WIDaT 2018

II WORKSHOP DE INFORMAÇÃO, DADOS E TECNOLOGIA

Informação, Dados e Tecnologia

Guilherme Ataíde Dias
Moisés Lima Dutra
Fábio Mosso Moreira
Fernando de Assis Rodrigues
Ricardo César Gonçalves Sant'Ana
(Orgs.)

Guilherme Ataíde Dias
Moisés Lima Dutra
Fábio Mosso Moreira
Fernando de Assis Rodrigues
Ricardo César Gonçalves Sant'Ana
(Orgs.)

Informação, Dados e Tecnologia

Faculdade de Ciências e Engenharia UNESP – Câmpus de Tupã
Tupã-SP
2019

Informação, Dados e Tecnologias

Copyright © 2019 GPTAD – Grupo de Pesquisa Tecnologias de Acesso a Dados

Organizadores | Organizers | Organizadores

Guilherme Ataíde Dias
Moisés Lima Dutra
Fábio Mosso Moreira
Fernando de Assis Rodrigues
Ricardo César Gonçalves Sant'Ana

Projeto gráfico e editoração | Graphic project & publishing | Diseño gráfico y edición

Fábio Mosso Moreira
Fernando de Assis Rodrigues
Ricardo César Gonçalves Sant'Ana

Capa | Cover | Tapa

Fábio Mosso Moreira

Equipe Técnica | Technical Team | Equipo Técnico

Daiane Marcela Piccolo
Fábio Mosso Moreira
Fernando de Assis Rodrigues
Guilherme Ataíde Dias
Jacquelin Camperos Reyes
Pedro Henrique Santos Bisi
Ricardo César Gonçalves Sant'Ana

C737 Informação, Dados e Tecnologia / Guilherme Ataíde Dias, Moisés Lima Dutra, Fábio Mosso Moreira, Fernando de Assis Rodrigues, Ricardo César Gonçalves Sant'Ana (org.). – Tupã : Faculdade de Ciências e Engenharia UNESP – Câmpus de Tupã, 2019.

635 p. : il. gráfs., tabs.

Inclui bibliografia.

ISBN: 978-85-67703-05-3

1. Informação. 2. Dados. 3. Tecnologia. 4. Ciência da Informação. I. Dias, Guilherme A. II. Dutra, Moisés L., III Moreira, Fábio M. IV Rodrigues, Fernando de A. V Sant'Ana, Ricardo C. G. VI Informação, Dados e Tecnologia.

CDD 020

http://dadosabertos.info/enhanced_publications/idt/

Sumário

Prefácio

Fábio Mosso Moreira.....7

Ciência Aberta: o papel dos metadados na descoberta de conhecimento

Ana Alice Baptista.....8

Integração de dados baseada em ontologias

Maurício Barcellos Almeida.....15

Curadoria digital e dados de pesquisa

Luís Fernando Sayão.....23

Infraestrutura brasileira para dados de pesquisa: reflexões

Pedro Luiz Pizzigatti Corrêa.....33

Text Mining: o uso de dados não-estruturados como insumo para extração de inteligência

Moisés Lima Dutra.....44

MPPB: a prestação de serviços ao cidadão através da disponibilização de dados

Marcos Vinícius Ferreira Cesário.....58

A gestão dos dados de pesquisa no contexto dos pesquisadores brasileiros na Ciência da Informação

Guilherme Ataíde Dias.....67

Dados de pesquisa e o profissional da informação

Plácida Leopoldina Ventura Amorim da Costa Santos.....73

A Ciência da Informação e os dados de pesquisa

Luana Farias Sales Marques.....83

A questão da identidade da Ciência da Informação frente aos cenários apresentados do paradigma dos dados

Sandra de Albuquerque Siebra, Ricardo César Gonçalves Sant"Ana, Plácida Leopoldina Ventura Amorim da Costa Santos e Luana Farias Sales Marques.....95

A emergência dos dados de pesquisa na ciência contemporânea

Wagner Junqueira de Araújo, Ana Alice Baptista, Marcello Peixoto Bax, Pedro Luiz Pizzigatti Corrêa e Luís Fernando Sayão.....113

Os princípios FAIR como diretrizes para maximizar o uso e (re)uso dos dados de pesquisa: traçando um paralelo com a gestão de documentos arquivísticos digitais

Pedro Jácome de Moura Jr., Maicon Henrique Ferreira Aragão e Bruno Cesarino Soares.....123

Práticas de gestão de dados: uma revisão da literatura sobre o termo Data Life Cycle

Débora Gomes de Araújo.....136

Metas, ações e indicadores como subsídios para análise da qualidade de dados: uma inversão necessária entre consequentes e antecedentes

Pedro Jácome de Moura Jr e Maicon Henrique Ferreira Aragão.....149

Previsões de ausência em cuidados especializados em Unidades de Saúde Pública de Florianópolis

Milena Maredmi Correa Teixeira, Leandro Pereira Garcia, Ingo Ramos, Douglas Dyllon Jeronimo de Macedo e Gustavo Medeiros de Araujo.....159

A construção do repositório de dados da UFPB: a experiência com o dataset de Arboviroses

Pollianna Marys de Souza e Silva e Sandra de Albuquerque Siebra.....175

Pornografia infantil: análise de manuais de pedofilia

Marcelo da Silva Moreira e Enrique Muriel-Torrado.....187

A Ciência da Informação e a educação em gestão e curadoria de dados de pesquisa

Gracielle Mendonça Rodrigues Gomes e Marcello Mundim Rodrigues.....200

Política de compartilhamento de dados científicos: a adoção nos periódicos da Ciência da Informação

Renata Lemos dos Anjos e Marynice de Medeiros Matos Autran.....213

Métodos multicritérios para auxiliar o processo de tomada de decisão sobre empreendimentos imobiliários utilizando modelos BIM

Bárbara Carvalho Diniz, Guilherme Ataíde Dias e Alzira Karla Araújo da Silva.....225

Web Scraping do ResearchID: proposta de sistema para o monitoramento de Índice H de pesquisadores no Brasil

Alexandre Ribas Semeler, Adilson Luiz Pinto e Arthur Longoni Oliveira.....240

Suporte à gestão de dados de pesquisa nas bibliotecas: identificação de serviços a partir da literatura

Fernanda Gomes Almeida e Marcos de Souza.....257

Revolução Científica? Reflexões para uma teoria crítica da Ciência dos Dados

Max Melquíades da Silva e Simone Cristina Dufloth.....268

Repositórios de dados de pesquisa: investigando sua adoção nos institutos brasileiros de pesquisa

André Luiz de França Madeiro.....282

Reconhecimento de entidades nomeadas em relatórios de inteligência financeira

Jairo Santana, Diefferson K. Moro, Rogério de Aquino Silva, Vinicius Faria Culmant Ramos e Gustavo Medeiros de Araujo.....291

Padrões de metadados para descrição de dados: panorama dos repositórios de dados na América Latina

Felipe Augusto Arakaki, Ana Carolina Simionato, Paula Regina Ventura Amorim Gonçalez e Plácida Leopoldina Ventura Amorim da Costa Santos.....303

O termo Big Data: quebra de paradigma dos n-V's

Marcos de Souza, Fernanda Gomes Almeida e Renato Rocha Souza.....314

O ensino da e-Science no âmbito dos Programas Brasileiros de Pós-Graduação em Ciência da Informação

Renata Lemos dos Anjos e Débora Gomes de Araújo.....326

Narrativas de visualizações guiadas por dados: Big Data e inovação

Adriana Alves Rodrigues.....337

Letreiros e amores: uma estratégia informacional para existir no Instagram

Tassyara Onofre de Oliveira e Matheus José Pessoa de Andrade.....350

Identificação de entidades destaque para a melhoria da Análise de Vínculos

Roberto Zaina, Vinicius Faria Culmant Ramos e Gustavo Medeiros de Araujo.....363

Humanidades Digitales: visualização da produção científica

Mirelys Puerta Diaz, Edgar Bisset Alvarez e Silvana Aparecida Borsetti Gregório Vidotti.....381

Gestão de dados da Biodiversidade: aplicação do padrão de metadados Darwin Core

Filipi Miranda Soares , Raíssa Yuri Hamanaka e Benildes Coura Moreira dos Santos Maculan.....397

Evasão estudantil e Ciência de Dados: primeiros passos de uma pesquisa aplicada no contexto da educação a distância da Universidade Estadual do Centro-Oeste

Sandro Rautenberg, Alan H. Costa, Paulo R. V. do Carmo, Renan Augusto Mattos Nutse, Maria Aparecida Crissi Knuppel e Marta Clediane Rodrigues Anciutti.....409

Direito Autoral + Creative Commons: uma solução para a academia na Sociedade da Informação?

Enrique Muriel-Torrado e Rebeca Silva Fernandes de Moura Andrade.....424

Design audiovisual para sistemas generativos: um experimento de construção audiovisual personalizada

Rafael Moura Toscano da Nóbrega, Valdecir Becker, Helder Bruno Alves Mendonça de Souza e Marianna C. Teixeira.....434

Desafios tecnológicos no processo de recepção normativa: adequação e conformidade na perspectiva da Lei de Proteção de Dados Pessoais

Andrea Carmo Name Willemin, Geralda Magella de Faria Rossetto e Cláudio José Amante.....447

As licenças Creative Commons e Software Livre como formas de proteção na sociedade da informação compartilhada

Maria Carolina Zanini Ferreira, Clarissa Stefani Teixeira e Enrique Muriel-Torrado.....464

Arbovis: uma aplicação de visualização de dados sobre Arboviroses

Talitha Alessandra Medeiros Ribeiro, Larissa de Sousa Moreira Gusmão e Damires Yluska de Souza Fernandes.....476

Análise de sentimentos: identificando sentimentos em comentários da Rede Humaniza SUS

Eduardo Alves Silva e Luis Felipe Rosa de Oliveira.....491

Análise da relação entre perfil e desempenho acadêmico dos alunos matriculados na disciplina de Introdução à Programação utilizando algoritmos de classificação

Roberto Silva de Oliveira Júnior, Douglas Valentim de Almeida Cardins, Wenddell Juler Pereira de Lima, Thereza Patrícia Pereira Padilha e Vanessa Farias Dantas.....501

A Ciência de Dados à luz da ciência do senso comum Aristotélico: uma análise comparativa com a tecnologia sensorial

Marcello Mundim Rodrigues e Tereza Cristina Fernees.....513

Aspectos do ciclo de vida de dados em processos de construção de ontologias biomédicas

Jeanne Louize Emygdio e Eduardo Ribeiro Felipe.....527

Direito fundamental à privacidade no Brasil: tendências

Rossana Gleucy de Ávila Chagas e Carvalho.....545

Informação e privacidade na Lei Geral de Proteção de Dados

Rosilene Paiva Marinho de Sousa, Fernando Antônio de Vasconcelos e Marckson Roberto Ferreira de Sousa.....555

O papel dos metadados na curadoria digital

Rachel Cristina Vesú Alves.....567

Proteção autoral de dados: uso de Blockchain

Elizabete Cristina de Souza Aguiar Monteiro, Jacquelin Teresa Camperos Reyes, Elaine Parra Affonso e Ricardo César Gonçalves Sant'Ana.....575

Tecnologia Blockchain: um novo paradigma no Ciclo de Vida dos Dados

Jailton Cardoso da Cruz.....588

A disseminação de informações associadas a epidemia do Zika Vírus: uma pesquisa a partir de dados coletados no Twitter

Guilherme Ataíde Dias, Denysson Axel Ribeiro Mota, André Luiz Dias de França e Eduardo de Santana Medeiros Alexandre.....599

Ciência Aberta: os desafios para concepção da ciência cidadã

Luciana Gonçalves Silva Souza, Izabel Antonina de Araújo e Júlia Rocha Ribeiro.....606

Metadados e Twitter: uso do Tweet Object para identificação de local

Denysson Axel Ribeiro Mota e Gracy Kelli Martins.....614

O papel do bibliotecário no processo de recuperação da informação

Miriam Cândida de Jesus, Nina Cláudia Mendonça Campos de Miranda e Célia da Consolação Dias.....*622*

Sobre os Autores

.....*630*

Organização Geral do Evento

.....*634*

Prefácio

Fábio Mosso Moreira[a]

O conteúdo deste livro é resultado das exposições e discussões realizadas no âmbito do II Workshop de Informação, Dados e Tecnologia (WIDaT), ocorrido entre os dias 27 a 29 de novembro de 2018, nas pendências da Universidade Federal da Paraíba (UFPB).

O WIDaT é um fórum de pesquisadores e demais envolvidos com a questão do acesso e uso a dados, oriundos de áreas como a de Ciência da Informação, Ciência da Computação, Engenharias, Matemática e Administração entre outras.

O evento abre espaço para participação de representantes do setor privado e do governo, possibilitando desta forma a realização de um amplo diálogo que possibilite operacionalizar uma Rede de Pesquisa Brasileira de Acesso a Dados.

A segunda edição foi organizada pelo Programa de Pós-Graduação em Ciência da Informação, da Universidade Federal da Paraíba (UFPB), sob coordenação do Prof. Dr. Guilherme Ataíde Dias, e ampliou os resultados da primeira edição do evento realizada em 2017, no âmbito do Programa de Pós-Graduação em Ciência da Informação, da Universidade Federal de Santa Catarina (UFSC).

O formato deste livro foi idealizado pelo Prof. Dr. Ricardo C. G. Sant'Ana, coordenador da Comissão Científica, e tem como essência reunir, não só os textos dos artigos publicados no evento mas, também, permitir o acesso aos demais conteúdos gerados. Neste esforço de ampliar o acesso e visibilidade da grande troca de conhecimento ocorrida durante o evento, foram incluídos nesta obra os conteúdos das palestras e mesas de debate. Cabe especial destaque, ainda, a inovadora proposta de divulgação dos vídeos, dos slides e das transcrições das apresentações dos autores e dos palestrantes, contribuindo, assim, para a ampliação das possibilidades de acesso e uso do rico conteúdo resultante das diversas atividades do evento. Trata-se, portanto, de um marco na trajetória das publicações ampliadas, em especial àquelas relacionadas a eventos.

a Universidade Estadual Paulista (UNESP). E-mail: fabio.moreira@unesp.br. ORCID: https://orcid.org/0000-0002-9582-4218. Currículo: http://lattes.cnpq.br/1614493890723021

Ciência Aberta: o papel dos metadados na descoberta de conhecimento

Open Science: the role of metadata in the knowledge's discovery

Ana Alice Baptista[a]

Transcrição da apresentação

Para mim é bastante diferente, mas é muito bom, é um prazer imenso estar aqui, a primeira coisa que eu queria dizer é agradecer a Universidade Federal da Paraíba, ao evento o convite. Cumprimentar meu colega, os que eu conheço e os que eu não conheço, cumprimentar também a audiência e desejar a todos um excelente Workshop.

Queria dizer também que gostei muito das falas da mesa, gostei muito de saber que os anais do Workshop vão ser disponibilizados assim dessa forma. É uma almofada de ar fresco, porque nós já temos as tecnologias para fazer isso a anos, e a comunidade científica é muito conservadora nos seus processos, não é conservadora em suas investigações mas em seus processos na minha opinião é muita conservadora.

Nós já mudamos e temos as tecnologias suficientes para fazer muitas coisas e não fazermos, e portanto é muito bom e fico muito feliz, dou toda autorização para fazerem a transcrição ou fazerem que quiserem porque é disso mesmo que precisamos, precisamos pôr as coisas a mexer, abalar um pouquinho as estruturas e fazer de forma diferente, porque não é pela dificuldade tecnológica que não fazemos. Essa era uma das coisas que eu ia dizer e portanto certamente estou aqui com essa perspectiva para contribuir para algo de bom, para que as coisas que fazemos estejam disponíveis e possam ser usadas, é disso que eu venho a falar hoje.

Eu vou falar de ciência aberta, da minha perspectiva de ciência aberta, eu tenho trabalhado ultimamente nas temáticas dos dados fundamentais abertos com a consciente aberta, na Europa eu tenho sentido que a ciência aberta está um pouco ao horizonte de algumas coisas, e o nível de tecnologias, de perspectivas de organização da informação, da minha perspectiva os dados fundamentais abertos estão a caminhar na ciência aberta.

Mas a ciência aberta também já está a querer a pegar o comboio. Acho que alguns anos atrás eu ficava muito na questão do acesso infra ao acesso aberto que é muito importante, mas muito na questão do repositório e pouco além dos repositórios. Portanto vou dar minha perspectiva sobre isso, vou falar do Linked Open Data ou dados linkados abertos, acho que no Brasil seriam dados abertos vinculados, metadados e claro para aquilo que me convidaram para vir aqui que é papel dos metadados na ciência aberta e que tem a ver com essas coisas todas.

E vou começar falando o que significa estar aberto. Estar aberto eu vou buscar a definição da Open Knowledge Foundation que diz que aberto significa que qualquer pessoa pode livremente usar, modificar, compartilhar, para qualquer propósito, portanto está aberto para outro acessar.

No Portal Português de Ciência Aberta tem uma frase muito interessante que é essa "o conhecimento é de todos e para todos". Está de acordo também com o que diz a Open

a Universidade do Minho (Uminho). E-mail: analice@dsi.uminho.pt. ORCID: https://orcid.org/0000-0003-3525-0619. Currículo: http://www.degois.pt/visualizador/curriculum.jsp?key=4103065722022437

Knowledge Foundation o conhecimento e para todos e não somente para alguns. E também com o que o senhor vice-diretor vinha a dizer, e o professor Ricardo e professor Guilherme, na questão da distribuição do conhecimento, ele não pode ficar enclausurado, precisa ser distribuído, disseminado por todos.

Ciência aberta, estamos a falar sobre o que significa estar aberto, está aberto não é só estar disponível, é mais do que isso, é poder ser utilizado. Na Ciência Aberta estamos a falar de partilha sem reservas, de informação, isso aqui já é um olhar meu, sobre o que está no portal português de ciência aberta.

Não estamos apenas a falar de partilha de documentos, de partilha de dados, estamos a falar de partilha de processos também do processo científico, na verdade é da cultura da informação dos processos científicos, expandindo um conceito de responsabilidade social.

Portanto, o que aparece no portal da ciência aberta português fala que publicações e dados abertos, a investigação e inovação abertos, eu botei aqui processos de investigação e inovação abertos, redes abertos, ciência e ciência aberta.

Eu acho que aqui nas publicações não são só publicações, portanto eu não compilei nada sobre mas eu acho que aquelas publicações não são apenas textos, temos mais coisa, portanto temos os vídeos, áudios, fotografias, o que tivermos, desde que sejam carácter científico. Eu mudei então em vez de chamar de publicações vamos chamar de fatos, mas de enquanto estiver a falar sobre publicações estamos a enfocar no texto, e nós podemos fazer muito mais.

Desmistificar os artefatos e os processos, portanto chega da gente ter as coisas disponíveis online, vou dar aqui alguns exemplos. Este aqui são vídeos, e screenshots de vídeos do periódico de vídeos, de um artigo que publicado em texto e possui um vídeo acompanhado. Este aqui é também uma captura de tela da informação e dados que estão disponíveis no European Portal de dados de ciência e tecnologia, portanto são dados científicos que estão ali.

A gente ter só disponível o vídeo é suficiente para encontrar esse vídeo, é o suficiente para conseguir manipular esses dados? Nós conseguimos manipular esses dados, e depois de entrara ali não consegui compreender nada daquilo. Os vídeos estão disponíveis, mas precisamos de mais um bocadinho além de publicar os artefatos na Web e achar que estamos a fazer ciência aberta.

Tem fundação do suporte que não são facilmente encontrados não são pesquisáveis. Então por que vamos abrir se eles estão ali mas não são encontrados e nem pesquisáveis, não dá para fazer nada, qual as necessidades de abrir.

Outro exemplo, entrando dentro dos dados fui buscar dados que a gente consegue ler, esse aqui é em espanhol, e me diz uma coisa, para compreender o que significa entrar aqui dentro dessa ciência, entrar e compreender o que são aqueles dados, para nós humanos que sabemos ler francês, espanhol, e conseguimos saber o significado daquilo que está escrito, não é fácil.

Eu tentei e não tenho a certeza de ter conseguido compreender aquilo, e também embora aqui seja um pouquinho mais fácil, eu tenho número de avaliadores na gestão pública mas eu não sei o que é este CIA, portanto há aqui bastante coisa que a gente não sabe o suficiente para conseguir interpretar esses dados de forma fidedigna, por mais que entenda o que está aqui escrita, aqui eu tenho o portal, etc., várias parcelas, mas por mais que a gente entenda aquilo não conseguimos interpretar bem aqueles dados.

E nós somos humanos, nós temos capacidade de interpretação, agora tendo esses dados abertos e máquina virem buscar esses dados e tentar aproximar esses dados automaticamente sem intervenção humana, ou com pouca intervenção humana, com outros dados não consegue fazer.

Portanto muitos dos artefatos que tentamos disponibilizar não são interpretáveis, e facilmente utilizados por causa disso. A minha utilização dos dados está diretamente ligada com coisas automáticas ou mais automáticas possível, está diretamente ligada a interoperabilidade, em particular, à interoperabilidade semântica, que é ser significado, deve ser informação que permita as máquinas interpretar o que está ali. Portanto se essas informações não vem junto com os dados não se consegue interpretar.

Se não se consegue utilizar nem interpretar para que abrimos? Para que disponibilizar? Na verdade precisamos de dados, na ciência aberta lidamos com dados, e dados sobre os dados, e quando falta dados não faltam só dados, faltam também outras coisas. Nós precisamos dos dados e dos catálogos, e tudo com os formatos adequados e significados embutidos, tenho que trazer significado para que eles possam ser interpretados.

Repare aqui, entrevistas foram realizadas com indivíduos que trabalham em instituições de ensino superior. Pelo catálogo eu consigo ter aquelas informações todas sobre os dados, e consigo ter aquela informação conforme processada por máquinas.

Outro exemplo, datasets que conjuntos de dados foram voltados de questionários sobre a necessidade de informação de médicos, portanto os nossos catálogos podem ter coisas mais simples outras mais rebuscadas.

E depois outra coisa que já tem a ver com os dados, entrar nos dados por dentro e ter mais informações, não apenas informações nos catálogos, mas também informação que está nos dados, e se esses dados trouxer significado com ela a gente consegue responder perguntas mais complexas, como por exemplo, que artigos sobre as necessidades de médicos oncologistas apresentam como resultado necessidade de informação sobre diagnóstico?

Aqui estamos a falar dos dados e aqui estamos a falar dos catálogos. Se essa informação vier dos dados e estiver em uma forma processável por máquina e trazer significado a gente consegue fazer perguntas desse gênero, e consegue aproximar isso daqui com dados de outros sítios facilmente.

É preciso poder interpretar facilmente não somente os catálogos mas os próprios dados. Tem havido um esforço grande por tratar os catálogos em Linked Open Data mas os dados também precisam estar em Linked Data, ou múltiplas informações sobre os dados precisam estar nos catálogos, temos que incluir mais informação no catálogo.

Este aqui é o primeiro site que eu pus no início quando tinha feito a definição de ciência aberta, e portanto são estas coisas todas que para mim que trabalho com dados e imagino que para muitas pessoas que estão aqui, nós precisamo a falar de dados, dados e metadados.

O que nós vamos ter de fato são artefatos e dados sobre os artefatos, os dados abertos também são um tipo artefato só que na definição aparecem separados, e dados sobre dados abertos, o processo e dados sobre o processo, redes abertas de ciência e dados sobre redes abertas de ciência.

Ter os processos abertos mas ter os processos abertos significa ter também dados sobre os processos, e estes dados estarem também abertos, e podem ser trabalhados e processados e cruzados com outros dados.

E informação devem ser interpretáveis para humanos e para máquinas, portanto devem ser human-readable e machine-readable. Uma das coisas que eu vejo também é gente que balança entre dois extremos, um é tudo human-readable ou ter tudo machine, nós humanos precisamos também de ler e processar aquela informação e buscar aqueles dados, e se a informação não estiver legível por máquinas também não conseguiremos trabalhar aquilo.

Viemos aqui a uma sigla que vocês já ouviram que é FAIR, que os dados devem ser FAIR, quer dizer Findable, Accessible, Interoperable and Reusable, ou seja, encontrável, acessível, interoperável e reutilizável. Na minha opinião é que tem havido um esforço muito grande aqui no Findable e no Accesible e esforço bastante menor aqui no Interoperable e Reusable, e eu acho que nós estamos na hora de fazer esse esforço. Tem havido algumas iniciativas mas é preciso mais, é preciso um esforço da comunidade para encontrar esses dados que nós temos disponíveis. Eu sei que os dados de catálogo ainda não são interoperáveis, eu sei que nós temos iniciativas mas não chega, vamos por dados linked data nos catálogos.

Quando eu falo que nestas coisas, no FAIR, estou a falar da coleta de metadados, portanto não estamos a fazer as coisas ainda bem-feita. A gente precisa mudar para o paradigma dos dados abertos dos dados em linked data. Por que? O linked data são dados semanticamente interoperáveis através de comunidades de prática, empresas, governo, possuem uma dificuldade de interoperabilidade mas nós temos que caminhar para lá.

Atualmente na minha opinião o cenário que nós temos é esse. Temos artigos, teses, relatórios, que falam muito bem um com os outros, com o protocolo PMH, mas falam mais ou mesmo porque depois vamos ver os metadados e vemos que algumas coisas não cruzam com outras. Depois temos os repositórios científicos com protocolos que também falam uns com outros, e também algumas outras coisas que falam com outras e estão ali.

Então temos ali coisas que falam uns com as outras mas que não falam com quem estão ao lado, atualmente a expressão que tem sido muito utilizada são os silos de dados. E Quando eu falo de interoperabilidade local é para essas coisas falando uma com as outras, é ter um mínimo de interoperabilidade, quando eu vou a Inglaterra eu não falo com os ingleses mas eles vão me reconhecer, e a mesma coisa com os franceses certo, mas entre os franceses e os ingleses eles conseguem resolver a questão. Com o espanhol todos temos essa questão que também estamos conseguindo resolver a questão. A interoperabilidade é isso, é por significado perceptível pelo outro.

Aqui um exemplo da LOD cloud, que significa Linked Open Data cloud, e esses aqui são datasets, são cada vez mais datasets, e a gente consegue ver ali no meio uns especiais que são a DBPedia por exemplo, mas hoje já tem muitos datasets. Esses datasets para estarem aqui tem que ter dados abertos e cumprir as regras do linked data.

O que eu falo é o que o Berners Lee chamou de dados cinco estrelas, em data portals você encontra dados em XLS e CSV, portanto estamos a falar de duas estrelas e tres estrelas. Mas o que isso significa?

Isso significa que o primeiro está na web mas é PDF, que não é facilmente processada. O segundo está na web como dados estruturados, como por exemplo XLS mas é formato proprietário. O terceiro é igual a este mas já não é proprietário, como CSV. O quarto é estar em RDF, que é um formato de base da web semântica. E o quinto é ser linked data, que significa linked data? Linked data significa dados com contexto, dados com significado, ou seja, eu preciso ter os meus dados e preciso não só de ser ligados entre eles, mas ser ligados a outros dados que já existem para darem contexto aos meus dados. E esses dados que já existem eles próprios estão ligados entre eles e estão ligados com outros, e que nós temos esse tal grafo que vocês viram anteriormente aqui destas ligações todas entre dados e datasets.

O que nós falávamos no início da ciência aberta? Dos artefatos e dados, no portal da ciência aberta portuguesa, nós criamos essas coisas todas não aqui mas aqui em cima, no linked data. Por isso precisamos de identificadores para as coisas, em Web Semântica temos que identificar coisas, e os identificadores têm que ser únicos, e depois ligar esses dados todos, para trazer contexto.

Aqui está um exemplo que eu trouxe, reparem aqui, isto aqui é uma parte de um vocabulário feito pelos meus alunos, no âmbito desse trabalho eles tiveram que cuidar de um vocabulário controlado de áreas científicas e importar aquilo em uma tecnologia que se chama SKOS. Então eles fizeram isso e aqui é uma parte, temos aqui um conceito que é um conceito da área de economia que faz parte desse conceito maior que é o 110, que é indivíduos, instituições e metadados.

Este aqui é chamado na descrição de dados com o link. Em vez de pôr economia, que está human-readable mas está aqui machine-readable o link para conseguir ser processado. Quando eu falo de link para outras coisas é isso, nós temos nossos dados e que ligam com outras coisas. Quando a gente for utilizar este vocabulário controlado pode utilizar pode interrogar meus dados como se tivesse em uma grande gama de dados e não como se estivessem confinados.

Aqui trago outro exemplo que é também do meu grupo de investigação, reparem tem informação sobre várias coisas do grupo, quem é líder do grupo, nesse caso não puseram nome mas está aqui o link, é um link ORCID da pessoa que está a frente do grupo de investigação. Quando falamos de linked data é isso, ou seja, não aparece nenhum nome mas aparece para as máquinas processarem o link. A mesma coisa aqui, e aqui outra vez a mesma coisa, apontando para um vocabulário controlado para dizer qual área, isso é o linked data, é ter as coisas ligadas, é trazer contexto.

Se eu puser tecnologia TSI que é tecnologia e sistemas de informação nós compreendemos mas para uma máquina qualquer a processar aquilo em um contexto qualquer não compreende o que está ali, precisa de informação adicional, senão vou processar inglês, francês, português, tudo igual.

Isso é um exemplo de um grafo mas é uma coisa muito pequenina, na LOD Cloud, é um grafo RDF. Tendo isto nós conseguimos ter isto que é que queremos, e a pergunta que eu faço é hoje o professor Ricardo Sant'Ana disse que os anais desse workshop vão ser publicados em uma forma completamente distinta e aberta. Quando eu falo aberta não é estar simplesmente na Web, quando eu falo aberta é vídeo, texto, etc, aberto no sentido de mais larga.

O que eu gostaria muito é que isto aconteça e estar a acontecer, no governo eletrônico isso está lá na frente na Europa já aconteceu, na ciência está mais devagar, mas pode ser que passe a frente do governo eletrônico. Quando digo isto eu falo de iniciativas da Europa, não estou a falar de casos fantásticos da ciência que ocorrem nos EUA, mas eu vejo alguma coisa em escala a acontecer.

A minha apresentação via terminar aqui, fiquem com esses desafios para vocês, pensem e levem isso convosco, vão ter mais apresentações aqui hoje que estão relacionadas com essa temática, e portanto pensem nisso e pensem em fazer.

Mais algumas coisas que eu acho que pode ser interessante para vocês da Dublin Core Metadata Initiative tem um canal do Youtube com alguns vídeos, a maior parte são inglês mas têm também em espanhol, e português. Há um projeto que tem um muitos cursos interessantes, não só em texto mas também em vídeo, e que são linkados, colocados no linked data, portanto podem confiar.

E se quiserem eu tenho um Scribd sobre Web Semântica que às vezes ponho coisas interessantes, podem também consultar que pode ser interessante. Depois chamar atenção para essa recomendação, ontem ainda eu vi o professor Guilherme falou sobre três brasileiros, é sobre guia prático para se ter dados na web. Isto aqui ainda não está tal como a gente gostaria mas é um bom conjunto de boas práticas para dados na web.

Também chamar a atenção para essa linguagem, que é uma linguagem para fazer espécie de templates para registros RDF, e portanto para fazer uma espécie que funciona como um Schema, que são espécie de formas onde avaliamos nossos dados para ver se nossos dados estão de acordo com as regras definidas, para repositórios, e para quem tem responsabilidade para criar normas pode ser interessante.

Depois por último acompanhar os trabalhos deste Dataset Exchange Working Group que está desenvolvendo uma série de especificações do W3C sobre essas temáticas. Aqui tem várias coisas acontecendo neste grupo começou com um objetivo pequeno e hoje tem quatro ou cinco especificações.

São coisas muito recentes que estão acontecendo e vale a pena que vocês de vez em quando entrem lá para ver o que está a acontecer. E pronto, termino aqui, muito obrigado, e estou aberto a questões.

Vídeo da apresentação

Título: Ciência Aberta: o papel dos metadados na descoberta de conhecimento.

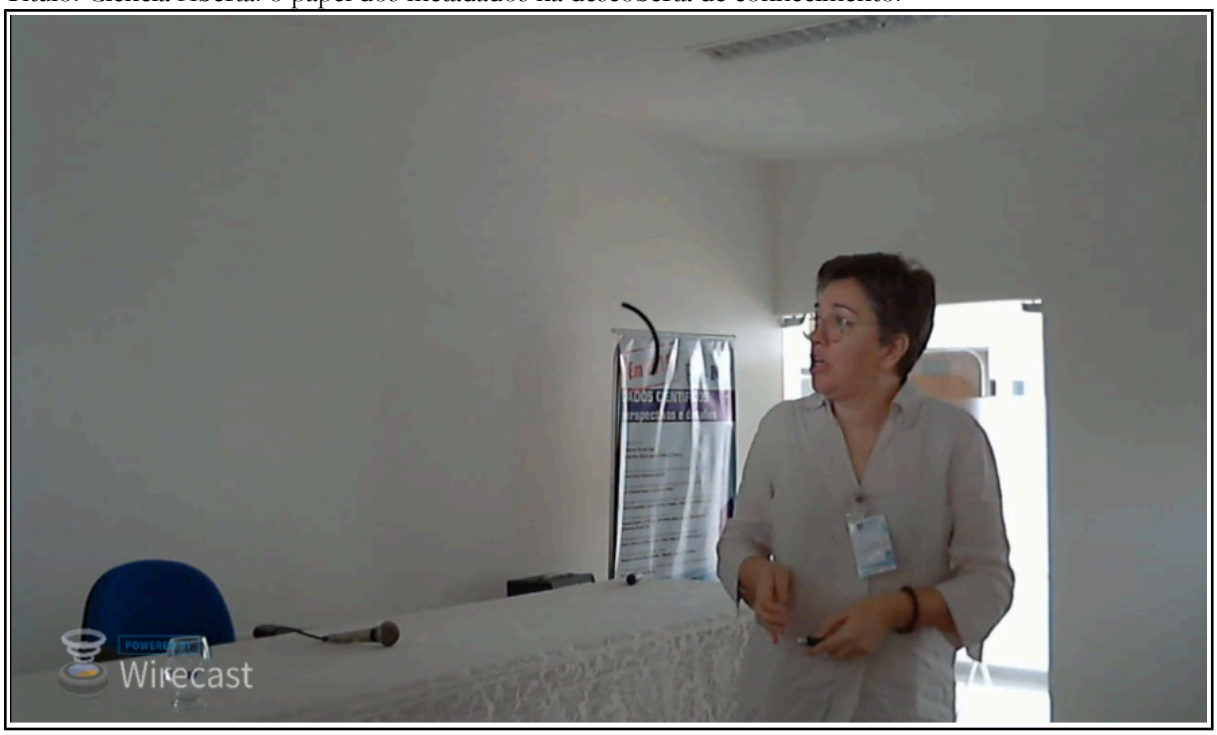

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=28

Integração de dados baseada em ontologias

Data integration based on ontologies

Maurício Barcellos Almeida[a]

Transcrição da apresentação

Eu vou falar um pouco sobre a interação de dados baseados em ontologias que é um interesse de pesquisa já há uma década. Como foi falado eu sou da UFMG, do Programa de Pós-Graduação em Gestão e Organização do Conhecimento, da Ciência da Informação, o grupo de pesquisa também liderado por mim e pelo professor Renato da FGV, que é o "Representação do Conhecimento e Ontologias de Dados", e tenho trabalhado também em conjuntos com universidades estrangeiras com pesquisas nessa área de modelagem e ontologias.

A palestra está dividida em quatro partes, a primeira é mais uma introdução, e o objetivo é explicar um pouquinho o que é interoperabilidade e como a ontologia pode ajudar nessa questão especialmente porque ontologia pode resolver tanto problemas de interoperabilidade quanto problema de ter solução. Mas se a gente souber identificar tipos de dados que a gente está manipulando talvez seja mais fácil aplicar as ferramentas adequadas inclusive a ontologia, é isso que eu pretendo explicar para vocês.

O que é ontologia? é uma palavra que muita gente tem dúvida, se você colocar no Google vai achar desde Filosofia até Computação, mas é uma palavra bem mais conhecida do que a gente pensa. Aqui por exemplo tem a porta de um D.A. lá da UFMG escrito "uma casa ontologicamente sustentável", não tenho certeza se a pessoa que escreveu sabe do que se trata mas está lá.

Aqui também tem outro exemplo de uma pichação na época das manifestações de 2013 e 2014, isso é lá no Rio Grande do Sul, um aluno de lá tirou e enviou para a gente. Mas o que realmente define melhor ontologia, por incrível que pareça, é o Neymar. Aqui nós temos o Neymar porque um dom ontológico, logicamente isso é uma brincadeira de um jornal de Belo Horizonte que custa 25 centavos, o que a gente pode esperar que seja de uma informação fidedigna. Mas é interessante ver com é que a ontologia está em todos os cantos.

Saindo da brincadeira, a ontologia é um termo que aparece desde a Filosofia Alemã desde o século 17, quase há dois séculos, e hoje em dia a gente encontra também muito área da Computação e da Ciência da Informação, e por um órgão que regula a tecnologia na área de Web Semântica.

A melhor definição de ontologia que eu consegui até hoje, apesar de várias que existem, é uma definição até antiga de um autor na área de inteligência artificial que fala que é tipo um cabide conceitual, onde nós vamos entulhando conceitos que podem ser usados para diversos motivos, mas a estrutura principal é essa esquelética, é o que a gente pode depois preencher com mais dados.

a Universidade Federal de Minas Gerais (UFMG). E-mail: mba@eb.ufmg.br. Currículo: http://lattes.cnpq.br/5218069708058487

A ontologia aplicada de certa forma ela vai reunir todos esses conceitos da metafísica e ontologia filosófica e aplicar como princípio de modelagem, a construção de ontologias na área da Computação e da Ciência da Informação. Então basicamente ela abre com conceitos e a gente vai descrevendo o mundo.

Nesse aspecto, da mesma forma que as pessoas amam Saracevic, a palavra lá em 96 na ligação com a inteligência artificial, do mesmo jeito que as pessoas precisam dos conceitos para falar e se expressar, o computador precisa dessa estrutura de mundo para fazer inferências automáticas.

Os aspectos que a gente pode também auxiliar hoje em dia é a questão de interoperabilidade dos sistemas, principalmente os sistemas médicos. A interoperabilidade é uma palavra que está na moda, todo mundo fala da interoperabilidade, mas realmente é uma coisa que a gente escuta mais falar do que uma solução.

Na verdade, eu acredito que não há uma solução perfeita, acredito que a gente pode mitigar o problema. No caso dos sistemas médicos, como a gente tem trabalhado lá na UFMG, por exemplo, na área de obstetrícia, tem dificuldades porque tem consultas médicas desde o parto até depois a continuidade dos cuidados ao recém-nascido, e isso é importante que o profissional de medicina possa ter acesso aos prontuários dessa pessoa independente de onde ela está, que podem ser hospitais diferentes mas tudo tem que estar transparente. Então a ideia da Medicina está muito ligado a essa questão com a nossa pesquisa que pretende ajudar.

Falando um pouquinho sobre a representação do conhecimento então, do ponto de vista semiótico, eu vou até começar a falar mas deve ter especialistas aí na área de semiótica, mas eu vou ser bem simples até porque tem pouco tempo. Mas a semiótica é a forma que o significado é gerado através da interpretação de dados sensoriais, e o criador foi Pierce, matemático e filósofo do século 19.

Peirce criou um triângulo conhecido e que tem uma lógica criada pelo próprio Peirce, e depois disso a gente teve diversas interpretações na área de Ciência da Informação, e também na década de 70 mais conhecida na nossa área de Biblioteconomia e Ciência da Informação.

Qualquer que seja o triângulo adotado a ideia da semiótica é bem simples, a pessoa a medida que ela percebe pelo signo, desenho ou palavra escrita, ela forma um conceito na cabeça dela a partir da lembrança que ela lembra de ter visto do objeto. Então esse desenho do elefante ela lembra que o pai levou no zoológico quando era pequena e lembra que esse bicho aqui é um elefante.

A ideia do triângulo semiótico, agora adaptado para a ontologia, eu tenho aqui um objeto que pode ser representado por um signo a partir de uma compreensão, então eu chamo aquele animal de elefante porque eu aprendi assim assim, é uma convenção. No entanto, eu poderia chamar gato se fosse assim que fosse ensinado a gente desde pequeno.

O conceito que se forma em nossa cabeça a partir da experiência, aquela do signo, e também temos as arestas do lado direito para a percepção, quando eu vejo um signo eu formo o conceito. Segundo o Pierce é isso que acontece com um signo e como interpretar o que ocorre no ambiente.

Eu gostaria de pedir licença para sugerir um novo triângulo um pouquinho diferente, que vai ficar mais fácil de identificar o que eu quero passar para vocês. Então esse triângulo de significados que eu vou apresentar aqui. Desse lado eu vou ter Símbolos, que pode ser diverso, pode ser cachorro, dog, perro, outros nomes de cachorro, são todas as coisas que vão se referir aquele animal cachorro. Desse lado eu tenho os indivíduos, que eu coloquei uma foto do Marley que é um cachorro específico, e desse lado eu vou pedir licença para colocar um outro conceito que é o Universal. O Universal que é muito controverso no plano aristotélico, basicamente ele quer dizer um título natural, que existe independente da nossa vontade, por exemplo, aquela árvore ali fora existe, o sol existe, se por acaso eu morrer amanhã o sol continua lá.

A classe é um pouquinho diferente. A classe é uma criação humana para determinado fim, por exemplo, eu crio a classe das pessoas que estão assistindo aula tal hora porque tem que fazer chamada, a classe dos carros que param no estacionamento da UFPB porque vão ter um crachá, então é um pouquinho diferente dos Universais mas até as pessoas tratam como se fosse a mesma coisa.

Nesse triângulo eu tenho também os símbolos, representando indivíduos, a aresta da denotação, os símbolos também remetem aos universais, e os indivíduos instanciam do universal. Eu tenho um universal cachorro eu tenho Marley que instância o universal cachorro, mas eu posso criar a classe cachorro que vão ser vacinados.

Com esse triângulo eu vou dar alguns exemplos que vão me ajudar explicar minha ideia. Então eu tenho aqui o indivíduo o Marley, que é o cachorro, outro exemplo, Marley é um cão, no lado aqui dos símbolos eu tenho que cão é um substantivo, já não estou falando de indivíduo, estou falando de entidade linguística, palavra cão. Cannis familiaris então são sinônimos, um outro aspecto linguístico, a questão da sinonímia. Cães são vertebrados é uma propriedade universal, todos os cães são vertebrados, não existe cão que não seja vertebrado. Por último eu tenho que cães são possíveis transmissores de raiva, então essa é uma possibilidade, é um conhecimento contingente.

Com esse exemplo eu vou criar o que eu vou chamar de níveis de representação, e daí vou dar vários exemplos de como a tecnologia pode atuar nesses níveis de forma a contribuir com o controle a atividade.

Os níveis que eu vou apresentar para vocês eu vou chamar de nível ontológico, de contingente, linguístico e pactual. Aqui eu apresento de novo a figura que acabamos de ver, aqui do lado dos indivíduos nós temos o nível pactual, com declarações das entidades e seus relacionamentos com o mundo, que é o caso do Marley que vive em um lugar chamado Terra, o Marley é o cão.

Do lado de cá eu tenho as propriedades dos significados para os signos de linguagem, é uma especialização do signo, aqui eu estou me referindo às questões linguísticas, são os substantivos, eu tenho sinônimos. Em cima eu estou chamando de nível ontológico, são signos universalmente verdadeiros, tem vários exemplos disso na Medicina que nós estamos lidando, só temos hepatite no fígado, não tem como ter hepatite em outro lugar. São vários axiomas que existem e podem ser facilmente levantados. Por último o nível do contingente, aqui o exemplo que cães são possíveis transmissor de raiva.

Eu vou mostrar agora para cada um desses níveis exemplos de como a tecnologia pode agir e ao final a gente vai mostrar como os sistemas vão usar esses diferentes níveis, então se a pessoa entender o nível de dados que ela está tratando ela vai poder utilizar a ferramenta tecnológica mais adequada, a gente vai ver que a possibilidade de conseguir seria via ontologias.

Um exemplo primeiro do nível pactual, são declarações sobre indivíduos, no caso aqui sobre o cachorro Marley. Declarações sobre indivíduo são feitas na computação desde os anos 70 pelos especialistas pela tripla entidade-atributo-valor, ou E-A-V. Nos anos 2000 a gente teve coisa parecida que foi inventada no caso o RDF falado na palestra anterior, e que não é nada diferente do que foi criado nos anos 70, o que muda agora é que se chama sujeito – predicado – objeto, mas é a mesma ideia.

RDF já tem quase 20 anos, tem outros recursos bem mais avançados para lidar com dados, mas RDF continua sendo algo muito importante. Então essa linguagem sujeito – predicado – objeto é exatamente isso, Marley é um tipo de cachorro, Marley viveu na Terra, então não tem uma forma mais intuitiva de apresentar dados do que o RDF. Me parece bem mais simples que os bancos de dados, mas, de qualquer forma, fica a ressalva que ela tem limitações.

A gente precisa extrair dados sobre os indivíduos, no caso la o Marley, mas aqui eu tenho um exemplo de como se fosse um prontuário médico de uma pessoa com alguma doença e eu tenho que instanciar essa pessoa com um tipo de doença e para um termo geral que está em um vocabulário. Então essa extração dos termos do prontuário são marcados com esses termos podem ser identificados por outros sistemas. Essa é uma forma de extração da informação no ponto de manipulação de indivíduos.

Agora vou dar um exemplo sobre a questão dos signos, do nível do bicho. Aqui uma marcação das partes do discurso que mostra que aquele erro lá é um substantivo, o fato dele ser um substantivo vai ajudar muito aos programas aí que lidam com padrões léxicos e lidam com uma série de coisas então essa marcação é muito importante, e o processamento da linguagem natural fazem isso com muita eficácia hoje em dia.

Aqui um exemplo também de um padrão para extrair informações de um determinado focus, por exemplo se usar dados de padrões eu consigo definir que CDA significa alguma coisa, então a gente vai pegar os prontuários existentes dessas formas. Uma coisa que eu esqueci de comentar ali é que por mais que a gente goste de estruturas em um prontuário de pacientes, os médicos quase sempre prefere escrever como um texto, é o que a gente tem que tentar para ajudar o profissional então essa questão do texto livre apesar de ser inicialmente uma coisa muito utilizada, seria forma preferível dos profissionais que vão lidar com isso.

Um outro exemplo no nível ontológico, dos universais. Ali a gente tem uma representação em OWL, uma linguagem bem mais avançada que o RDF, e eu tenho aqui cachorro que é subclasse vertebrada, vertebrado que é subclasse de animal, e a classe dos vertebrados quando eu coloco palavras equivalentes a eu to colocando necessários o suficiente, que é o que se deve fazer com o conceito completamente, então eu estou colocando vertebrado em uma classe que o animal tem alguma parte. Essa é uma lógica meio aportuguesada mas se eu colocar isso em OWL em um motor de inferência como o Protege ou de ontologias, eu vou achar que é um assunto universal no questionário, e a ontologia é capaz desse tipo de coisa.

A ontologia não vai ser uma panaceia que vai resolver todos os problemas de integração, ela vai resolver problemas com nível básico, problemas em um nível mais abstrato, mais próximo à necessidade humana vão ser inicialmente difícil de resolver, mas é importante que a gente comece com algum nível de dificuldade e depois vão evoluindo.

Aqui um exemplo dessa inferência que eu acabei de mostrar, não existem pontos que não tenha ossos, então eu tenho ali a classe vertebrada embaixo de animal. Protege pra quem não conhece é um construtor de ontologia que vem com um motor de inferência, que são algoritmos que fazer inferências automáticas.

São coisas simples mas são exemplos de inteligência artificial, então eu tenho aqui vertebrado ao lado direito a classe equivalente tem em marte alguma vértebra, subclasse animal. Se eu rodar uma consulta como esta no lado direito ali e peço todos os cachorros que não tem alguma parte que não seja osso eu vou ter inferência e vou ver ali no lado direito que não existe essa classe. Então você construir ontologias na Ciência da Informação e trabalhando com vocabulário, é muito interessante porque o motor de inferência ajuda a achar coisas que você não vê. Às vezes você vai trabalhar com um vocabulário é bem razoável você conferir ali a consistência do seu vocabulário.

Aqui tem outro exemplo de extração de relações taxonômicas, que são oscilações básicas que a gente encontra em ontologias, através de chavões taxonômicos. Então eu tenho se ele acha um substantivo, como aqui no exemplo, então ele vai identificar que esse GAR 3 vai é subclasse de uma proteína. Abaixo outros padrões que eu vou conseguir identificar que fraturas são tipos de machucados, e por exemplo, um tipo de doença mental.

Aqui um exemplo de extração de outras relações, por exemplo, o algoritmo que faz o web mining procurando na própria Internet ou banco de dados Wikipédia ou outros DBPedia, e, por exemplo, aqui vamos ter que achar um tipo de informação buscando, então estudar sua definição que está no seu lado direito que foi buscar na própria Web e conseguiu a informação.

Por último, o exemplo do nível do contingente, que seria o conhecimento possível, tem um exemplo desses vetores de raiva. Essa aqui é uma fala de um importante cientista de ontologia do mundo, é um professor de Manchester, ele fala que muito trabalho sobre ontologia na área da computação tem objetivo integrar o raciocínio tipo com o raciocínio probabilístico, isso porque Medicina trabalha grande parte com dados estatísticos, mas a ontologia trabalha apenas com raciocínio clássico, então em geral, sistemas clínicos vão muito além do que ontologias podem proporcionar. Mas a ontologia é o primeiro nível de integração para sistemas para depois pensar em níveis mais avançados e abstratos próximos do raciocínio humano.

Um exemplo da tripla RDF para mostrar como é que conclusões podem ser representados em RDF. Eu já tinha dito que o RDF não é uma linguagem com semântica bem definida, os termos podem ter diferentes interpretações, eles são complexos no sentido de que são montados, e não posso afirmar 100% dos casos quando faço declarações RDF.

No exemplo que eu dei sobre a tripla sujeito – predicado – objeto, eu tenho, por exemplo, na segunda linha que tabaco causa câncer, a gente sabe que isso é verdade mas não é verdade em 100% dos casos. Então um caso representação que pode ser feita em RDF e outros casos mas que se tem que o cachorro pode ser transmissor de raiva mas nem sempre.

Um vocabulário muito conhecido da Ciência da Informação é o Mesh, que foi criado por bibliotecários e traz também exemplo dessa ideia de conhecimento contingente com só ocorrências, por exemplo, e se o conceito que está definido aqui sobre o bipolar ele tá definindo no Mesh como uma terapia de drogas, como complicação, então tem vários labels que eu posso classificar, demonstrando várias possibilidades para a ação de dados.

Por final as diretrizes que são árvores de decisão, para casos de urgência ou bem conhecidos, que um médico vai seguir determinados padrões, inclusive de aplicações éticas, se ele não segue esses padrões depois têm que se explicar porque não seguiu as diretrizes do hospital. Então a gente pode tirar várias tags que são utilizadas nos sistemas de construção de ontologias, baseados no conhecimento.

O eu passei para vocês uma grande quantidade de informações em um período relativamente pequeno, aquela teoria geral que a gente viu desde o início que tinham ali os quatro níveis, vieram lá do triângulo do Peirce originariamente, a gente está fazendo essa conexão, e representamos esses quatro tipos de níveis de dados, o linguístico, o nível pactual, o contingente e o ontológico.

Quando a gente junta tudo isso agora é possível ver que a gente tem de um lado, o lado esquerdo aqui os signos, conhecimento sustentável, quer dizer, uma vez que eu definir que cão é sinônimo de canis, aquilo ali está resolvido, e do lado direito a gente tem o conhecimento dinâmico que vai representar as coisas que acontecem no mundo na medida que vão conhecendo.

Então do lado do conhecimento sustentável está o conhecimento ontológico, são axiomas fixos, mas obviamente é falível, a ciência está sempre evoluindo então como um livro tem que ser atualizado em 10 anos a ontologia também. É mais para mostrar como a gente tem que pensar a ontologia como uma ferramenta que carece de ser sempre atualizada e a gente chama de curadoria.

Agora eu vou então ligar todos esses níveis e mostrar a minha ideia de como é que os sistemas de informação deveria funcionar de maneira geral, e concluir como as ontologias podem ajudar nesse sentido.

Aqui nós temos os usuários de um sistema de informação e aqui eu coloquei dados em repositórios que representam aqueles níveis de conhecimento que eu acabei de mostrar, como repositório de signos vai ser de ferramentas pactual, as ontologias que são modelos da realidade, repositório de regras, por exemplo as diretrizes que eu mostrei, e repositório de fatos consistentes com a realidade, como é o caso do pão né, então eu tenho todos esses níveis dispersos e misturados das entidades que vou preparar.

Os sistemas de informação vão utilizar todos esses níveis, vão usar o motor de regras de fato, as ontologias e os signos. Os signos vão representar as ontologias que propriamente mostram o que é a realidade e também vão ser utilizados no sistema de informação onde a gente ter a interface de acesso ao usuário. Já as ontologias vão conter o significado das regras para os repositórios de fatos, e você articulam as coisas que acontecem na prática. Dessa forma, com essa arquitetura, eu vejo a forma que as ontologias podem contribuir na realidade.

Primeiro eu queria dizer que a interoperabilidade semântica, com a conotação de semântica formal da Web Semântica, não se trata da semântica que a gente trabalha na linguagem natural, e as ontologias podem ajudar a mitigar esse problema da interoperabilidade em um nível realmente

base, você tem, por exemplo, determinado osso do corpo em um hospital, no outro você tem que ter o mesmo osso em outro hospital representado basicamente da mesma forma.

Se eu for trabalhar com inferências numéricas de determinadas características do paciente, talvez a ontologia não seja capaz de representar isso tudo. Nós temos bons modelos para se fazer isso baseados em ontologias que eu posso apresentar em uma outra oportunidade porque o nosso tempo aqui é curto.

Então basicamente o que eu queria mostrar é isso, tem aqui diversas referências que foram utilizados, posso mandar depois esses slides pro Guilherme, e agradecer vocês a atenção.

Vídeo da apresentação

Título: Integração de dados baseada em ontologias.

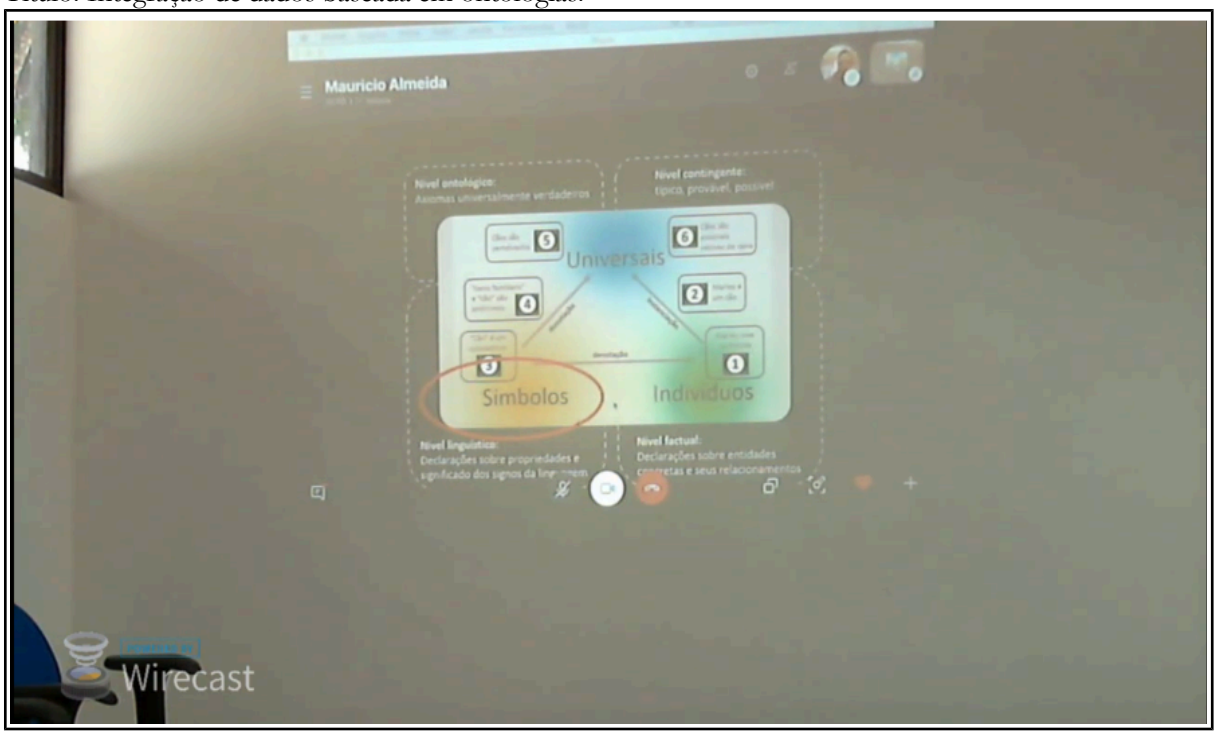

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=29

Curadoria digital e dados de pesquisa

Digital curation and research data

Luís Fernando Sayão[a]

Transcrição da apresentação

Quero dizer que é um grande prazer estar aqui na UFPB, é uma reunião muito importante porque ela analisa essa questão dos dados, ela enfoca os dados, e isso torna o evento muito importante.

A minha palestra ela tem um objetivo oculto, vou começar pela conclusão. Eu acho que a gente está tendo um grande problema no país hoje com a gestão dos dados. A gente percebe que as instituições de pesquisa e universidades começam a criar repositório de dados e esses repositórios são muito genéricos, sem especificidades, eles surgem diante de vontades políticas ou desejos de criar novos centros de informação e perdem um pouco o contato com a comunidade de pesquisadores.

Então a gente percebe em nossos estudos que é necessário que as plataformas de dados estejam muito próximas das comunidades de pesquisadores, senão a gente vai começar criar cemitério de dados, e podemos cometer o erro que cometemos com os repositórios institucionais, onde a gente percebe que não tem contato próximo com os usuários e acabam perdendo as funções. Então a gente tem a chance de não cometer esse erro novamente, de corrigir a trajetória, nós percebemos que a tendência mundial e que os repositórios nascem nas comunidades e sejam apoiados pelas bibliotecas de pesquisa e você ter um contato orgânico com os pesquisadores.

É um enfoque multidisciplinar e como colocou pretexto sobre isso, gostaria de falar um pouco sobre uma questão muito importante, é que uma parte da composição acadêmica desaparece, as nossas infraestruturas de dados não são capazes de tornar visível a produção de dados dos nossos pesquisadores.

Outra questão complicada é que nós temos que atender e tratar a curadoria dos dados uniforme, sem distinguir essas culturas, então essa palestra é tentar esclarecer um pouco esse ponto de vista de expor a necessidade de criar plataformas ligadas organicamente com as unidades de pesquisadores e que a gente enfoque o foco de gestão de dados como plataforma como múltiplos serviços e que tenha visibilidade.

Queria mostrar para vocês como é necessário a gente criar padrões específicos para isso, então esse aqui é o título da palestra e com o subtítulo aqui: a gestão do que a gente chama de cauda longa da pesquisa. Essa questão aqui é nosso alvo de estudo, e o que a gente percebe é que a gente tem uma riqueza fantástica que conta a história da geração de conhecimento, do fluxo de produção de sites, do que acontecem nesses laboratórios, novo experimento, processa os dados, planeja, faz e refaz, e toda essa trajetória de erros e acertos ela é perdida, porque só uma parte

a Centro de Informações Nucleares (CIN). E-mail: lsayao@cnen.gov.br. Currículo: http://lattes.cnpq.br/3422623122948389

pequena se torna publicados em livros, revistas, artigos científicos, e a gente chama de dados de autenticidade.

Você tem toda uma história aqui de descoberta, de coleta, de geração de dados que está oculta por trás do gráfico, e esse é um ponto importante. Você tem uma parte da ciência visível que é o que aparece nos periódicos, e uma parte invisível que a gente desconhece. Essa é a questão geral que temos aqui.

Esses dados, se eles aparecerem em plataformas de dados, se fossem tratados, poderiam gerar novos conhecimentos, novos horizontes, que é uma coisa que a gente já sabe. Eles servem para reúso de dados científicos, validar as pesquisas, ajudar com os outros pares, porque a ciência não é perfeita, ela tem um monte de deslizes, de imperfeições, fraudes, como é feita por humano ela também tem falhas. Então os dados servem para a autoafirmação da ciência, novas interpretações e basicamente nas pesquisas. Essa parte que ficou invisível se for tratada, se passar por processo de gestão, ela pode servir para essas coisas aqui.

Mas para que isso possa acontecer, para que esses processos de gestação, geração, coleta e processamento possam se tornar insumos nas nossas pesquisas é necessário que a gente crie infraestruturas tecnológicas, políticas, institucionais, para dar visibilidade a essas atividades. É um trabalho importante das bibliotecas científicas é apoiar essa visibilidade ao processo de geração de dados.

Uma coisa importante para gente é que nós temos essas infraestruturas, não só tecnológica mas variam, são políticas gerenciais e informacionais. E a gente vê que a sociedade demanda por isso, as agências de fomento querem que você faça planejamento de seus dados, faça gestão desses dados, faça planos de compartilhamento, ciência aberta, e-Science, e assim por diante.

Para o gestor científico, professor, os dados são fontes importantíssimas para a prática da ciência, na Medicina por exemplo as imagens são super importantes. Então eu preciso de infraestruturas que começam lá nas políticas internacionais e nacionais até chegar nas infraestruturas tecnológicas.

Na gestão dos dados existe isso, é uma infraestrutura que começa lá no político, quando se estabelece formas de recompensa, de fomento, de distribuição desses dados, até chegar às especificidades do documento, ferramenta, preservação, etc..

A gente tem essa ideia de que os repositórios vão ser a base de tudo, mas a gente precisa de política, financiamento, capacitação, pesquisa, legislação, parcerias, tecnologias e padrões. Uma coisa fundamental para essa gestão são os metadados, que são da área de informação. Nós temos uma parcela da parte da computação que em parte está resolvida, e uma enorme parcela de recurso de informação que devem ser colocados na gestão de dados de pesquisa.

Essa infraestrutura não está só no repositório, o repositório é um subconjunto de toda essa tecnologia que está em volta. Você precisa de recursos computacionais para modelagem, simulação, armazenamento, curadoria, colaboração, uma série de coisas que criam esse conceito de plataforma. Parece uma coisa banal mas é muito importante a gente pensar nessa situação mais ampla.

Por que gerenciar o dado? Preservar a integridade da pesquisa, permitir que os dados estejam disponíveis, e aí por diante, tem uma série de motivos para gerenciar os dados.

Aí surge uma questão fundamental, que é que nós temos a tendência de tratar os dados da mesma forma, parece que os dados são todos iguais, mas eles são heterogêneos, essa é a grande dificuldade dessa gestão. Aqui existe uma questão muito importante, a gente chama de Big Science, que são os grandes projetos com grandes instrumentos, altos custos, muitos colaboradores, por exemplo, a área de genoma, astronomia, física de partículas, o grande colisor lá na Europa que é o maior artefato humano de pesquisa, que gera 15 milhões de terabytes por ano, na parte da tarde vou falar mais sobre essa questão do Big Science.

E tem também a Small Science, que é a ciência feita no laboratório das universidades por exemplo, com pequenos instrumentos, baixo custo, quem financia isso é bolsa, pequena duração no máximo 3 anos, equipe pequena às vezes o pesquisador somente, e pesquisa local com abrangência ampla. Essas pesquisas a gente chama de posse, e trabalha para comprovar situação de posse. Na Big Science você tem algo relacionado com dados, a gente vai ver isso a tarde com mais discrição, na mesa.

Essa grande ciência não é uma coisa nova, esse cara aqui era um físico, historiador, da ciência da informação, que em 1976 já falava sobre o aspecto da grande escala da ciência moderna, nova, brilhante e curiosa, é tão evidente que foi criada para cunhar o termo grande ciência. A grande ciência é tão recente que muitos de nós não abordamos a suas origens, então a grande ciência é tão vasta que começamos a nos preocupar com o tamanho do monstro que criamos, que talvez nos gere nostalgia da pequena ciência do passado.

Mas não foi ele que cunhou esse termo grande ciência, foi esse cara aqui [leitura da citação presente no slide].

Vejam só, nessa época já se tinha essa visão de que o fomento, os recursos, eram emblemáticos para a ciência, os dois meses que eu estive em São Paulo, fui lá na FAPESP fazer uma palestra, e eu percebi que os caras já falam sobre uma Big Science, eles já se preocupam com os dados que estão nos laboratórios, e esses dados são os mais importantes que a ciência tem.

As características dessas duas áreas são super importantes para a gente pensar nos processos de gestão, por exemplo, na Big Science a gente tem uma uniformidade dos dados, são muito iguais, são gerados pelos mesmos instrumentos, então lá no CERN na Europa os dados têm o mesmo formato, são iguaizinhos, então é mais fácil gerenciar esses dados porque são parecidos. Os procedimentos de geração de dados são padronizados, mas na cauda longa desses laboratórios não, você tem gente coletando dados manualmente e são específicos, cada laboratório, cada centro de pesquisa tem uma especificidade. A gestão e a curadoria estão presentes, assim como no projeto genoma gera dados eles são curados.

No mundo da Small Science é curadoria manual, os repositórios institucionais são disciplinares, voltados para uma formação orgânica da comunidade, e na cauda longa desses laboratórios a gente tem os laboratórios multidisciplinares, porque os repositórios institucionais são muito problemáticos para fazer a gestão desses dados.

A preservação na grande ciência tem sistemas de storage, aqui a gente tem pendrive na gaveta. A grande ciência não usa esse conceito de repositório, mas são grandes bancos de dados específicos modelados especificamente para trabalhar esses dados.

A gente tem na pequena ciência basicamente planilhas, os administradores usam planilhas, etc. Vejam a grande diferença fantástica, na grande ciência eles já tem tudo, é o paraíso dos dados, o acesso é aberto na Big Science, então o cara da grande produção gera 600 milhões de fenômenos por segundo, e esses dados não podem ser analisados em um só sistema, eles são distribuídos para o mundo todo, não é uma dádiva, não é humanista, mas é uma necessidade, um imperativo desse tipo de ciência.

O reúso é imediato, o cara que tá lá em Singapura ou São Paulo recebe os dados imediatamente. Na Small o acesso é escuro, protegido, o cara bota o pendrive no bolso ou no seu computador e some, ele se torna invisível. O reúso é imediato para analisar na Big Science e na Small Science não.

E o financiamento na Big Science é fluxo contínuo, apoio internacional, etc. Na pequena ciência é por projeto. Há o reconhecimento da recompensa, o pesquisador dos grandes projetos são recompensados por gerir os dados. Aqui não, o CNPq não liga se você não fazer a gestão de seus dados.

Esses caras da Big Science tem expertise, pesquisadores, cientistas de dados, bibliotecas de dados, arquivistas, instrumentos fantásticos, satélites, colisores, sensores, recursos computacionais, software, rede, é o céu dos dados. Os meus laboratórios são o inferno, ou o purgatório dos dados.

Será que essa ciência produzida nesses laboratórios é uma ciência de segunda linha por ser menor? Não, pelo contrário. Aqui você chama de cauda longo porque a maioria dos dados é produzida pelos pequenos laboratórios, o Big Data científico não está na cabeça e sim na cauda longa.

Dados da grande ciência são fácil de vincular e arquivar, a pequena ciência é mais heterogênea e vasta, e gera duas ou três vezes mais dados. Então o Big Data científico são os dados que estão no nosso laboratório, olhem aqui, nos datasets, pequenos laboratórios, e aqui grandes projetos. Aqui são poucos projetos que geram muitos dados e ali são múltiplos projetos que geram poucos dados, são coisas pequenas, planilhas, interessante isso daqui.

Esse é o nosso problema, porque uma parte considerável disso daqui não está publicada, desaparece, some, não serve para nada.

Os dados da cauda longa são super heterogêneos, eles variam em parâmetros, tamanho, tem coleções imensas, são variados, então cada laboratório tem um formato, as vezes proprietário, mesmo os laboratórios que fazem pesquisa e geram em formatos criam uma diversidade muito grande, as estruturas são diferentes, as vezes você tem dados primários, algumas em planilhas outras em banco de dados. O nível de complexidade de dados, alguns dados simples que são imagens outros são compostos por vários arquivos e com especificidades como banco de dados por exemplo, e variam em termos disciplinares.

Se a gente olhar aqui, a cauda longa se estende por todos ramos disciplinares, domínios tecnológicos e as comunidades também, ciências humanas, ciências sociais, então a gente tem uma vasta heterogeneidade nesses termos aqui, tamanho, formato, estrutura, complexidade, tecnologia, etc.

Vocês estão vendo que a gente tem uma complexidade muito grande para fazer sistemas que possam lidar e gerenciar dados na cauda longa, que são dados produzidos pelos laboratórios no cotidiano das universidades. Esse é um problema terrível mas não é local, é do mundo todo, se procurar na Internet vai perceber que tem muita gente trabalhando com a complexidade dos dados gerados na cauda longa das pesquisas.

A gente tem que grande partes destes dados aqui da cauda longa não são publicados, grande parte não vão nem para os periódicos. Então aqui tem a revisão da literatura, isso aqui é o que é publicado e isso aqui o que não é, que é um pequeno número de projetos científicos que geram muitos dados.

Ela é pequena mas essa não é uma ciência menos importante, uma coisa interessante é que não é aqui que surge as grandes descobertas, é na cauda da ciência, aqui na grande ciência os dados já são previsíveis, não tem surpresa, não tem inovação.

Então essa área aqui se torna super importante na ciência, é aqui que surgem os modelos, as patentes, os artigos científicos, a inovação, o conhecimento multidisciplinar, e a autonomia. Tem uma frase que diz: parece que é provável que a ciência inovadora venha mais da cauda longa que da cabeça, por isso a gente tem que gerenciar esses dados.

Tem autor que diz o seguinte, a Big Science legal é a que gera muitos projetos na pequena ciência, e é verdade. Se você tem duas áreas super importantes, essas áreas são silos de dados, você precisa de dados gerados na cauda longa e dados gerados no Big Science para criar a ecologia de dados.

A nova ciência ela precisa da Big Science mas as grandes ciências são da pequena ciência. Na astronomia é bem interessante porque você tem grandes projetos e observatórios espaciais e você tem os laboratórios terrestres que fazem parte da pequena ciência, e a relação entre os dois e homogênea, produtiva, eles conseguem gerar conhecimento entrelaçando os dados da cauda longa com a cabeça, então essa ecologia dos dados é produtiva.

Esse texto aqui, a perspectiva sistema espaço – dado torna-se chave para as respostas na nova ciência, isso acontece ao vincular a estabilidade da grande ciência ao território de autonomia da cauda longa, cuja conduta desses criadores leva a inovação e geração de conhecimento multidisciplinar.

A gente precisa das duas ciências, essa é a questão. E que as coisas importantes inclusive a geração de empregos necessitam que a ciência seja feita nas nossas universidades, e a gente esquece que a riqueza desses projetos são eles que geram os artigos em periódicos, não é a grande ciência que gera artigos em periódicos.

Então a gente tem essa pirâmide aqui que eu que fiz uma adaptação, então aqui você tem os recursos relevantes, banco de dados maiores, grande colisor, definição de formatos, e assim por diante, esses caras aqui são super organizados. Depois a gente tem os repositórios disciplinares, eles são super entrosados, tem princípios da comunidade, da disciplina, só de modelos biológicos, então eles nascem da comunidade e crescem em sistemas específicos. Então na análise de genoma você tem vários bancos de dados que se juntam.

Depois é como se estivesse caindo no inferno aqui, o inferno são os repositórios multidisciplinares e institucionais, que não é capaz de oferecer serviços de curadoria, e o acesso é

muito restrito, e tem uma coisa muito importante, a gente fala muito da indexação mas pouca gente fala sobre a manipulação dos dados, alguém já ouviu falar sobre recuperação de dados. Essa questão nos repositórios multidisciplinares você não consegue recuperar os dados que você quer, você recuperar grandes coleções ou segmento específico, então não tem metadados para poder lidar com isso tudo, não tem serviço aos pesquisadores por isso que eu acho que os repositórios de dados multidisciplinares e incluem os institucionais podem virar cemitério de dados.

Aqui por último estão as coleções individuais, aqui é o purgatório e aqui é o inferno, e aqui é o céu, a gente precisa criar o céu para os dados da cauda longa. O sucesso na prestação de serviços para gestão de dados de pesquisa está relacionado a sua capacidade de dar apoio as classes e culturas da comunidade científica da instituição, por isso não adianta criar grandes repositórios de dados porque senão eles podem virar cemitério de dados.

Será que a gente está construindo cemitério de dados em repositórios? Que você vai guardar bases de dados mal apresentados, não vão ser recuperados, não vão ser preservados, não vai ter curadoria? Essa é a questão, então a solução pode ser que a gente tenha que construir repositórios talhados a cada área, disciplina, comunidades, e depois crie a interoperabilidade. Mas também a gente não pode criar silos, cofres, a gente tem que fazer com que esses repositórios se falam via Web Semântica, Ontologias, e a gente quer também o reúso.

Outra coisa importante nesse mundo que a gente está trabalhando é saber por que a gente está em um novo partido. A maioria dos pesquisadores concordam com os principais meios de compartilhamento e reúso, mas relutam a participação dos próprios dados.

Por que isso? Em termos gerais o cara tem culturais, tem disciplina que compartilhar faz parte, como exemplo a Astronomia, Física, mas tem outras que o dado é um segredo, Química por exemplo é super fechado, a área nuclear em que eu trabalho. Então isso também faz parte da cultura disciplinar, para a Astronomia é fundamental.

Interesses econômicos, comerciais, por exemplo.

Resultados negativos o cara acha que se não for confirmado ou se der errado ele não vai publicar os dados mas ele tem que publicar. Hoje a gente tem periódicos de dados negativos, é tão importante quando você ter um novo tipo de periódico que se dedica isso.

Custos, é muito custoso em termos de tempo e dinheiro você tratar os dados, é muita coisa, criar e limpar os dados, processar, publicar, é muito complicado, então ele prefere publicar em periódico.

Vantagem produtiva, o cara tem que publicar o máximo que ele pode, publicar em periódico o máximo que ele puder, depois abona os dados, coloca no pendrive e não compartilha. Medo muito grande dos dados serem erroneamente interpretados, e a dificuldade na área de Medicina por exemplo, o cara tem muito medo disso.

E a gente foi mais adiante nisso e trabalhou numa pesquisa de motivos mais específica, e 50% não são publicados, e a gente viu motivos individuais como atitude dos caras, disciplinares, organizacionais e políticas.

Uma coisa importante é poder ver as agências de fomento e as revistas que exige para que você publique seus dados.

E a gente essas políticas que começam lá em cima, requisitos internacionais, vai descendo até o nível disciplinar, essas coisas vão se ajustando às comunidades específicas.

Aqui eu tenho os motivos pessoais que vão de oportunismo a medo de lançar os dados que revela o que foi feito, e assim por diante. Tem uma série de motivos que o pesquisador da cauda longa não publique seus dados, por isso nós temos que criar infraestrutura para coordenar isso.

A gente não tem que focar em repositório, repositório é um subsistema de um sistema mais amplo que faz serviços mas que precisa também se preocupar com a visibilidade do pesquisador, a citação, o conhecimento, criar a memória dinâmica da instituição, criar serviços inovadores, a gente percebe que os repositórios têm serviços muito talhados nos dados, serviços bacanas, então grande problema que a gente tem hoje é que não tem serviços, tem uma submissão e um acesso que é muito precário.

Tanto é que agora o esforço para se criar maior infraestrutura de repositório que tenha mais serviços, mas isso só é possível se estiverem próximos das comunidades e disciplinas.

O pesquisador precisa de capacitação, então a ideia da plataforma é mais ampla que a ideia do repositório, simplesmente um mecanismo incluído aqui.

Uma coisa importante nessa complexidade da gestão dos dados é que os dados não é útil quando coletados, não é como uma tese ou um livro, os dados vão se transformando, dados científicos, dados brutos, processamento, análise, e esse fluxo tem duas coisas, ele é complexo e precisa ser registrado para saber a proveniência, o histórico dos dados com metadados específicos.

E esse fluxo não é um fluxo padronizado, cada disciplina, cada laboratório, tem um tipo de fluxo, você tem que trabalhar o fluxo de cada área no laboratório, de cada linha de pesquisa, a gente tem essa complicação.

É necessário compartilhar muito mais que os dados finais, eu preciso compartilhar trajetórias de erros e acertos. A gente tentou botar aqui um fluxo padrão incluindo questões de publicação em data papers, análise, mas é uma fixação nossa, para entender como funciona, e aqui uma intervenção, é legal esse exercício para fazer o embaralhamento de um fluxo genérico.

Dados são objetos complexos que precisam ser preservados, e essa complexidade é crescente, tem várias camadas que você tem que preservar. E tem os dados confiáveis, que está se trabalhando muito agora. E uma coisa fundamental aqui é que a gente precisa dos metadados, os dados não falam por si próprio, se você tem um livro, uma tese, ou um artigo está escrito o que ele é, mas os dados às vezes é só um monte de número, monte de letras, precisam ser documentados, informação de representações, significados, semântica, estrutura.

E esse aqui é um cara aqui é Grey, cara da Informática que criou os esforços da e-Science, e era da Computação mas achava que a Biblioteconomia iria resolver essas questões todas, é muito interessante. Ele fala o seguinte, dados de pesquisa são incompreensíveis e portanto inúteis a menos que haja uma descrição detalhada de como e quando eles foram obtidos. Então eu tenho que detalhar com metadados todas essas coisas aqui.

A gente tem um negócio que chama metadados similares, porque cada área é específica, e esses metadados documentam o processo todo, resolução, limpeza, tudo mais.

Os dados são versionados, e tudo isso para o reúso, mas o reúso também é uma coisa complexa. As atividades que são locais tem que se tornar globais e explícitas, então você pegar o conhecimento do seu laboratório e tomar como base, é a complexidade.

Tem um monte de coisa que você tem que fazer além da propriedade tecnológica, tem um grau muito grande a ser levado em conta. A gente tem que ter os dados FAIR mas a gente acha melhor os dados "manerios", em São Paulo é "daora", existem outros conceitos de FAIR.

A gente tem que contornar isso incentivando capacitação e financiamento, hoje a gente tem um monte de outras formas de publicação, dados negativos publicados em repositórios específico, publicação ampliada, e nos laboratórios que colocam da Internet.

A gente tem que sair daquela plataforma genérica que é stop down, que é da reitoria, e sem preservação, sem serviço, ir para plataforma disciplinar, serviços disciplinares, cursos, a gente tem que tentar, obrigado.

Vídeo da apresentação

Título: Curadoria digital e dados de pesquisa.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=30

Slides da apresentação

Título: Curadoria digital e dados de pesquisa.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=30

Infraestrutura brasileira para dados de pesquisa: reflexões

Brazilian infrastructure for research data: reflections

Pedro Luiz Pizzigatti Corrêa[a]

Transcrição da apresentação

Inicialmente eu gostaria de agradecer ao organizador do evento, professora Bernardina e professor Guilherme pelo convite, é um prazer enorme estar aqui com vocês e compartilhar um pouquinho do que a gente aprendeu e aprender também com vocês.

Eu sou mais da área de computação e da engenharia, o que envolve muito aplicação, mas a gente tem aprendido muito nesses últimos anos com a comunidade da Ciência da Informação. Então gostaria de agradecer essa oportunidade porque para mim já é uma consolidação desse aprendizado e dessa evolução que tivemos do ponto de vista do conhecimento.

Sou da escola Politécnica da USP, do departamento de Engenharia da Computação, que trabalha temas de desenvolvimento de aplicação da computação nas engenharias, a gente vem trabalhando com a comunidade científica no sentido de dar apoio, armazenamento, acesso, nos últimos 10 anos. Desenvolvimento de ferramentas e técnicas para aprendizagem, e com o tempo a gente foi entendendo que o problema era maior, não era simplesmente disponibilizar repositórios, ferramentas de análise, a gente viu que o problema era maior e que existe uma demanda enorme por recursos que permitam agregar esses dados, disponibilizar essas ferramentas para a comunidade. Existe um problema sério nessa área e que essa interação com a Ciência da Informação é a chave para resolver esses problemas.

O nosso grupo de pesquisa Big Data tem uma atuação nos últimos quatro anos trabalhando com projetos na área de e-Science, em conjunto com o Ministério do Meio Ambiente, ANEL e recentemente a gente disponibilizou um centro de dados com parceria do Itaú.

A ideia desse centro é disponibilizar bolsas de mestrado e doutorado para incentivar o ecossistema de Ciência de Dados em especial para pesquisa. Do ponto de vista de Pós-Graduação, a gente tem atuado no programa de Pós-Graduação em Engenharia da Computação, Engenharia Elétrica da Escola Politécnica da USP. Dentro desse programa a gente criou uma linha de ciência dos dados com o objetivo de tratar a questão de gestão de dados e análise dos dados. Também temos trabalhado com o pessoal da Universidade do Tennessee que também tinha acabado de criar um programa de Pós-Graduação com Mestrado e Doutorado em Ciência dos Dados, então a gente tem procurado estabelecer cooperação com as instituições no sentido de que a gente precisa aprender com os outros, é uma área que precisa de colaboração, então a ideia é que a gente possa estar estabelecendo colaborações para auxiliar na formação de recursos humanos.

Essa é a ideia de fazer essa colaboração com a Universidade do Tennessee e com um Laboratório de Energia do Governo Americano, é um laboratório que participou do Projeto

a Universidade de São Paulo (USP). E-mail: pedro.correa@usp.br. ORCID: https://orcid.org/0000-0002-8743-4244. Currículo: http://lattes.cnpq.br/3640608958277159

Manhattan na década de 40, eles desenvolveram toda a parte das pesquisas na área de energia nuclear e atualmente conta com 5.000 pesquisadores, e uma parte desse laboratório cuida da questão de pesquisas climáticas para entender o papel do clima para a energia.

Temos alguns cursos de extensão em Big Data voltado para o mercado, cursos de curta duração e cursos gratuitos voltado para a comunidade. A gente tem montado alguns cursos na área de gestão de dados e análise de dados.

Vou falar bastante da experiência que a gente teve com o RGs, Universidade do Tennessee e que já vem desenvolvendo a algum tempo, pelo menos nos últimos 20 anos, pesquisas na área de análise e gestão de dados científicos.

Temos feito Workshops com eles, a gente realizou três Workshops internacionais, na USP, na escola Politécnica, o último foi em 2017 com a professora Suzie Allard, que é da Ciência da Informação.

Na minha apresentação eu vou fazer uma rápida introdução sobre como a gente vê esse conceito de Ciência dos Dados, eu vou falar sobre gestão dos dados científicos, eu vou repetir um pouquinho pro Sayão algumas coisas que ele já colocou, inclusive é bom porque a gente aprende quando a gente repete. E eu vou falar um pouquinho na prática como esses conceitos estão presentes nesses dois grandes projetos, que são a cabeça como o DataONE.

Depois então a gente vai falar sobre dados, dados são fatos brutos, as informações são aqueles dados que são significados, e o conhecimento são as informações relacionadas e estruturadas.

Como a gente está falando sobre dados, ele acaba perdendo essas três áreas, dados normalmente são as observações, esses dados tratados e úteis também são passíveis de gerenciamento, e o conhecimento gerado também é passível de gestão.

A nossa definição de dados do ponto de vista científico é o resultado de uma pesquisa que não está publicado no texto dos artigos, teses, monografias ou dissertações. A gestão é uma iniciativa global que reconhece a importância dos dados como produtos que podem ser gerenciados.

Do ponto de vista de dados de pesquisa, a questão dos dados de pesquisa envolve coleções de registros que são utilizados pelos pesquisadores para realizar um registro de uma determinada evidência de sua pesquisa. De maneira geral tem alguns atributos, são digitais, seguem algum formato, do ponto de vista de conteúdo tem um contexto que é válido, tem um domínio de aplicação, e tem um valor.

Do ponto de vista de ciência, a gente tem uma variedade de dados de vários domínios de aplicação, desde a área e energia por exemplo, que temos dados que são observações e modelos também, na área biológica e ambiental, temos dados numéricos e tabulares, dados gerados através de sistemas de georreferenciamento de imagens, dados de gravações, então a gente tem uma variedade grande em cada um dos domínios de aplicações.

Quando a gente discute a questão da análise e gerenciamento dos dados, por que a gente chegou nisso? Na palestra anterior o Sayão comentou sobre um pesquisador na área da computação e banco de dados que publicou um livro chamado o quarto paradigma. O que seria o quarto paradigma da ciência?

Primeiro é preciso conhecer os paradigmas anteriores. Começou com a ciência empírica voltada para descrever fenômenos naturais, céus, estrelas, etc. A partir do século XV a ciência passou a ter uma abordagem teórica, representava fenômenos através de modelos. Nas últimas décadas, a partir de 40 e 50, a ciência foi auxiliada pela Computação, que passou criar modelos de simulação para descrever fenômenos, e isso foi um avanço do ponto de vista de novos conhecimentos. O quarto paradigma coloca o uso intensivo de dados e a simulação para gerar novos conhecimentos na ciência de maneira geral.

Ciência dos dados veio dessa ciência, hoje tem uso intensivo dos dados na ciência, que nasceu a partir dessa visão de que o conhecimento vão ser gerados a partir de simulações e experimentação baseado em dados.

Existe junto com essa visão a ideia de que a ciência seja convergente, a ciência é multidisciplinar, as novas ideias vem de campos diferentes a ideia é que você gere inovação e descoberta utilizando a colaboração multidisciplinar de várias áreas da ciência. É essa a abordagem que a ciência dos dados traz pra gente descobrir e gerar novos conhecimentos.

Em termos de ciência dos dados, tem algumas definições para entender como situa esse conceito. A ciência dos dados pode ter algumas definições, por exemplo, a ciência que estuda os dados científicos, dados de negócio, que une áreas do conhecimento como Estatística, Ciência da Informação e Tecnologia da Informação para resolver problemas por meio de extração de conhecimento a partir dos dados. Essa é uma definição que a gente entende objetos mas não entende processos.

Uma outra definição que nos dá a ideia dos processos é que envolve o processo de manipulação, tratamento, processamento, análise que visa a descoberta de novos conhecimentos.

Nessa visão de processo a gente pode entender a ciência dos dados como a possibilidade de estabelecer questionamentos gerais, adquire dados em diferentes fontes, esses dados de certa forma não estão organizados nem estruturados, a gente passa para uma etapa de organização e tratamento dos dados. Esses dados então estão prontos para alimentar um modelo, esse modelo gera um entendimento, esses dados entendidos podem ser visualizados, e com a visualização desses dados é possível analisar resultados e refinar o problema as hipóteses.

Esse é um ciclo de experimentação, que de maneira geral todo cientista passa, agora a gente tem que imaginar que em cada uma dessas etapas a gente está manipulando dados. Coletamos dados, colocamos nos programas, e a ideia é que a gente possa estar fazendo a gestão desse processo. Quando falamos de dados científicos estamos pensando em todas essas etapas aqui.

Do ponto de vista do gerenciamento, de como a gente trata esses dados, temos várias questões que podem ser feitas em cada uma das etapas, desde o planejamento, o que é um PGD, como eu garanto a qualidade, quais serão os metadados para descrever, como eu armazeno, como eu coloco os dados armazenados em outra plataforma, e, por fim, todos os mecanismos e estratégias de análise. Em tudo isso estaremos gerando dados e a ideia é que possamos fazer o gerenciamento de todas essas coisas.

Eu gosto de colocar esses slides aqui porque motiva, por que a gente aplica as técnicas de gestão de dados? por que hoje a gente está fazendo ciência dos dados? Tem a questão de proteção dos dados. Aqui tem um exemplo do Governo Americano que passou os dados de

segurança para o Governo Britânico, a gente teve aquele caso recente no governo da Dilma do pré-sal, que foram coletados e disponibilizados de acordo com o interesse econômico das empresas que iam para o leilão do pré-sal.

Existem questões de segurança e isso é gestão dos dados. A questão de reproduzir as análises é uma necessidade de manter os dados. Outra questão é a substituição se tiver problemas técnicos, a gente teve aqui recentemente o museu nacional do Rio, a gente perdeu várias coleções que provavelmente não vai recuperar, o próprio Butantã da USP perdeu os dados em 5 ou 6 anos atrás uma coleção enorme. Esse é o problema, não ter digitalizado e não fazer gestão desses dados.

Do ponto de vista não institucional, o pesquisador guarda em pendrive ou discos externos vários projetos como projetos de grande porte por exemplo LDA que está fazendo coleta de dados atmosférico da região amazônica, boa parte está na Alemanha, nos EUA, outra parte no pendrive dos pesquisadores, então não estão integrados, e vocês sabem dados climáticos sobre a região da amazônia são fundamentais para que a gente possa criar modelos e prever o futuro.

A questão da gestão dos dados acaba sendo uma disciplina fundamental, ele coloca questões de como eu defino, planejo, executo estratégias, procedimentos e práticas para gerenciar de forma efetiva recursos de dados e de informações dentro das organizações.

Uma questão que já comentaram aqui é a importância de que muitos dados acabam sendo perdidos, são dados em mídias que ficam defasadas, tem a questão de dados que são de pesquisadores, a gente teve contato com pesquisadores que disseram estar aqui toda a minha vida, trabalhei por 30 anos nessa organização guardado em uma caixa com todos os pendrives dos dados coletados, porque senão as pessoas se desligam das instituições e você vai perder esse conhecimento.

Conforme o Sayão comentou, a gente teria esse problema de que muita parte desses dados um dia vão ser órfãos ou serão perdidos, boa parte dos dados que são da ciência, da Big Science, são coletados aqui, por exemplo, os dados de energia nuclear boa parte estão aqui, são dados que você consegue capturar dos sensores e são simples de fazer gerenciamento.

Agora um outro desafio é o volume de dados, quais desses dados são úteis? Quais armazenar? A gente tem coletas que são locais, outras mais extensivas que envolve imagens de satélites, então isso tudo gera um volume de dados grandes. Quais são os dados significativos e que podem ser importantes para se manter a longo prazo?

Para a gente entender a importância de não perder esses dados, temos que imaginar que o conhecimento dos dados a partir do momento que vai passando o tempo a gente vai perdendo de maneira natural. A ideia de fazer gestão é que a gente impeça que haja perda de informação com o passar do tempo.

Aqui um exemplo, em 1889 teve um projeto que fez gestão e coleta de dados, que foi sistematizado e organizado. Hoje esse mesmo processo desde 1889 até hoje encontra-se no sistema deles. Agora a questão é o seguinte, a ciência de maneira geral foca na interpretação e nas conclusões que são sintetizadas, mas esses dados todos e esse legado estão em caixas desse tipo, essa é a ciência normal que é a que vem acontecendo nos últimos tempos.

Tenho alguns dados interessantes, por exemplo, a probabilidade de você encontrar a origem de dados ela decai 17% a cada ano em uma determinada publicação. Então uma publicação que disponibilizou os dados depois de um ano o site parou de funcionar ou o pesquisador não atualizou. Todo ano você vai perdendo 17% dos dados e a gente precisa mudar essa situação.

Quais são os princípios que direcionam as ações do ponto de vista da gestão de dados. Primeiro, os dados são ativos, incrivelmente valiosos, os dados coletados têm valor porque não tem como você fazer a leitura novamente desse mesmo dado.

A ideia é que a gente possa administrar e proteger os dados coletando de modo que eles estejam acessíveis e compreensíveis, reproduzíveis e utilizáveis. Esses são os princípios que regem a gestão dos dados.

O nosso objetivo é mudar o futuro dos cientistas, para que não seja só sintetizar, gerar conclusões e compartilhar as conclusões, mas você também compartilha os dados que são gerados no processo.

Um ponto importante para a gestão dos dados é a definição de uma política que estabelece todo o modelo e estratégia que as instituições podem utilizar, por exemplo, essas políticas podem ser explícitas, você escrever em um documento, ou implícitas para a comunidade que compartilha os dados, mas é importante ter essa política.

Se a gente pensar em uma instituição de pesquisa, qual é a estratégia dela fazer curadoria dos seus dados? Normalmente essa política estabelece os fundamentos para a gestão dos dados, define ferramentas, softwares, padrões para descrever dados, estabelece o processo para revisão, aprovação e publicação dos dados, e define quais os requisitos para preservar os dados com o tempo.

Por isso eu comentei com você sobre aquelas parcerias, para a gente entender um pouco como eles estão com 100 anos de dados científicos, a gente tem que ter essa experiência trabalhando com quem tem para entender quais são os problemas para que a gente possa avançar nesses problemas. A gente não pode querer refazer a roda, por isso é importante utilizar um pouco da experiência dessas outras instituições que já passaram por esse problema e já avançar mais que a gente.

Um atrativo pro partido de uma política, você faz o plano de acesso, de como será implementada essa política, a RGs definiu um plano de como ela implementou essas políticas, de quais são as estratégias que ela utilizou.

Imagina assim a RGs é uma instituição de pesquisa como outras, a maioria dos cientistas estão preocupadas com essas questões, não estão preocupados com metadados, estão preocupados em como fazer publicações, deadlines, concursos, laboratórios, equipes, congelamento de contratações, resistência de colaborações e prestações de conta, esse é o dia a dia do cientista.

Agora você chega para o cientista e fala que tem que fazer metadados e gestão dos dados, ele fala que isso não interessa e tem resistência, como a gente resolve isso? Claro que tem todo o trabalho de conscientização mas precisamos de ferramentas para ser fácil de usar senão eles não vão fazer.

No caso do RGs, dentro da política de dados existiam um ciclo de vida dos dados com enfoque desde o planejamento até a publicação, e com ferramentas que difundiam melhores práticas, estabelecem comunidades de usuários e ferramentas para apoiar cada uma das etapas, por exemplo, editor de metadados, ferramentas para citação, ferramentas para armazenamento, ferramenta para catálogo de dados, foram criadas para viabilizar a questão da gestão dos dados simples. Tem alguns detalhes interessantes, essas ferramentas são compartilhadas, então o vocabulário de dados aqui é utilizado para indexar os dados dali, é importante a integração dessas coisas por isso precisam ser baseadas em padrões para que você não precise reproduzir dados de uma etapa em outra etapa.

Uma outra questão para que a gente possa fazer proveniência e todo o processo em ciência dos dados, a gente precisa pensar na questão do software, ter informação sobre o software, porque se eu quero reproduzir os dados preciso saber como ele parametrizou aquele software, esse é um desafio do ponto de vista de pensar na questão de tornar os experimentos reprodutíveis.

Um software pode ser disponibilizada de uma maneira informação, você pode deixar o link ou de maneira forma, você coloca em ferramentas que você documenta todos objetos de software para representar e tornar bem documentado aquela ferramenta que foi utilizada. Também tem a questão de licenças, que pode ter domínio público e você pode deixar disponível de alguma maneira, inclusive disponibilizar informações de uso. Tem algumas sugestões do ponto de vista de obtenção de DOI para software para ser referenciado também, mas isso está sendo estruturado, as instituições estão se organizando.

Vou falar também sobre alguns projetos na prática como essas coisas acontecem. Aqui eu to falando mais sobre a cabeça e não da cauda dos dados, sobre quais são as estratégias que algumas dessas instituições e projetos têm adotado. Esse programa aqui foi onde fiz meu pós doc, é um programa que coleta dados atmosférico do mundo todo, para que você possa prever alguma mudança você capta dados do mundo todo para que criar modelos de como vai ser a evolução e fazer predição no futuro. Existem coletas permanentes nos EUA, e campanhas que são realizadas no mundo todo, no Brasil teve uma campanha em 2014-2015 na região amazônica para coletar dados dessa região e agora terão novas campanhas que serão feitas na Argentina e na região do Ártico, envolve sensores que são levados para esses lugares, têm aeronaves coletando na atmosfera, e satélites fazendo mapeamento da região. Então você acaba tendo uma boa coleta de dados atmosféricos de determinada região.

Esse projeto o foco é para a questão energia e fazer gestão dos recursos que são importantes para a humanidade. Ele definiu um ciclo de vida de dados, estratégias de qualidade, estratégias de monitoramento, e medidas para saber como está sendo sua evolução, quantos dados você disponibiliza? Quantas referências são feitas sobre seus dados? A gestão de dados passa por toda essas questões aqui, ciclo de vida, qualidade, métricas e monitoramento.

Esse projeto coleta atualmente 1.4 petabytes pode ano, a base de dados dele gira em torno de 9 petabytes, e isso é a tendência de ir crescente. Se a gente pensar onde tem essa experiência aqui no Brasil a gente tem pouca experiência para fazer gestão desse volume de dados aqui no Brasil, por isso a gente precisa ter essas parcerias para formar gente que entenda e saiba fazer a gestão

desses dados aqui, por isso a gente precisa de colaborações, essa é a ideia que eu comentei com vocês.

Como funciona esse ambiente? Ele guarda dados e tem que analisar, por exemplo, você não vai fazer download de 9 petabytes no notebook, então funciona assim. Você como a comunidade de usuário requisita parte dos dados, parte desses dados vão para um cluster conectados a essa estrutura, nesse cluster você roda suas análises, ou se precisar trabalhar com dataset menor você pode fazer download. Então veja, estas conectando dados de satélite, você está conectando dados do site, dados enviados por projetos que não necessariamente fazem parte dessas campanhas mas que tem interesse em disponibilizar dados aqui nessa estrutura, e a partir daí é disponibilizado tanto para análises locais em clusters quando fazer download para analisar seus dados.

Essa aqui é para vocês terem ideia como que é a interface de acesso a esses dados. Então aqui você tem uma unidade de um sensor, aqui informações de qualidade dos dados, você passa o mouse aqui e ele mostra se houve falha do sensor em coletar esses dados por exemplo, você seleciona quais dados você quer, colocar os dados em uma cestinha e depois faz escolhe o formato e faz download desses dados.

Em termos de plataforma e infraestrutura de software envolvida. Você tem infraestrutura de software desde o sistema operacional, por exemplo Linux, copiadores padrões, não tem nenhuma ferramenta proprietária, todas são de acesso livre, algumas ferramentas de desenvolvimento como Python, Matlab para controle de qualidade dos dados, ferramentas para distribuir dados no cluster como Cassandra e SPARQL, e ferramentas para você fazer a mescla, porque você não recebe diretamente esses dados, são ferramentas de comunicação via mensageria, que usam para poder executar a extração de dados.

Um outro projeto que eu queria comentar com vocês que passa por todas essas questões de gestão de dados e envolve uma comunidade científica maior, é o projeto DataONE. Uma coisa que é interessante é que a gente pode interagir em função das pessoas, eu passei um tempo nos EUA durante meu pós doc trabalhei com Mike Frame a RGs, boa parte da documentação que eu passei para vocês é da RGs. Aqui está a Suzie Allard uma das PIs desse projeto, as pessoas estão atuando o tempo todo em diversos projetos, essa é uma das chaves do trabalho aqui diferente do Brasil.

Aqui também está o Mike Frame que colabora com esse projeto que tenta agregar dados da natureza de maneira geral. O DataONE agrega dados de uma maneira geral e extensiva de diversas fontes, esses são pontos de observação de coleta de dados em diferentes posições geográficas, dados de observação de satélite, esse é o nível de dados que o DataONE agrega.

Ele trabalha hoje financiado pela CNs que completa 10 anos e tem três nós coordenadores, na Universidade do México e na Universidade da Califórnia. Esses catálogos têm por objetivo organizar os metadados, indexar buscas, serviços de rede para compartilhar, assegurar disponibilidade de conteúdo, e a ideia é que você possa preservar em três instituições diferentes.

Além dos nós coordenadores, têm os nós membros, no Brasil tem um que é o PPBio que coleta informações ecológicas, e uma série de instituições e universidades que são nós membros. Os nós membros gerenciam seus dados, fazem capacitações e treinamentos.

A ideia é que ele disponibiliza uma série de ferramentas para cada uma das etapas, no planejamento dos dados, geração de conteúdos, geração dos metadados, ferramentas que auxiliam na integração e ferramentas de análise também.

Do ponto de vista do profissional da informação, em cada uma dessas etapas ele tem alguns desafios. Por exemplo, nessas etapas iniciais quais são os desafios? É definir e auxiliar no plano de gestão de dados. Na etapa de gerar os metadados, qual é o desafio? É verificar qual é o padrão mais adequada para aquela comunidade. Na etapa de agregar os metadados você tem que conhecer algumas ferramentas e repositórios para disponibilizar os dados. E na etapa de análise é conhecer as ferramentas e estratégias de análise para auxiliar o pesquisador. O profissional da informação está envolvido desde o início, em todos os processos.

Aqui eu estou consolidando algumas lições aprendidas por essa equipe da RGs que é a equipe do DataONE o que eles consideram e a gente vem aprendendo com eles. Um ponto é considerar o ciclo de vida dos dados. O ciclo de vida dos dados é qual é o ciclo de vida mais adequado para minha instituição ou para o meu domínio.

Identificar e disponibilizar ferramentas fáceis de usar, de treinar e apoiar cada uma das etapas. A formação de recursos humanos de maneira interdisciplinar, para que possa formar as pessoas com seus novos gestores, analistas e cientistas dos dados. Envolver gente da Ciência da Informação, da Computação, todos trabalhando juntos.

Um outro ponto a questão de recursos específicos é importante porque preservar dados é caro, então tem que ter modelos de apoio específico, pessoas engajadas, que não necessariamente sejam técnicos, e especialistas, pesquisadores, que possam contribuir na geração desse modelo de gestão.

As políticas de dados que apoiam dentro da instituição e que também tem um sistema de valorização que reconheça o fato de que a comunicação daquele dado possa ser reconhecida de alguma maneira, por exemplo o DOI.

Campanhas de engajamento da comunidade é importante, hoje a USP está o tempo todo informando as boas práticas para fazer reciclagem, é a mesma coisa com dados de pesquisa.

Métricas, você está avaliando os resultados e impactos o tempo todo. Do ponto de vista de quantos downloads, quantos acessos, quem está usando, o perfil do uso. Tem muita coisa a ser feita ainda, do ponto de vista de promover os principios FAIR de Findable, Accessible, Integridible e Reutilizable. Deve-se garantir que todo objeto de dados possa ser encontrado com mecanismos de comunicação e isso não está resolvido atualmente. A questão dos dados e metadados acessíveis, as vezes só os metadados, se existem mecanismos para tornar acessíveis esses dados. A questão da interoperabilidade e semântica dos dados, e o fato dele serem usáveis, manter para que sejam úteis.

Estes são os desafios e existem muitas pesquisas em cima disso, por exemplo, para análise e visualização, formação de pessoas sob abordagem interdisciplinar, a questão do uso e reúso na formação, a gente sempre estar praticando essa questão de uso e reúso dos dados, precisa pôr a mão na massa.

E como estratégia existem algumas áreas que são emergentes, Física, Biologia, Química, mas Química um pouco mais atrasada, mas Biologia e Física são áreas estratégicas.

A questão dos avanços culturais e das mudanças, é fundamental mudar a cultura. Investimentos a longo prazo, investimento nessa área para sustentabilidade. E sempre estar promovendo e divulgando.

Para concluir, temos um gráfico em duas dimensões, que de um lado fala sobre o armazenamento e do outro do entendimento. Podemos ter armazenamento a curto prazo para o pesquisador fazer uma publicação, beleza resolveu o problema dele aqui. Agora se a gente quer de fato do ponto de vista do armazenamento a gente tem a curadoria ativa, para que esses dados possam servir para gerar novas intervenções na sociedade, ter um nível de maturidade de uso bem alto.

A nossa meta é chegar aqui, dados que tenham curadoria ativa, que de fato estejam armazenados e possam ser utilizados para apoiar tomada de decisão, iniciativa de políticas públicas, etc.

Eu vou deixar esses slides disponíveis para a organização porque tem uma série de links interessantes com relação à política de dados, melhores práticas de gestão de dados, é isso, obrigado.

Vídeo da apresentação

Título: Infraestrutura brasileira para dados de pesquisa: reflexões.

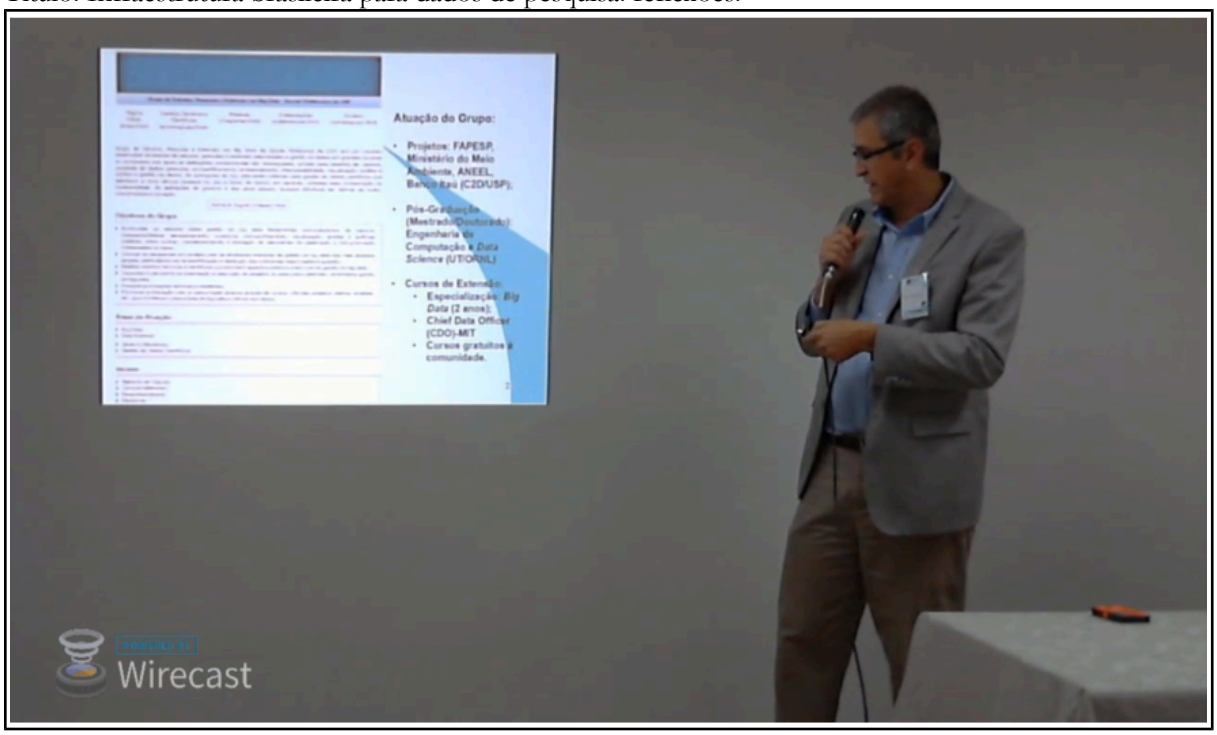

Fonte: http://dadosabertos.info/enhanced_publications/idt/video.php?id=31

Slides da apresentação

Título: Infraestrutura brasileira para dados de pesquisa: reflexões.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=31

Text Mining: o uso de dados não-estruturados como insumo para extração de inteligência

Text Mining: the use of unstructured data as input for intelligence extraction

Moisés Lima Dutra[a]

Transcrição da apresentação

Bom dia, nós vamos conversar hoje sobre Text Mining. Essa é uma disciplina que eu ministro lá na Universidade Federal de Santa Catarina no curso de Ciência da Informação, então tentei fazer um apanhado de maneira geral o tema, um campo muito amplo e vasto então na verdade não teríamos tempo de entrar nos detalhes, de cada um dos processos e de cada uma das etapas que ocorrem em um Text Mining.

Eu vou tentar fazer de maneira geral um overview e a ideia aqui é que vocês saiam sabendo do que se trata, e aí a gente pode depois desenvolver isso mais pra frente pra quem tiver interesse a gente pode conversar alguma coisa e tentar aprofundar ou detalhar alguma coisa que tenha passado.

Essa aqui é a agenda da apresentação, eu começar primeira uma introdução, um preâmbulo, depois a gente vai dar uma olhada geral no que é o Text Mining, vou apresentar para vocês as etapas de mineração, alguns exemplos e falar no final sobre desafios e oportunidades.

Vamos começar falando de cinema, vocês gostam de cinema? Já viram esse filme, Contato de Risco? a princípio tem tudo para ser um grande filme, lançado em 2003, título original Gili, título no Brasil ficou Contato de Risco, gênero comédia romântica, vejam só que o elenco é um grande elenco, Ben Affleck, Jennifer Lopez, Christopher Walken, Al Pacino. Por que esse filme é tão emblemático? Ele acabou criando um antes e depois, muito simples.

Porque ele custou 75 milhões de dólares e arrecadou 7,2 milhões de dólares, um grande prejuízo apesar de todo aquele elenco. Então isso aqui acendeu uma luz vermelha em Hollywood, o filme ganhou 6 prêmios no Grammy de Ouro: pior filme, pior diretor, pior ator, pior atriz, pior roteiro, etc. Aí além disse foi nomeado em algumas outras categorias: pior ator e atriz coadjuvante, e para finalizar ganhou o prêmio de pior comédia dos últimos 25 anos do Grammy.

O filme foi de fato um marco. Então isso acende uma luz amarela nos produtores de Hollywood, nos criadores de roteiro no sentido será que a gente não consegue prever o sucesso do filme? Será que a gente tem como saber se o roteiro é certo não, se seria adequado ou não? Além disso, será que eu poderia estar extrair então a informação, extrair inteligência de maneira a não jogar dinheiro numa obra que não vai dar retorno? Por exemplo, os orçamentos podem ser baseado nas possibilidades de sucesso? O que uma obra, enfim, pre diz.

E aí é interessante falar do caso Epagogix. A Epagogix é uma empresa britânica, que foi fundada em 2003, ela utiliza softwares analíticos baseados em redes neurais, e ela faz uma coisa

a Universidade Federal de Santa Catarina (UFSC). E-mail: moises.dutra@ufsc.br. ORCID: https://orcid.org/0000-0003-1000-5553. Currículo: http://lattes.cnpq.br/1973469817655034

muito interessante, ela avalia o grau sucesso dos roteiros e das tramas criadas pelos escritores, pelos criadores de roteiro.

Então ela começou trabalhando com filmes e programas de TV, na Inglaterra, no Reino Unido, logo no início, veja que interessante foi em 2003 que foi o mesmo ano de lançamento do filme. São dois eventos que se conectam mas que a princípio não tinham nenhuma conexão.

Então a Epagomix estabeleceu uma parceria com órgãos próprios da Europa no sentido de avaliar 16 programas piloto de televisão, eles queriam levar os programas para o mercado americano e como a gente sabe o público americano tem outro perfil. Portanto o roteiro que vai para os Estados Unidos ele precisa ser diferente do roteiro que é feito para Europa.

Vejam que interessante, para 13 programas a taxa de audiência calculada ficou dentro da margem de erro de dois pontos percentuais das taxas de audiências reais medidas quando o programa foi ao ar. E desses 13 programas, 6 programas ficaram dentro da margem de erro e 0,06.

Os caras pensaram, pera aí, a gente tem aqui uma coisa muito interessante, a gente consegue a partir da análise do script, identificar a quantidade de audiência do programa e, obviamente, isso vira um modelo de negócio onde você pode direcionar orçamento e procurar investidores.

Na verdade a Epagomix foi a primeira de uma série de empresas e ela foi o estopim daquilo que se costumou chamar em inglês de Análise de Scripts. Hoje existem diversas opções e uma das mais conhecidas é o Script Book que cobra 100 dólares por cada piloto que você faz de um roteiro inglês.

Cada um de nós que podemos escrever um roteiro tentando ganhar um dinheiro em Hollywood faz o upload no Script Book para tentar avaliar este roteiro. Então eu trouxe dois screenshots do dashboard do Script Book, onde são feitas análises do tipo do filme, do gênero, da categorização do filme como a variedade a partir de critérios norte-americanos, a estimativa de audiência mais ou menos, ela faz tipo uma tag cloud aqui na sinopse do filme.

Além disso são feitas algumas avaliações dos personagens com relação a diversas facetas, as diversas características como raiva, tédio, felicidade, amor, e aí sim você consegue avaliar pelos scripts a quantidade de cada uma dessas características presentes no personagem da sinopse.

No Script Book é possível analisar a probabilidade de sucesso de um filme, por meio dessa análise de sentimentos e dessa análise da história. Como é que os caras fizeram isso?

Tem um modelo de Machine Learning, eles pegaram um dataset composto por todos os filmes exibidos em cinema nos EUA desde 1970, foi por puro reconhecimento de padrão, se pegou os filmes de sucesso e cruzou com os filmes com sucesso de bilheteria.

Os filmes de maior sucesso foram usados então como um sistema de treinamento, e a partir daí cada novo script que é submetido ao site é comparado com esse sistema de treinamento e é então submetido a um modelo de classificação feito para prever o grau de sucesso que esse filme pode ter.

Como nem tudo são flores, esse é um site bastante criticado principalmente pelos autores que se sentem pouco, digamos, no terraço de uma máquina, os caras têm reviews bastante curiosos sendo interessante a gente procurar, os caras dizendo que a história é a capacidade criativa, mas enfim… Sem entrar no mérito o fato é que isso existe e já está sendo utilizado.

Em publicações científicas, esses dois carinhas aqui eram estudantes do MIT em 2005, no Departamento de Sistemas Cibernéticos e Informática. Mulecada nova, começou a desenvolver programas e eles fizeram alguns artigos científicos, como esse daqui que é muito interessante, propondo uma metodologia. É um artigo bem interessante, bem estruturado, ele trabalha um pouco a questão dos relógios de Lamport, a cadeia de Markov, são alguns os matemáticos.

O que há de tão interessante sobre este artigo? Ele é mentira, é fake.

Os três estudantes descobriram uma maneira de criar um gerador automático de artigos científicos para a Ciência da Computação. Eles não param por aí. Submeteram o artigo a um evento científico e o artigo foi aceito neste evento aqui, e alguns dias antes do evento eles vieram e confessaram tudo por uma Rede Social e disseram "ah pessoal era tudo uma brincadeira, o nosso artigo não é de verdade.

Isso gerou um grande zunzunzum, eles disseram que haviam criado um gerador automático de ciberespaço da Ciência da Computação, então você coloca o nome dos autores, alguma proposta de tópico e a partir daí um software gera automaticamente o paper e a prova de fogo foi justamente porque aquilo passou num sistema de avaliação por pares, de uma conferência bem-conceituada.

A I3E patrocinava o evento e retirou o patrocínio no mesmo ano, a empresa não gostou e começou a analisar então o software que foi a público. Só entre 2008 e 2013 de mais de 120 prêmios criados com software foram detectados pela I3E. Isso começou de uma forma a se tornar tão freqüente que daí que surgiu o software que detectava papers criados assim.

Então a Springer, que é aquela editora, se juntou à universidade de Grenoble, na França, e junto eles criaram um cyber detect, que é um detector de artigos gerados com o software.

Coloquei aqui mais alguns exemplos de geradores de texto, mas existem aos montes, como um clássico gerador de lero-lero né, usados para engrossar TCCs, Teses e Dissertações.

Mas o que está por trás então desses dois processos, desses dois cenários, tanto de cinema quanto da publicação científica? Simples, a detecção de padrões, a análise textual profunda e muito forte procurando buscar padrões e a partir desses padrões aplicar uma análise para extrair uma parte da inteligência, para extrair conhecimento.

Tanto o Script Book quanto a Epagomix fazem análise de roteiros de cinema. O Script Book tem um dataset monstruoso, com todos os filmes americanos. A Epagomix utilizava um outro método, que é preciso abrir um parenteses aqui.

Desde os anos 70 nos Estados Unidos, roteiristas de hollywood sabem que existe uma estrutura nos filmes, então foi escrito um livro chamado A Jornada do Herói, por um estudioso do folclore, enfim, e escreveu esse livro dizendo o seguinte: a humanidade sempre conta a mesma história, todas as nossas histórias são fazendas de uma mesma história, e ele faz um paralelo com personagens da história, Buda, Jesus Cristo, Confúcio, depois ele vem para personagem mais modernos. E os roteiristas de Hollywood entenderam um pouco isso, e o que se diz é que todos os filmes fizeram sucesso nos últimos 40 e 50 anos, eles seguem de alguma forma essa estrutura.

Cada sinopse teria 3 atos. O primeiro ato duraria 25% do filme, com a apresentação dos personagens, o personagem sendo uma pessoa comum e vivendo um dia-a-dia banal.

Na página dois do script é interessante tem um fato, uma revolução que leva para o ato 2, que pode ser uma coisa traumática ou uma coisa excepcional, se for filme de ação e aventura pode ser um momento na estrada que gera então para o herói uma busca por algo que quase espiritual, segundo alguns critérios.

Eu to detalhando todo o ato 2, o antagonista do filme seria uma serial que confrontaria o herói pessoalmente, e teria que superar essa meta se pode chegar um grau superior, e esse ato 2 se encerraria com isso.

Então o nosso herói vencendo seguiria para o ato 3 que seria trazer esses novos aportes que ele absolveu nesta sua jornada para aquela sua vida medíocre lá no início. Então ele voltaria para aquela vida com esses novos aportes. Então esse é a Jornada do Herói, e o autor do Script Book trabalhou em cima disso. Independentemente da metodologia que se usa, o fato é que as sinopses de filme hoje estão sendo avaliados por ferramentas e veio para ficar.

Quanto à análise de produções científicas, a detecção de padrões também está sendo utilizado. Na prática a gente precisa disso porque humanamente é impossível vocês vão avaliar devido ao tamanho e a quantidade de documentos e texto. Basicamente o que a gente tem por trás é o Text Mining permeando o fundamento desses cenários.

Mineração de texto, também chamado por alguns autores de mineração de dados, pessoais, a gente encontra isso também. É uma busca por padrões em textos digitais com linguagem natural, uma definição bem sucinta e objetiva

O texto é de linguagem natural, que é a mais importante fonte de informação, tem um relatório interessante de 2011 que estimava que mais de 90% dos dados existentes hoje são dados textuais, são dados não estruturados. Então vejam agora, vamos pensar um pouco nos nossos sistemas de trabalho com dados estruturados, como banco de dados, os metadados, seria apenas 10%, a gente está na ponta do iceberg.

Então a gente tem ainda 90% de dados que de forma nenhuma estão organizados. Mas, nem por isso, deixam de ser tão ou mais importante quanto os dados que estão estruturados.

Os dados textuais estão em sua maioria na forma não estruturados, uma sintática que não é confiável, justamente porque eu não tenho nenhum tipo de regra como um sistema de informação.

Desde os anos 50 e 70 fazer um tradutor entre o Inglês e o Russo, por exemplo. Porque a gente nunca conseguiu isso 100%? Porque trabalhar com texto é uma coisa bastante complexa, tem diversas nuanças e características que são muito peculiares apesar da grande evolução dos últimos tempos, como o Google Translator que está aí pra não me deixar mentir, mas, ainda assim, a gente precisa ir lá no Translator e fazer ajustes, retirar redundância, e ajustar o contexto.

Text Mining ou Data Mining? Essa é uma dúvida que muita gente possui, ah mas isso aí de minerar texto não é a mesma coisa de minerar dados? Sim e não.

É óbvio que nós temos hoje um ambiente com abundância de dados, só para citar algumas coisas, tudo que é informação digital, ela é um dado obviamente. Então imagine quantas transações eletrônicas são efetuadas por dia e por hora, todos os dados que estão na nuvem, todos os dados que estão em empresas, que estão universidades ou institutos de pesquisa, toda a

parte de internet das coisas e computação pervasiva, é cada vez mais dispositivos e sensores gerando dados, Machine Learning, etc.

É óbvio que a gente está num ambiente de abundância de dados, o pessoal coloca Data Mining nos textos, a gente encontra uma frase que é muito interessante principalmente nos Estados Unidos que dizia o seguinte: mostre-me dados que eu apresentarei padrões.

Mineração de dados ela tem alguns pré-requisitos no entanto, quais são? Os datasets precisam ser muito bem estruturados e organizados. Em toda a fase de preparação de um Data Mining ela é importantíssima, senão os resultados que obtemos não vão ser corretos, imprecisos. Eu preciso ter formatos muito bem definidos, ou seja, o processo prévio de preparação tem peso importante, então ou os dados já estão organizados para serem minerados ou a gente vai ter que fazer isso na mão.

Se a gente pudesse contextualizar as duas definições dos conceitos, apresentaria dessa forma aqui, a gente tem os dados não estruturados sendo estruturados.

O Data Mining, pessoal, ocorre em bancos de dados estruturados, SQL, Oracle, DB2, existe um formato, um padrão formal a ser seguido, esse dado já está organizado.

Mas a gente tem também os dados não estruturados, que é texto em linguagem natural, que é um post no Facebook ou no Twitter, que é a frase no WhatsApp que a gente escreve sem se preocupar com vocabulário controlado, tesauro ou ontologia, a gente escreve errado, com gírias, com pontuação incorreta, enfim…

E a gente tem uma camada cinzenta aqui entre esses dois, que eu chamaria de dados semi-estruturados, que são quase não-estruturados, que seriam por seriam, por exemplo, arquivos em XML de um sistema proprietário.

Hoje, os metadados e as tags foram definidas para funcionar assim. Ele é estruturado, mas é semi-estruturado, porque dependendo do sistema com o qual eu vá processar aquelas dados ele vai entender ou não.

Então Text Mining abrange essas duas camadas, dos dados estruturados e dos dados semi-estruturados.

Mas o que é interessante é o seguinte, na verdade elas interconectam no sentido de que mesmo trabalhando com dados não estruturados, muitas vezes no Text Mining o objetivo é chegar aqui, muitas vezes quando começo analisar texto o que eu quero na verdade é chegar a um modelo de dados estruturados, pode ser que a pura análise, a pura varredura do texto tal como estão, me permita extrair os ensaios que eu busco. Caso contrário, eu vou ter que fazer essa transição, então essa transição do dado não estruturados para os dados estruturados nada mais é que organizar, preparar e harmonizar esses dados, higienizar enfim, existem outras palavras que se usam para que eu cheguei nesses dados aqui.

Se a gente pudesse, digamos, subir uma cama nesse overview, eu posso se contentar com a Ciência de Dados, ela vai abarcar todos os dados, vai abarcar Text Mining, vai abarcar o Data Mining.

A transformação desse texto cru ou texto bruto em números, porque na verdade esse processo aqui ele acaba de certa forma transformando o que é texto em números, porque eu posso não ter chegado a uma estrutura em comum mas eu posso aplicar modelos matemáticos, aí

eu consigo trabalhar algum tipo de Machine Learning, porque aí tem números e eu consigo processar matematicamente, enquanto é só texto eu não consigo.

Na verdade essa transformação do texto cru envolve uma série de outras coisas. Eu posso tirar uma série de coisas, medição, enfim… De uma maneira geral essa seria a idéia dos Text Mining.

Esse processo de transformar o texto em números, a raiz do processo dá-se o nome de vetorização, eu vou vetorizar esse texto, vou transformar isso em um vetor matemático, Isso aqui é um assunto muito vasto, isso aqui a gente trabalha em muitas aulas lá na UFSC mas eu vou tentar pincelar aqui de uma maneira bem sucinta do que significa sem entrar muitos em detalhes técnicos.

É importante falar do modelo SAC of Words, ou modelo SAC de palavras. Esse é o modelo que está por trás da minha mineração de texto. Esse modelo compreende a freqüência das palavras distintas existentes nos documentos. Então na verdade você vai pegar um conjunto de dados no qual cada elemento desse conjunto é a freqüência de uma palavra em determinado documento.

Evidentemente, eu tendo um conjunto de dados nesse para cada um deles. Essa freqüência de termos gera um peso que vai se associado a cada um dos termos. Se conta o número de ocorrências do termo dentro do documento para me gerar um valor matemático que a gente chama de freqüência de Deus, e isso vai atribuir o peso a quantidade de ocorrências desse termo.

Entretanto, existe um problema aqui. O meu cálculo final pode ficar desequilibrado, porque dependendo do contexto que eu estiver trabalhando há termos que são figurinhas carimbadas, que existem aos montes, e isso pode enviesar o resultado final.

Para que isto não ocorra, existe o inverso da frequência dos termos nos documentos, que é um outro cálculo que se faz. Ele tenta melhorar esse problema de que todos termos se torne proeminente, porque pode se tornar um problema crítico, vou dar um exemplo aqui para vocês.

Imaginem que a gente teve trabalhando com processamento de uma massa documental da indústria automobilística por exemplo, a gente vai ter muito frequentemente a ocorrência dos termos carro, automóvel e veículo, olha se eu já sei que esses termos vão aparecer aos montes e eu ainda sim considerar o peso deles em relação aos outros, vou criar um viés ali que vai impactar firmemente no resultado final que eu quero.

A ideia do universo da frequência e não superdimensionar a ocorrência dos termos que irão ocorrer de qualquer forma, muito frequentemente, então para esse fim a gente considera também o número de documentos no qual eu tenho em uma base, e aí a gente tenta atribuir um peso menor para aqueles documentos que estão mais abrangentemente dispersos, de maneira que eu sei que aquele termo vai aparecer de qualquer forma, eu não preciso minerar porque ele é frequente, então a gente atribui um peso menor.

Como o exemplo da indústria automobilística, imagina que eu tenho lá esses quatro temos, essa coluna representa a quantidade de documentos que esses temas aparecem, e a última coluna a frequência atribuída a eles.

Vejam que o mesmo o termo que foi o que menos apareceu é o que vai ter um peso maior. Por que? Pra que isso se equilibre, o TF que é o universo da frequência vai equilibrar o TF que é a frequência do termo.

A gente chega então no cálculo que a gente quer, que é o cálculo do Tf, que é o produto das duas métricas anteriores, então vamos considerar que a freqüência que o tema aparece em um documento juntamente com o ingresso da freqüência em que ele aparece no documento.

Nesse cálculo aqui ele pretende estabelecer uma relação entre os termos mais freqüentes do documento tanto quanto a relação do documento com o corpus textual como todo.

Ainda assim é preciso que se faça um último ajuste no Tf e ITf, porque eu preciso considerar o padrão de diferentes documentos do mesmo corpus, então imagine que eu tenho um corpus de 10 documentos, e um dos documentos tem dez páginas, e eu tenho outro documento com 100 mil páginas, fica completamente irreal eu atribuir o mesmo peso a esse documento, é óbvio que o documento de 100 mil páginas o termo vai aparecer muito mais frequentemente, a chance dele estourar ali o delta é grande, então a aplica equações matemáticas como aqui mas a gente chega depois nesse ITf que deve ser normalizado. Aí sim esse cálculo que a gente vai associar aos termos dentro do processo de mineração de texto. Aquela vetorização vai ser preenchida para cada termo, geralmente com o cálculo da ITf normalizado.

Algumas aplicações aqui do Texto Mining. Elas são inúmeras, tentei pegar o que era mais significativo aqui, mas isso não é, de maneira alguma, de maneira exaustiva.

Classificação dos documentos, categorização de documentos, sumarização, similaridade, reconhecimento de entidades nomeadas convencionados, análise de sentimentos ou como geração de opiniões, sistemas de pergunta e resposta, chat box, vou tentar rapidamente solucionar cada um deles para que a gente tenha uma ideia do que significa cada uma dessas aplicações.

A classificação de documentos é aplicada quando eu tenho um corpus documental e eu quero literalmente revelar quais os documentos dentro de categorias pré estabelecidas, pré definidos, então o sistema de classificação vai obter sucesso porém ele consegue associar cada termo todo documento a sua correta categoria que corresponde.

Aqui 3 categorias criadas, uma categoria polícia ou pelo telefone celular por filmes né eu tenho documentos que remetem a ao iPhone 6, outro liga da justiça, outra a milk shake de banana, enfim… E a gente roda isso no sistema de classificação textual e ele automaticamente agrupa os textos dentro da categoria pertinente, como é que isso é feito?

Atribui-se um peso para cada um dos documento, avalia-se na hora em que vai definir você faz esse ajuste, a gente pode, por exemplo, ter um exemplo imagine que eu livro que possui mais de 30% do conteúdo sobre a preparação de comida, a gente pode definir se passou dessa categoria, a gente pode dizer o que ele pode se classificar com um livro de culinária de receitas.

Prioridades e pesos são atribuídos. O que é importante lembrar que a classificação é que os grupos eles são criados pelos humanos, eles são pré definidos e aí a gente tem também a uma aplicação similar que é a clusterização.

Na clusterização os grupos são defendidos automaticamente, o próprio processo de mineração textual se encarrega de criar os grupos, então a gente vai aplicar a clusterização sobre

uma massa documental e vai identificar os clusters existentes ali, a gente vai categorizar. Tem um processo a mais, a gente poderia dizer que a classificação é um processo de machine learning supervisionado e aqui é um processo de machine learning não supervisionado.

O objetivo é criar clusters desses documentos que sejam similares, ele procura automaticamente e atribui subgrupos. Mesmo que a granularidade, que estou chamando aqui de documento pode variar desde uma pequena frase até coleções inteiras de documentos.

Aqui é uma ilustração que mostra uma coleção de documentos depois de rodar por clusterizadores e simplesmente criar clusters como agrupamentos desses documentos.

Quais são as vantagens da clusterização? Ela retirou do elemento humano a obrigatoriedade participar desse processo. Muitas vezes você pode por curiosidade ou por identificar tendências também, é muito interessante, você pode ter uma massa documental e quando faltou conversa que eu tô falando também de dados textuais coletados na Web, imagine eu posso estar analisando posts, ou site de notícias, sites informativos, eu quero identificar a tendência, quais são os tópicos mais discutidos naquele momento?

A gente vai rodar aquele de software de clusterização nesse corpus e vai identificar automaticamente os clusters que existentes ali. Principalmente quando o corpus textual tem grande clusteridade, poder dois exemplos aqui na classificação de notícias de última hora. pra ver como funciona com uma notícia trend topics de hoje, documentos no mercado de ações que mudam a cada minuto.

Outra aplicação é a sumarização, ou seja, a criação de resumos automáticos, exatamente isso que vocês estão pensando, imagine que eu tenho um documento e quero criar automaticamente o resumo contendo as partes mais significativas do documento. Ele pode ser aplicado tanto documentos solitariamente quanto em grandes corpos documentais.

A gente consegue definir qual vai ser o tamanho desse resumo, é 10% do total? Claro, é um processo automático, o software precisa saber. Então eu tenho lá um documento de 500 páginas, 50 páginas resume? Será que 50 páginas consegue fazer resumos? Ou 58? 20 páginas?

Além disso a sumarização pode ser feita por quem escolheu os documentos, eu posso simplesmente pegar um documento que seja representativo no meu corpus, então após ter o corpus documental é o momento de dizer, olha esse é um exemplo clássico é indicativa, ele contém resumidamente tudo aquilo que o documento representa.

Não esqueçam de que já foi criado o clusters com o agrupamento de similaridades de documentos, uma outra proposta é sumarizar pela mescla de documentos. Aqui eu tenho três clusters de documentos, vamos pegar o mais significativo de cada um deles e vou criar um novo clusters aqui com o resumo, vou ter um conjunto de documentos que representam de maneira resumida a informação que está no meu cluster.

Algumas vantagens, a gente pode visualizar a sumarização automática de um texto bastante extenso desde que para pesquisas científicas ou uma outra coisa interessante, sumarização automática independente, fazendo ali um fichamento eu posso fazer algo automatizado. Múltiplos documentos com o mesmo tópico, a gente pode pegar de fato aquele que é mais significativo, não ficar repetindo, ou posso organizar automaticamente.

Outra aplicação do Text Mining é a similaridade de documentos. Similaridade de documentos faz uma comparação e indica o grau de similaridade que o documento possui com outras. Então aquele documento 1 e documento 2 eu vou montar a similaridade em cima do escore aqui.

Então a similaridade é realizada como uma etapa anterior a clusterização, você só vai clusterizar documentos similares. O que é mais comum, no entanto, é que isso seja feito como um chamado de documentos compostos, que são aqueles documentos que já vem de vários clusters, de um ou mais clusters, e a gente pode calcular a similaridade desses dois.

Imagine que você tem um corpus documental com 50 mil documentos. Cada documento com n páginas e eu quero clusterizar isso. A gente precisa de alguma forma rodar um algoritmo ali dentro para ele aplicar a similaridade par a par, é uma tarefa bastante custosa na computação, a clusterização é sempre mais pesada processado do que a classificação.

Como é que a gente calcula essa similaridade? Usando nosso retorno atras, a gente chegou aqui na parte da data mining, transformou um texto em números, com números eu consigo calcular a proximidade numérica. Quando transforma o texto em número, eu consigo aplicar processos matemáticos naquilo ali. E aí faltou o Tf e ITf deve ficar com um aqui.

Então geralmente se calcular três valores, eu vejo o valor dos documentos, dos dois documentos mais próximos entre si e o valor dos outros documentos mais distantes entre si, e a média desses valores. A partir daí a gente calcula o score de similaridade.

Vejam aqui um exemplo. Imagina que eu tenho ali dois vetores compostos, só que são três documentos, esse aqui é o único, e a gente vai computar a singularidade daquilo ali e vai chegar nesse escores aqui, 0,50 para o mais próximo, 0,45 o mais distante da média, e 0 o restante, a gente pode dizer de cara de eu tenho um grau médio de 47% de similaridade dos documentos, por exemplo.

A partir dos valores gerados pela similaridade, simplesmente depois faz uma transferência dos documentos para os clusters, a gente agrupá los por similaridade. O cálculo de similaridade pode se bastar por ele mesmo pode ser usado intermediário da clusterização. Existem diversas métricas de similaridades, citei algumas aqui que calcula a distância entre dois strings parecidos, métrica de Manhattan e a distância do seno e coseno, e a distância de Levenshtein.

A distância de Levenshtein ela calcula o número mínimo de edições necessárias em forma de adoções, remoções e substituições. Então a gente observa essas duas strings para saber qual é a distância de uma para a outra.

Outro exemplo aqui são essas palavras, e a distância de Levenshtein é três, porque eu preciso fazer uma substituição aqui, depois uma segunda substituição e finalmente com a inserção de letras, aí eu consigo chegar perto dele.

Então só métricas que são utilizadas no cálculo da similaridade.

As entidades nomeadas são análises que se fazem em textos que a gente consegue extrair daí categorias pré-definidas, como pessoas, organizações, locais, como dados monetários, etc.

Aqui tem um exemplo, imagine que eu rodei essa frase aqui "a Wikipedia corporation é empresa criadora da Wikipedia", e a gente traz essas duas entidades, uma organização que é a Wikipedia Corporation e o software que é a Wikipedia. Vejam aquela frase ali, a gente tem quatro

entidades reconhecidas, então Obama como uma pessoa, a GM como uma organização, Detroit como local e Today como uma data.

Então a gente consegue a partir da extração das entidades nomeadas, veja que eu já estou agregando valor semântico aqui na mineração, eu estou extraindo informação de mais alto valor agregado.

Análise de sentimentos é uma aplicação também bastante utilizada, principalmente quando a gente analisa redes sociais. Basicamente é uma extração subjetiva da informação, a gente tem duas formas de aplicá-lo, uma forma binária sim ou não, gostou ou não, e uma forma mais elaborada de identificar.

Óbvio que quanto mais especificada é a mineração que eu faço, mais custoso computacionalmente será isso.

Sistemas de perguntas e respostas. Como exemplo o IBM Watson, é uma aplicação que foi feita lá em São Paulo, e conversa com as pessoas que visitam a exposição e ele vai aprendendo também aí. Então existe um sistema de retroalimentação, ele vai reorganizar os documentos baseados em critérios racionais. Muitas vezes pode ser um comentário durante uma resposta, enfim, é um sistema de aprendizagem supervisionada.

E o Chatbox, que são aplicações de conversa entre duas pessoas, eles são baseados no teste de Turing, que foi proposto pelo Alan Turing ainda nos anos 30 para tentar descobrir se uma pessoa conseguiria identificar quando é uma máquina ou uma outra pessoa que estivesse conversando com ela normalmente. Hoje é muito utilizado para serviço de atendimento ao cliente, à venda, no Facebook e ele também vai aprendendo conforme as novas respostas.

Etapas da mineração. A gente tem uma coleta do corpus textual, tem um pré-processamento que é chamado também de processamento de linguagem natural, o processamento em si, e também uma etapa de pós-processamento.

A coleta de corpus textual eu posso trabalhar com documentos que já são meus, ou eu posso acessar datasets que sejam públicos e estejam disponíveis, ou eu posso coletar dados da Web utilizando uma técnica chamada web scraping, que é ir lá e baixar os dados do HTML.

Precisamos ver quais são os documentos relevantes, em que formatos eles se encontram, isso está em ASC, PDF, RDF, etc. Geralmente se transforma para UTF-8 que é padrão para mineração de texto, padrão UNICODE, e aí a gente entra na etapa mais importante que seria o processamento de linguagem natural, que perpassa todas essas etapas aqui.

É uma limpeza textual, uniformização de maiúscula e minúsculas, tokenização textual, expansões e contrações, remoção de símbolos e pontuação, remoção dos stopwords, exposição da grafia, e lematização/radicalização.

A limpeza textual a gente retira tudo aquilo que não serve, tudo aquilo que é estranho ao texto, tokens, anotações, depois a gente uniformiza, o software que compara os strings, geralmente jogam a grafia para o maiúsculo.

Remoção de todos os símbolos de todas as pontuações, afinal de contas isso não agrega nenhum valor semântico.

A Tokenização textual. Os tokens são a unidade básica do Text Mining, são as unidades mínimas e eventualmente serão palavras, mas nem sempre será uma palavra. Eu posso ter uma frase ali, depois que a gente faz as primeiras etapas posso chegar nesse conjunto de tokens aqui.

Expande-se as contrações, caixa d'água, copo d'água, queda na água, São Miguel d'oeste, a gente faz uma expansão de contrações, mas isso já caiu um pouco em desuso no nosso português, mas no português de Portugal ele é muito utilizado. Em inglês você passa a descontração do verbo em expansão.

Remove-se então as stopwords, que são palavras sem significados, artigos, pronomes, advérbios, conjunções, etc.

Corrige-se a grafia, para evitar problemas gramaticais. Obviamente vai ter que ter um dicionário aqui na língua que está trabalhando.

E faz-se o processo de lematização e radicalização. A lematização busca a forma canônica dos termos, por exemplo o verbo estudar. A lematização ela pode ser substantivada ou verbalizada.

A radicalização simplesmente é ver o que tá igual aqui, pegar a interseção e definir. Veja que a radicalização nem sempre vai resultado em um dicionário de dado, a lematização sempre vai resultar em um dicionário de dado. A radicalização é mais adequada para busca sintática, enquanto a lematização e mais adequada para busca semântica.

Finalmente então o pós-processamento tem as etapas, geralmente de validação cruzada, tem uma série de metas, você tem que avaliar o resultado do classificador, do clusterizador, do sumarizador, ver se aquilo está adequado, e então realimentar o sistema, redefinir as métricas e os parâmetros, reavaliar o corpus textual, eu corpus pode não estar adequado, pode não ter sido limpo o suficiente, talvez a lematização tivesse sido melhor que a radicalização, a gente precisa fazer esses ajustes.

Aqui um exemplo rápido da vetorização, eu peguei três documentos muito pequenos, que são conjunto de frases, e fui aplicando aqui, vejam, "ambiente agradável e tranquilo", "comida rústica com qualidade", e "adoramos o filé à parmegiana". No documento dois, "o filé parmegiana da cidade", "ambiente agradável" e "qualidade no atendimento", e documento três "o filé a parmegiana com fritas é uma delícia".

Então aplicando a análise léxica dos corpus a gente chega nesse tipo de tokens, depois de todas aqueles processos de limpeza. Depois a gente remove as stopwords, veja que já reduziu aqui minha quantidade de tokens. Finalmente a gente faz a radicalização e chega-se a esses termos aqui. No dicionário de termos a gente fica então com 13 termos naquele conjunto de documentos.

Finalmente a gente bota isso em uma matriz e faz uma representação binária, cada coluna é um dos termos e cada linha é o número do documento, e eu faço uma representação binária para ver se o termo existe ou não em determinado documento.

A partir daí, a gente calcula o Tf e ITf para cada um dos termos e dos documentos, e finalmente o cálculo normalizado do Tf e ITf. Agora eu tenho um dataset pronto para que se rode algoritmos de Machine Learning.

Alguns desafios da mineração de texto: minerar termos em línguas que não são inglês, é um dos grandes desafios hoje principalmente falando em termos de Brasil, a gente tem uma série de problemas que são mais complexas como relações semânticas.

E as oportunidades do Text Mining, existe uma miríade de softwares disponíveis, muitas APIs, pacotes, bibliotecas de software, códigos na linguagem Python com o uso do R a gente faz maravilhas porque está quase tudo pronto, o nosso trabalho basicamente é o trabalho de coleta, fazer web scraping, isso é uma Ad Hoc que não está pronta ainda.

A curva de aprendizagem ela é percorrida muito rapidamente, então para retomar lá do início tanto no cinema quanto na produção científica e inúmeras outras áreas elas podem ter aplicação na mineração de texto, obrigado.

Vídeo da apresentação

Título: Text Mining: o uso de dados não-estruturados como insumo para extração de inteligência.

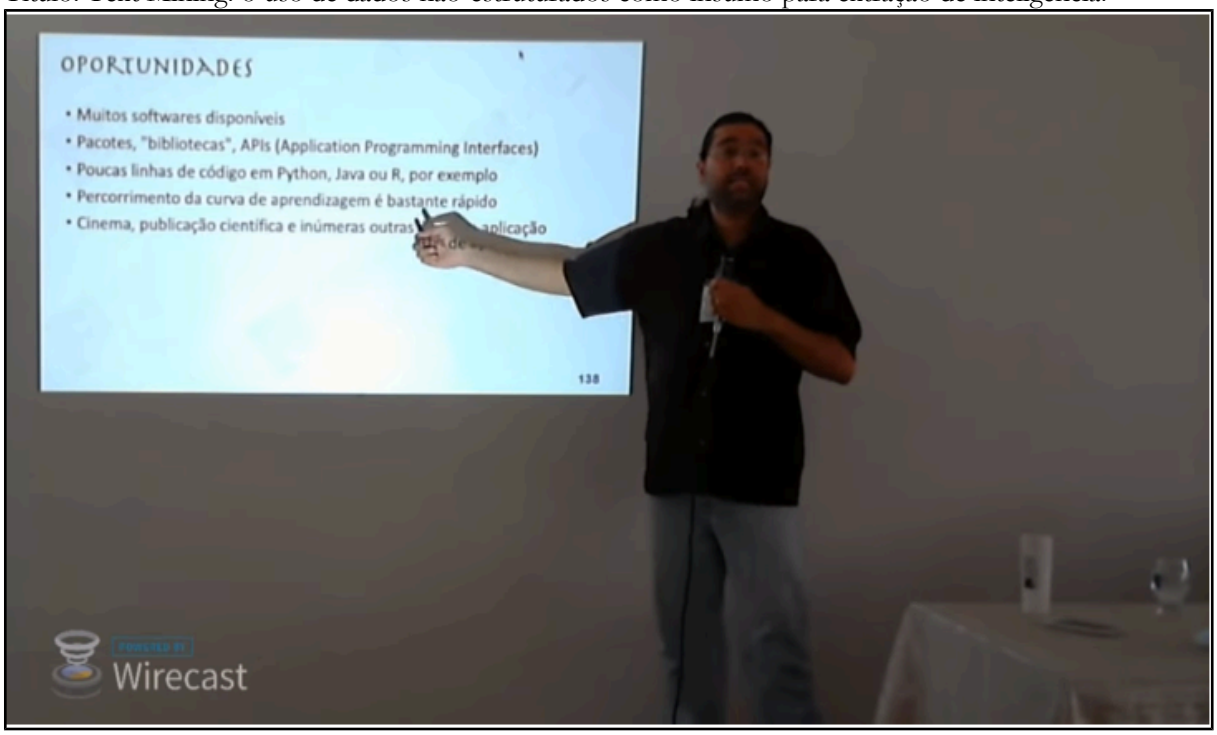

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=32

Slides da apresentação

Título: Text Mining: o uso de dados não-estruturados como insumo para extração de inteligência.

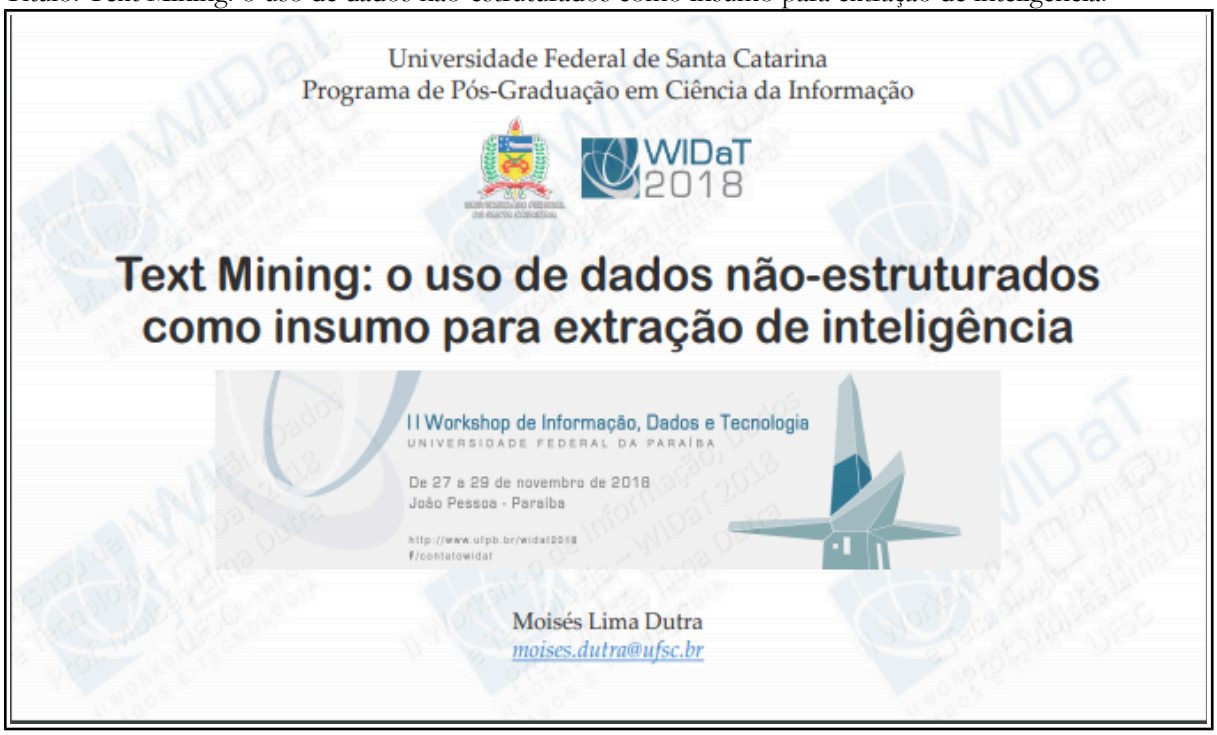

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=32

MPPB: a prestação de serviços ao cidadão através da disponibilização de dados

MPPB: the provision of services to the citizen through the provision of data

Marcos Vinícius Ferreira Cesário[a]

Transcrição da apresentação

Bom dia, eu gostaria de agradecer primeiramente o convite do professor Guilherme, muito obrigado pela oportunidade.

Gostaria de começar falando com vocês de uma expressão bastante conhecida chamada xeque mate. Quem acompanha o noticiário público local e internacional deve estar bastante acostumado com as operações que o Ministério Público (MP) tem desenvolvido para o combate a corrupção, uma das mais famosas dela é a Operação Lava Jato.

Aqui na Paraíba nós tivemos uma operação chamada xeque mate que desmembrou um esquema de corrupção em um município, tudo que estou dizendo aqui está disponível no website do Ministério Público. Esse esquema criminoso foi articulado para beneficiar um empresário da cidade de João Pessoa, através da manipulação do poder Executivo quanto do poder Legislativo, ou seja, esses poderes tinham que trabalhar para atender a intenção privada.

A partir disso o MP identificou que a compra municipal tinha cerca de 60 a 80 funcionários fantasmas, mas como foi que eles utilizam isso? Na primeira edição do Hackfest dois estudantes, um de engenharia civil e outro da ciência da computação tiveram a seguinte pergunta "Vamos cruzar os dados do site do Tribunal de Contas que traz todos de empenhos para alimentos dos municípios do estado da Paraíba, vamos mapear todos os endereços das câmaras municipais dos municípios da Paraíba, vamos pelo Google Earth vamos ver o tamanho deles e vamos ver quantos servidores têm em cada Câmara.

Eles fizeram essa análise e disseram que tem uma MPL que diz que para uma pessoa trabalhar em ambiente de escritório deve trabalhar 9 m², mas na Câmera de um dos municípios havia 1 funcionário a cada 1,6 m², isso sem descontar às áreas de circulação e área para, como banheiro e copa.

Essa aplicação chamada Enquadrados foi a vencedora do primeiro Hack Fest, e foi uma solução que talvez o MP em seu ambiente de investigação não tivesse criado, foi proposta por jovens entre 18 e 24 anos que passaram um final de semana para trabalhar. É disso que o Hack Fest trata e que o MP da Paraíba tem oferecido a nossa população como uma forma de engajar as pessoas no combate a corrupção em vista que todo órgão público tem suas limitações operacionais, não dá pra dar conta de todas às investigações em um tempo rapidamente, então quando a gente consegue engajar a população no combate a corrupção isso se torna muito mais dinâmico.

a Ministério Público do Estado da Paraíba (MP/PB). E-mail: viniciusc@mppb.mp.br. Currículo: http://lattes.cnpq.br/6051846594211806

Tem também o condão de transformar isso em uma rotina, porque esse câncer que existe hoje na sociedade brasileira chamada corrupção só vai ser expurgado quando tivermos consciência de que temos que tratá-lo diariamente. Temos que tomar conta do que é público diariamente, a sensação de empoderamento feminino que tanto tem se falado agora ela tem que ser visto como um bem público porque ele é nosso, então o Hack Fest foi uma forma que o MP desenvolveu em parceria com a Universidade Federal de Campina Grande e hoje tem mais de 50 parceiros que apoiam a iniciativa, e que encontrou como engajar a população.

A primeira informação que a gente trouxe foi um ranking da corrupção de 2017. A transparência internacional em 2017 posicionou o Brasil bem pertinho né, num universo de 180 países estamos pra lá da metade. Quanto ao índice de corrupção às Américas apresentam um índice de 44% uma vez que abaixo de 50% indica que os governos não conseguem combater a corrupção. O Brasil caiu 3 pontos comparados ao índice de 2016.

Aí a gente trouxe algumas informações sobre o custo da corrupção: 5% do PIB mundial, 303 bilhões no Brasil, enfim tem várias comparações, se a gente fosse fazer com cédulas de dez reais dava dois mil quilômetros de cédula, quatro mil prédios de seis andares, 57.700 escolas, dez em cada 100 municípios no Brasil, 7.272 hospitais por ano, 10 vezes o contingente policial nas ruas, duplicar a malha ferroviária, oito vezes mais o Bolsa Família.

Esses dados nos informa que nós temos orçamento, com base em que o Brasil é um país que tem futuro mas a gente tem que sabem como usar isso, esses dados de corrupção são os dados mais visíveis, não é daquela que é desviado, é os 10% da obra pública, 10% da entrega de material que o gestor ficou pra ele.

Para beneficiar uma organização privada a máquina pública trabalha para isso, então tem todo o custo dos servidores que estão trabalhando para isso, esses são os custos mais diretos e fáceis de identificar, mas nós temos também os custos indiretos nisso, então vejam o tamanho.

Há duas semanas atrás nós estávamos no Acelera Startup que é um evento desenvolvido pela FIESP em São Paulo, lá naquele prédio do pato. Acelera Startup é para empresas operacionais que já estão lucrando com uma ideia criativa e para profissionais que ainda não começaram e também para estudantes. E eu tava falando lá justamente disso que o industrial brasileiro não se engane que a corrupção também atinge ele, não só quando ele vem com um pedido de propina mas sobretudo quando há ocorrência mitigada, desleal por conta da corrupção, como você vai concorrer com uma empresa que está sendo beneficiada por um agente público, a chamada carta marcada.

Nós temos no nosso site, dados que a gente trabalhou também com o pessoal do Hack Feste, que chama empenhados.mppb.br. O processamento da coisa pública se dá da seguinte forma: empenho, que é a reserva do dinheiro, quando ele empenha quer dizer que o orçamento da União reservou 100 mil reais para o pagamento a você; a liquidação que é quando o funcionário pública indica que a obra foi feita, e há a transferência do recurso para o credor.

Esse estudo verificou que quase 80% da indicação da coisa pública no Estado da Paraíba é feita no mesmo dia. Como é que você faz uma obra pública e você empenha, liquida e paga no mesmo dia? É impossível, porque para construir uma pequena sala você vai demorar aí uns 3 meses, e só pode pagar depois.

Não existe no contrato com o órgão público aquele famoso adiantamento de 50%, que às vezes se contrata com um fornecedor particular. Em administração pública isso não existe porque eu só posso pagar quando o serviço foi efetivamente prestado. Então esse estudo indica que pode haver coisa errada nessas prefeituras.

O Hack Fest tem esses eixos aqui, que são às atribuições do MP no combate à corrupção. Mas ele também é dirigido para a melhoria do serviço público, por exemplo, esse ano ganhou um aplicativo que não necessariamente está voltado para combate a corrupção mas sim a melhoria do serviço público. O cidadão diz nesse aplicativo qual é o medicamento que ele está precisando, ele vai procurar na rede pública e qual é o local o próximo a ele e que tem o medicamente. Você loga, acha o seu medicamento e vai lá buscar. Se não tiver no município próprio o aplicativo direciona isso ao MP que vai lá investigar. Nós temos esse eixo também de melhoria do serviço público.

O Hack Fest já foi feito em quatro edições, este ano incluímos a virada legislativa. O que é isso? Às vezes para fazer um aplicativo você não tem permissão legal para todas as análises que você precisa, então o Hack Fest acoplou a virada legislativa para dizer que para eu fazer isso eu preciso consultar a lei. O que é aprovado através de iniciativa popular, através de um aplicativo da mudança, que também é uma organização que está nos ajudando com o Hack Fest. Para ninguém reclamar entregamos a solução tecnológica e a solução legal para aquilo.

O que é o Hack Fest? É um movimento tecnológico cuja proposta é incrementar o combate direto a corrupção, entendida como uma das principais causas para o desencadeamento da pobreza. É uma iniciativa coletiva de profissionais e estudantes de diversas áreas correlatas à gestão pública e seus artefatos, como Tecnologia da Informação, Contabilidade, Administração, Direito, entre outros, sempre com esforços para o desenvolvimento de soluções tecnológicas avançadas como aplicativos ou jogos, que atuem na formação e controle de conscientização popular no acesso a dados públicos.

O Hackfest não é direcionado só para o pessoal de TI, ele também é para profissionais de engenharias, design, que são às pessoas que vão fazer como o aplicativo o website se apresenta para que as pessoas possam utilizá-lo de maneira mais simples, tem a pessoa de contabilidade, de Administração, quase todas às áreas, a gente só precisa que as pessoas tenham boa vontade já que é um movimento voluntário e às pessoas não recebem remuneração direta. Você concorre a um prêmio, a gente sempre premia quando encontra um parceiro que patrocina o prêmio, no caso o BNDES já patrocinou um prêmio de 60 mil reais na edição passada.

Quem pode participar? Todos, estudantes, profissionais, membros da sociedade em geral, não precisa ser especialista, junte seus amigos e venham. A gente sempre diz isso, você não precisa ser especialista em nada, você precisa ter boa vontade, e ideias na sua cabeça, porque quando começa essa competição, e eu vou contar para vocês como é a metodologia do Hackfest para vocês entenderem, e às ideias são inúmeras e uma ideia acaba sendo ajudada pelas outras pessoas e o escopo vai sendo definido para aquele aplicativo.

Como nós selecionamos o pessoal para o HackFest? Nós lançamos um edital com 250 vagas, todo mundo se inscreve, 40% é pra área de TI e o resto para as outras áreas. Você que se

inscreve é selecionado por um professor daquela universidade, que olha seu currículo, e depois você vai pro Hackfest e a primeira coisa que acontece é um Brainstorming.

E lá todo mundo primeiramente faz um nivelamento, corrupção é isso, despesa pública é isso, empenho é isso, licitação é isso, então a gente dá uma nivelada que todo mundo entenda, leva técnico da Controladoria Geral da União e Ministério Público, todos esses órgãos de combate e controle, e depois todo mundo dá suas ideias. Nós fazemos um formulário, depois que terminar todas às ideias todo mundo vota, cada um vota em cinco. Dependendo do tamanho do evento a gente seleciona às 26 mais votadas e seleciona os padrinhos que vão ser os chefes do grupo, e eles se juntam por proximidade. A gente sempre procura deixar todas as equipes mais ou menos com os mesmos tipos de profissionais para ajudá-las, por exemplo TI tem que ter um técnico, uma pessoa de Direito, outra de Contabilidade, mas é uma coisa mais por afinidade. A partir daí começa o desenvolvimento das soluções tecnológicas.

Quanto custa participar? É um evento gratuito, o ano passado foi todo custeado pelo MP, o desse ano já é patrocinado por Banco do Brasil que investiu. Eu estava falando com um professor que esse evento lá na FIESP o pessoal, é um evento que você se reuni com vários investidores do país inteiro, e eles vão fazer perguntas e você tem um pitch de 3 minutos para mostrar sua ideia e eles perguntaram, você está querendo investimento a super nível? Porque todo mundo estava tentando, tinha gente vendendo caixa de levar órgão transplantado, tinha gente fazendo agricultura, tem todo tipo de ideia. E eu cheguei lá com a ideia do Hackfest, aí o cara assim você está querendo investimento a super nível, eu disse que não. Qual empresa que hoje não quer ter um selo de probidade, de apoio a uma ideia de integridade, porque hoje o que mais se fala no Brasil é combate a corrupção, e se nós cidadãos não apoiarmos empresas que se preocupam com isso, é como enxugar gelo.

Você vai vincular sua marca a um selo de probidade, que é um evento voltado para o combate à corrupção. Se nós estamos no desenvolvimento de uma imagem diferente no nosso país, e se essa imagem é de integridade voltada ao combate a corrupção, é importante que algumas empresas que assim ser identificadas, também carregam esse selo. E falaram que representaram na ideia e vão refazer a forma de deixar às Startups porque o empreendedorismo acaba ficando um pouco de lado porque você não lucra, o produto do MP é a prestação de serviço a sociedade, o nosso lucro é o reconhecimento social, que é quando o povo na rua elege o MP como uma das instituições mais confiáveis do Brasil. A gente está cuidando da imagem da instituição e aprimorando a prestação de serviço.

Como acontece? Além da maratona de programação que é o desenvolvimento da tecnologia, a gente tem a mudança de leis na mobilização, que é avalia os projetos de leis para viabilizar os aplicativos, além disso a gente ainda pensou, como era para trazer o pessoal que não trabalha com aplicativo, que não tem esse interesse, então nós desenvolvemos juntos o Hackfest para essas insígnias. A gente traz a pessoa da operação Lava Jato, várias pessoas de tecnologia, vai fazendo às palestras que ocorrem do lado do Hackfest, e a gente deixa a nave de programação que é onde se desenvolvem os aplicativos, como observatório, para todo mundo que não está participando se interessar por aquilo e dizer que coisa interessante, e vou dizer a vocês que os aplicativos do Hackfest estão hospedados no eufiscal.org.br todos estão lá de todas as edições.

O formato. Participação voluntária da sociedade, maratona de programação, desenvolvimento de soluções tecnológicas, premiação e disponibilização dos softwares. Nós também estamos trabalhando uma forma de fazer a propaganda desses softwares, uma forma de torná los conhecidos junto ao povo. Nós tivemos um aplicativo que foi abraçado pela CGU no Maranhão que dá ao aluno que está comendo na sua escola a chance de avaliar. Por lei às escolas tem que publicar o cardápio, então o aluno loga lá e vai analisar e avaliar se a merenda está de acordo com o que foi publicado pela direção da escola.

A gente teve um desenvolvimento uma ação no MP para desempenho das gestões das prefeituras e junto também na sociedade geral para ver se implanta em todos os municípios.

Maratona de programação tem um público estimado de 300 maratonistas. Temos os maratonistas e temos os técnicos, que são às pessoas que ficam ali fazendo análise de dados, tirar dúvidas, analisar o que está no banco de dados do Tribunal do Estado, da União, e tudo isso é levado para o Hackfest e às pessoas trabalham do jeito que elas quiserem.

A transparência pública, os portais, já é um avanço porque eles estão nos dando os dados, mas é mais fácil você navegar naqueles dados. Nós que somos especialistas, tem coisa em gestão que eu não consigo entender, por exemplo, se você quiser analisar o salário do pessoal da câmara dos deputados você tem que passar por três fases para chegar e entender o que era aquilo.

No primeiro dia de Hackfest foi proposto o desafio do quebra-quebra e eles quebraram lá e colocaram de uma forma mais explícita, então você entra lá e vê o salário de todo mundo sem passar pelas etapas, enfim a embromação foi adiada.

Tem também as oficinas, palestras, e o objetivo é "ser promotor da geração do conhecimento para o enfrentamento à corrupção e melhoria da gestão pública pelo controle social, produzindo ferramentas tecnológicas a serem utilizadas pela sociedade, estimulando a participação colaborativa e voluntária dos atores sociais e possibilitando não só a replicabilidade e sustentabilidade do Hackfest, como uma conscientização de cidadania digital que possa ser exercida pelos cidadãos por meio da tecnologia da informação como repúdio à corrupção".

O Hackfest trouxe uma metodologia documentada, já aconteceu esse ano no Amazona Feste, o Amapá também está fazendo seu Hackfest inclusive neste mês, nós fomos selecionados pelo diretor das Nações Unidas e indicadas para concorrer um prêmio da ONU do escritório de Nova York. Ele escolheu dois prêmios no Brasil e um deles foi o Hackfest, nós concorremos com 800 projetos do mundo inteiro, não ganhamos mas só o fato de ter sido indicado já é uma honra.

Essa ideia nasceu em um final de semana entre alunos da Universidade Federal que resolveram desenvolver uma aplicação de controle social, pegaram cidades no país e compararam pelos dados, população parecida, orçamento parecido, e pegavam uma cidade com mesmo orçamento de Campina Grande e comparavam, e saiam diferenciando essas cidades. Aí veio a ideia para mim por um promotor de combate ao crime organizado aqui da Paraíba e pensamos em fazer para o MP, mas nós do sistema de justiça temos meios monótonos, que são sempres cursos e palestras, aquela coisa mais formal. Então como trazer esses meninos?!

Não adianta botar todo mundo aqui em um ambiente de sala de aula com uma pessoa só falando que não vai sair nada, aí tivemos a preocupação de trazê los para perto da instituição mas

de uma maneira que eles se sentissem em casa. No Hackfest é um ambiente totalmente diferenciado, primeiro que o jeito de se vestir é flexível você vai com a roupa que quiser, e segundo que você se interna e faz todas as refeições lá, que é a refeição adaptada para o público, tem até para vegetarianos, é uma refeição para angariar esse tipo de público. No ambiente nós temos jogos, videogames, ping pong, lugar para deitar e descansar, a gente trata da melhor forma aquela pessoa que está indo de graça exercer sua cidadania, e muitas veze a pontuação é a mesma que o MP utiliza.

A quarta edição do Hackfest aconteceu esse ano em João Pessoa lá na Estação do Vaz que é o prédio que tem do lado da Estação Ciências, foi realizada pelo Conselho Nacional do Ministério Público, através da Comissão Especial de Enfrentamento à Corrupção. O pessoal da Lava Jato quis fazer o Hackfest em Curitiba esse ano só que acabou não dando certo e foi realizado novamente em João Pessoa. Já é uma iniciativa que o próprio Conselho Nacional tomou para si e está tentando replicar nos estados. Esqueci de dizer que o direto tem a ideia de começar a aplicar o Hackfest também nos países da América Latina, são algumas características parecidas com do nosso país.

O Hackfest é um evento no sentido de que você identifica pessoas que têm o mesmo propósito e estabelece uma rede de colaboração, onde trabalham entre pessoas, organizações, empresas, organizações da sociedade civil, órgãos de combate a corrupção e o povo. Todo mundo está no mesmo propósito, que é acabar com a corrupção.

Aqui eu trouxe alguns exemplos de aplicativos desse ano como "#Pra elas", "Estamos de olho", "Democracia digital", "Abre ai", "Lei do Respeito Mútuo". Esse "Lei do Respeito Mútuo" eu acho muito interessante, não sei aqui na UFPB tem mas em outros órgãos públicos têm, sabe aquele quadro que diz que desacato a funcionário público é crime, que muitas vezes inibe a pessoa que vai ser atendida, realmente desacato é um crime previsto em código penal, esse projeto diz tipo assim que desacato ao usuário do serviço público também é crime.

Os aplicativos. "Cadê meu Remédio", que foi aquele que falei para vocês, "Lupa na Toga", aplicativo que mostra e analisa todos os auxílios e diárias recebidas pelos magistrados brasileiros, eles foram lá e colocaram os excelentíssimos que mais recebem dinheiro e indenização em relação ao magistério. "Não nasci para ser a outra", plataforma que investiga as candidatas fantasmas para preenchimento de cotas dos partidos públicos, "Brasirama", aplicativo que mostra um perfil sociodemográfico dos cidadãos, "Focaqui", aplicativo que mostra os índices de homicídio e de violência contra a mulher por localidade, "Câmera das Deputadas", plataforma que apresenta um levantamento das leis propostas e aprovadas por mulheres na Câmara Federal, além de um perfil das deputadas, mostrando o cenário político feminino, "Me diz quem tu és", aplicativo que identifica os deputados e deputadas por meio de análise do discurso, passando como entrada uma afirmação através de voz ou texto.

Esses foram o desse ano, nós tivemos outros interessantes como "Vida de Balada", ali você loga e vê qual deputado tem uma vidinha de balada com o dinheiro público, que mais viaja, que mais frequenta restaurante. Nós temos também o "Obras Go", que é aquele joguinho, então você loga nesse aplicativo e ele vai mostrar todas às obras públicas que estão em andamento perto de você. Então para fiscalizar o aplicativo vai mostrar que essa obra custou tantos milhões, que foi

empenhado tantos milhões, foi feito um teste em Campina Grande com uma circuito de Atletismo, já foi empenhando 5 milhões de reais e o que tinha era terra, capim e riscos com giz tinha pó branco.

Isso não é necessariamente um avaliativo de que ali teve corrupção, mas isso é sobretudo uma forma que o cidadão está se preocupando com o bem público, está fiscalizando, fica de olho e faz a coisa certa porque vocês está exercendo o poder mas o titular do poder é o povo.

Temos os apoios aqui que eu coloquei para vocês, aqui um vídeo mostrando o ambiente deste ano, a gente fez um grande jogo de Tetris e cada equipe do Hackfest está em uma pecinha, aqui é o controle inicial do Tetris, aqui é onde eles lancham, os videogames, aqui é o palco, aqui está os técnicos que tiram dúvidas, aqui cada equipe e aqui o palco onde tem as apresentações no último dia e onde são passadas todas as instruções do evento.

Esse ambiente como mostrei para vocês é um ambiente que é sempre renovado, todo ano tem uma espécie de ambiente, às ideias são várias, e nós sempre nos preocupamos justamente em fazer 8ma coisa menos formal e mais atrativa aos estudantes para que eles se sintam em casa e que seja criativo, para que induza a criatividade. Esse aqui, por exemplo, é uma praia, aqui está o mar, as pessoas estão aqui, nós tivemos participação do país inteiro nesse evento.

E para encerrar eu queria dizer para vocês uma coisa que ouvi do promotor que é coordenador do evento, ele faz alguns questionamentos por exemplo o Google é responsável pela grande organização de dados no mundo, a Amazon é a que mais vende coisas, tudo que você precisa a Amazon vende, a Spacex tem esse intuito agora de povoar o Universo, e o Hackfest tem o intuito de transformar pessoas em cidadãos, para que as pessoas exerçam seus direitos e para que nós possamos extirpar a corrupção do nosso seio, obrigado.

Vídeo da apresentação

Título: MPPB: a prestação de serviços ao cidadão através da disponibilização de dados.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=33

Slides da apresentação

Título: MPPB: a prestação de serviços ao cidadão através da disponibilização de dados.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=33

A gestão dos dados de pesquisa no contexto dos pesquisadores brasileiros na Ciência da Informação

The management of research data in the context of Information Science Brazilian researchers

Guilherme Ataíde Dias[a]

Transcrição da apresentação

Muito obrigado, bom dia para todos, hoje nós vamos discutir aqui um assunto que eu acho muito importante para comunidade da ciência da informação. Então no terceiro e último dia do WIDAT, mostra que todas as palestras têm um eixo em comum, que é a questão da Ciência da Informação (CI) e da questão dos Dados. Nos dois primeiros dias não, nos temos um foco diferente, mas hoje é a Ciência da Informação e a questão dos Dados. Porque eu acho que isso é importante para a área? Historicamente a comunidade da CI foi responsável pela introdução de uso dela na área, visto os portais de periódicos.

Eles foram abordados por essa área e eu acho que no Brasil os periódicos abertos é um verdadeiro sucesso. Talvez seja um dos países que a ferramenta mais deu certo. É o uso do PKP para você disseminar periódicos.

A questão dos repositórios também passa pela Ciência da Informação. Eu acho que em escala menos. Os periódicos foram os mais populares, foi abraçado mais rapidamente. Tanto que eu acho que até hoje a questão dos repositórios ainda não está consolidada, mas isso passou pelos colegas da CI.

E um assunto que eu acho que precisa ser tocado é a questão dos dados de pesquisa, dados científicos. É um assunto que a área precisa investigar, precisa entender para que outras áreas se aproveitem disso. Todos nós temos condições de trabalhar com as questões que envolvem os dados científicos, e de forma mais notória a gestão desses dados.

Outra forma de dizer isso, eu acho que o tempo do profissional da informação, seja arquivista, bibliotecário ou outros, tenham condições de atuar em todas as caixinhas do ciclo de vida dos dados, todas as partes do fluxo, não importa qual ciclo de vida, n´s temos como trabalhar.

Para eu entender o que a comunidade acha disso, nós fizemos uma pesquisa com os pesquisadores da área. Fomos entender o que os professores têm a oferecer para a comunidade, a gente não pode dizer que o aluno não sabe trabalhar, porque talvez tenha faltado o treinamento, então nós fomos entender o que os pesquisadores acham dessa área.

Esta palestra, os dados dela, já foram apresentados em outras palestras, mas eu só consegui compilar tudo agora. Nessa compilação de dados só foi finalizada agora, aqui tem 70% dos dados compilados.

a Universidade Federal da Paraíba (UFPB). E-mail: guilhermeataide@ccsa.ufpb.br. ORCID: https://orcid.org/0000-0001-6576-0017. Currículo: http://lattes.cnpq.br/9553707435669429

Na nossa pesquisa, qual foi o universo: todos os pesquisadores vinculados a programas de Pós-Graduação em CI listados na plataforma Sucupira da CAPES. Muito provavelmente alguns de vocês aqui responderam a essa investigação.

Quero dizer que o questionário foi baseado no questionário do USGS. Aqui estão todos os programas da área que foram submetidos ao survey. Isso foi em 2017.

Foi um questionário enviado por e-mail para todos os pesquisadores listados nas páginas dos programas brasileiros de CI. O questionário foi construído e disseminado com o uso de uma ferramenta de software livre. O período de aplicação da coleta de dados foi entre 17 de julho a Agosto de 2017. Eu optei por utilizar uma ferramenta de software livre mas o Google Forms também faz isso, mas preferi ficar aderente ao software livre.

Foram enviados 341 questionários, obtivemos em todo de 190 questionários completos. Taxa de retorno 55,4% o que eu acho que foi excelente. Historicamente fica entre 20% a 15%. Então eu acho que a comunidade nos prestigiou com isso, mas também fizemos 3 chamadas para que pudessem enviar o questionário.

A faixa etária dos pesquisadores, a maioria é de 45 a 54 anos, mostrando que o pesquisador não tem uma faixa etária muito baixa não [risos].

Tempo de atuação na pós, a maioria de 10 a 19 anos, e 27,7% entre 5 e 9 anos. Isso é novo né, é gente nova.

A pergunta foi: realiza a gestão de dados científicos?

Antes não foi explicado o que é isso, mas na segunda etapa era perguntado se você queria continuar e alguns já saíam. O total de 188 vai caindo, a partir de algumas questões feitas esse número vai caindo.

Aparentemente tá todo mundo igual, nós temos 62,8% dos entrevistados fazendo gestão de dados científicos.

Realiza a gestão de dados científicos por faixa etária na pós-graduação?

Aqui vocês podem ver na tabela por tempo de pós-graduação quem faz a gestão de dados científicos por faixa etária.

Então, se você faz gestão ou não, eu perguntei por que você não faz? Surgiu a teoria do desconhecimento. A maior parte da resposta é desconhecimento por não fazer a gestão, consideram crescente mas ainda não tem tanto conhecimento para fazer. Falta de prática, já li a respeito, desconheço métodos adequados de armazenamento, foram algumas respostas que os pesquisadores foram dando, mas o motivo de desconhecimento foi o mais evidente.

Mais razões: desconhecimento de procedimentos sobre como gerenciar e armazenadas os dados científicos; ainda tenho pouca familiaridade com este procedimento; preciso conhecer estratégias necessárias para o preparo e disponibilização dos dados de pesquisa em repositórios; porque sou obrigado a fazer e de fato não sei nem começam; a única coisa que faço é guardar meus dados brutos de questionários e transcrições de entrevistas em pastas físicas e digitais.

Criei uma categoria "diversos", para o motivo de não fazer gestão. O foco foi desconhecimento, depois diversos.

Faltam recursos que permitam acesso a dados, tempo é um dos principais dele. Concordo, porque tempo é complicado para o pesquisador.

Público o resultado da pesquisa, mas a gente não quer só os resultados a gente quer os dados também.

"Infelizmente ainda não faz parte das atividades do fazer científico", pensamento de um colega nosso.

"Ainda não é tradição na área", "guardei por vários anos em fita magnética os dados de pesquisa, entretanto nunca recebi uma solicitação para compartilhar dados". Assim como o tempo esses dados o suporte de preservação ficaram defasados. Desinteresse, na categoria "diversos", do por que não fazer.

Se você não faz gestão eu optei pela decisão de não continuar participando, as questões do questionário eram pertinentes a gestão de dados, então se você não faz gestão de dados por que continuar?

Você elabora um PGD?

Agora o PGD é um instrumento que está mais popular, principalmente lá em São Paulo agora porque a FAPESP se for um projeto temático ela exige. Geralmente o que começa na FAPESP dissemina pelas outras fundações de apoio científico no Brasil. Acho que o CNPQ também em breve deve estar pedindo. Então, 45% não elabora o PGD, 55% sim.

Vou adiantar aqui uma coisa que achei interessante. Às vezes você faz uma pergunta, o pesquisador diz que sim e aí o discurso não condiz com a resposta, mas todo assunto novo é alguma coisa.

Razões para não elaborar o Plano de Gestão de Dados?

"Não incorporei ainda esta prática, mesmo que considere importante". Mais uma vez a teoria do desconhecimento foi a que prevaleceu.

'Falta de capacitação técnica para tal", "precisa saber mais sobre o tema", "falta de conhecimento a respeito do assunto", desinteresse.

Você faz o uso de alguma ferramenta computacional para utilizar na elaboração do PGD? Sim com 55% e com 45% não.

"Por falta de software específico da faculdade"; "prazos e outras habilidades deixam o PGD em última prioridade sendo ao final não realizado"; "já possuo prática de procurar e curar os dados de pesquisa"; "já faço milhões de outras coisas absolutamente sozinho", etc.

"A função do pesquisador não é gestão de dados"; "demanda uma política institucional com pessoas qualificados", eu acho isso muito plausível. Todos os processos de gestão eu entendo que o pesquisador não tenha como fazer isso pela dificuldade.

Quem é essa pessoa qualificada para resolver a gestão? É aí que vocês profissionais da informação tem que entrar, não pode perder esse trem, de perder essa possibilidade de conhecimento, se vocês não forem atrás alguns irão, certo?

Você^s faz uso de metadados para descrever seus dados?

A maioria não faz, meio a meio quase. Vamos ver dos nossos colegas como está o uso de padrão de metadados. "Uso etiquetas com palavra-chave para catalogar a documentação física"; "também uso recurso para organização do dado no computador"; etc.

Lembrando que a pergunta era: Padrão de metadados utilizado na gestão de dados? Tiveram várias respostas mas ninguém respondeu qual padrão de metadados, apenas dois pesquisadores colocaram Dublin Core.

Estou disposto a guardar todos meus dados em um repositório central sem restrição de acesso? Então discordo fortemente e discordo é a maior parte, como vocês vêm aqui. A maioria dos colegas acha que todos, não a maioria, todos os dados não devem ser compartilhados. Eu mudei a pergunta para alguns dados, aí nesse caso ficou mais positivo.

Usaria conjunto de dados de outros pesquisadores se esses conjuntos de dados estivessem facilmente acessíveis? A maioria sim, entende que eu não compartilho mas eu usaria. Talvez a questão de compartilhar ganhe visibilidade quando os órgãos de fomento estimule isso. Mas em geral a visão da área é que todos os dados não devem ser compartilhados.

Os pesquisadores devem definir um período de embargo?

O período de embargo é o tempo em que você depositou em um reportório mas esses dados não estão disponíveis para todos, estão preservados e você pode controlar com o software do repositório, você faz preservação, a sua comunidade de pesquisadores pode acessar, como meus orientandos, mas para o mundo está fechado. Mas então por que é importante o embargo?

Você publica seu dataset aí alguém pode pegar esse dataset e utilizar para fazer descobertas antes que o pesquisador que coletou e processou, então iria se beneficiar desse dataset antes que quem criou faça isso, por isso a importância do embargo de dados.

Foi rápida apresentação mas basicamente é isso, não só a visibilidade mas quanto mais dados, eu acho que a nossa comunidade não está preparada para repassar isso para os discentes. Como que você começa com 188 respondes e cai para 66, e a partir do momento que você faz aquelas perguntas mais indiscretas como "Qual o padrão de metadados você usa", as respostas não condizem com o que o pesquisador afirmou.

Vocês que são pesquisadores e trabalham com isso, você tem uma missão, a missão de levar isso aí, é orientar as pessoas acerca dessa temática. Então muito obrigado, espero ter sido claro, e obrigado pela presença.

Vídeo da apresentação

Título: A Gestão dos dados de pesquisa no contexto dos pesquisadores brasileiros na CI.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=34

Slides da apresentação

Título: A Gestão dos dados de pesquisa no contexto dos pesquisadores brasileiros na CI.

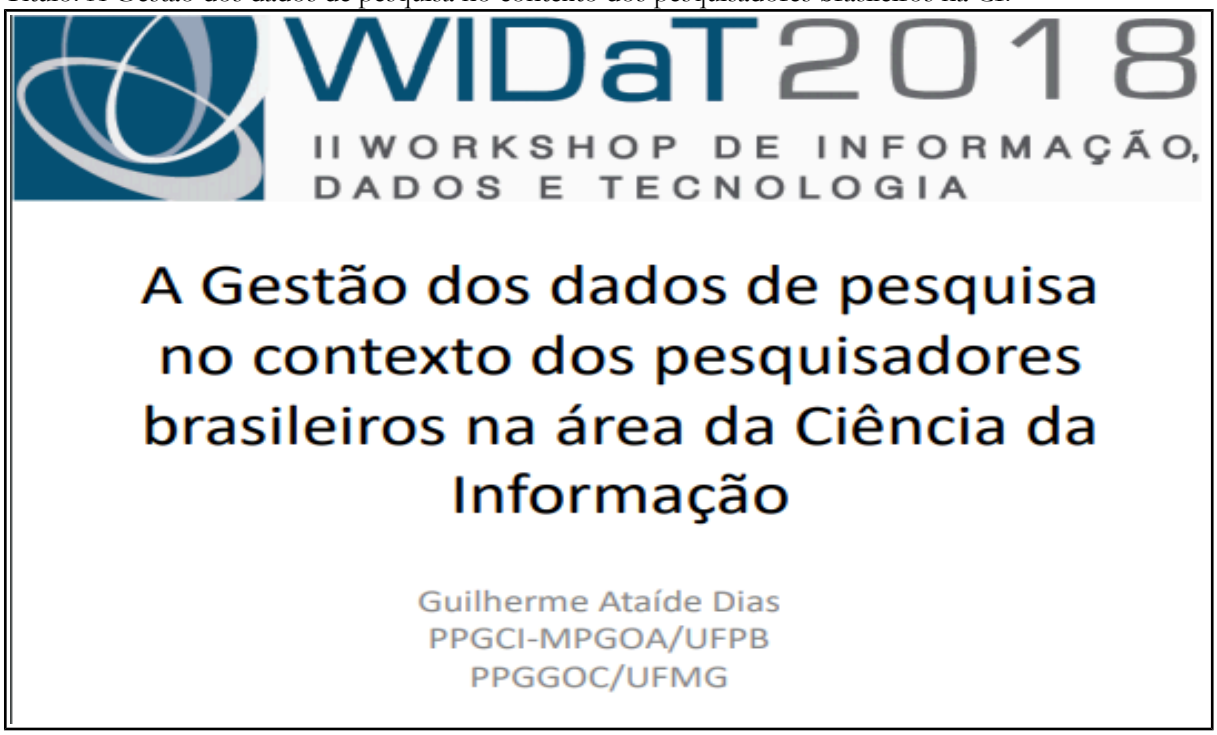

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=34

Dados de pesquisa e o profissional da informação

Research data and the information professional

Plácida Leopoldina Ventura Amorim da Costa Santos[a]

Transcrição da apresentação

Eu quero agradecer imensamente a oportunidade de estar aqui, agradeço ao professor Guilherme, ao professor Moisés, ao professor Ricardo pela disponibilidade de me dar essa oportunidade, de falar um pouco sobre dados de pesquisa e o profissional da informação.

É um prazer enorme estar em João Pessoa, fiz uma viagem super longa, vim de Marília, moro lá do sertão de São Paulo e estou chegando aqui no nordeste lugar lindo, praia, tudo muito bom, e revendo amigos, porque descobrimos hoje que João Pessoa é o centro do mundo, pois estou revendo um monte de gente e amigos que faz muito tempo que eu não via.

Ao para comparar, antes de falar com vocês o que conversamos, eu tive a oportunidade de rever muitas coisas durante esse longo período que eu trabalhei na área de Ciência da Informação e com o curso de graduação em Biblioteconomia e na Pós-Graduação em Ciência da Informação.

A meu ver, todas as coisas que eu já havia falado, eu tive uma dificuldade em manter o foco no que eu ia querer falar aqui, porque eu revi muitos documentos, revi muitos dados, tive a oportunidade de jogar os dados que eu coletei no mestrado, numa época em que vocês não eram nem nascidos, quando eu terminei eu tinha uma quantidade de planilhas e resultados do meu mestrado, que foi com alunos de ensino médio, com 1.200 crianças e jovens, e mais uma parte da cidade, e eu tinha tudo isso guardado, e aí descartei.

Do meu doutorado também, muitos aqui também não eram nem nascidos quando eu fiz o doutorado, e esses dados todos estavam lá no meu escritório, e eu comecei a rever e pensar "puxa vida daria para fazer tanta coisa que eu não fiz com essas respostas", com esses dados coletados já a mais de 20 30 anos, e aí descartei.

Se eu tivesse conhecimento sobre a gestão e gerenciamento de dados, provavelmente esses dados estariam disponíveis e poderiam ser analisados sobre um novo olhar. O olhar foi pro lixo mesmo, já joguei, fiz uma limpeza na minha estante. A ideia foi tentar focar no título proposto que é "Dados de pesquisa e o profissional da informação".

O que são dados de pesquisa? Nessa minha faxina no escritório, eu descobri que os dados de pesquisa são aqueles dados que antecedem os resultados, e eles podem estar em diversas estruturas, documentos textuais, planilhas, cadernos de planilhas arquivos e fotos, eles podem estar em diversas estruturas e a partir deles serão geradas as publicações que nós profissionais da informação estamos acostumados a trabalhar, que são as teses, as dissertações, os artigos, as publicações em evento, que a gente acha que estão muito bem nisso.

a Universidade Estadual Paulista (UNESP). E-mail: placida@marilia.unesp.br. Currículo: http://lattes.cnpq.br/7408791408049766

Mas como vamos trabalhar com esse conjunto de recursos gerados antes da publicação? e aí esses dados podem ser do tipo observacionais, experimentais, simulações, dados compilados, dependendo do tipo da área do conhecimento onde o pesquisador vai estar atuando.

E eles tem uma característica muito em comum, eles são de difícil estrutura, organização e armazenamento. Então depende de alguém e de um planejamento para que esses dados sejam publicáveis, acessíveis e disponíveis.

E aí você me pergunta, o que você faz? Você tem um plano de gestão de dados? Não. Eu faço parte daquela turma que caiu na entrevista que o Guilherme fez la no questionário, eu fui parte dos descartados, eu recebi o questionário e faço parte dos descartados lá na primeira parte. Eu fiz também o do IBICT, mas eu também deve ter sido descartada.

Aí nós temos algumas perguntas que vem a mente dos pesquisadores? Nas nossas cabeças como pesquisadores ou iniciantes. As perguntas são: Quais dados coletar? Como descrevê-los? Como assegurar a qualidade? Como tornar acessíveis ao longo do tempo? Como fazer isso em público? Como escolher o repositório? Além de tornar os dados acessíveis eu ainda tenho que saber onde colocar. O que é um plano de gestão ou gerenciamento de dados?

Porque agora você entra em um lugar e a pessoa perguntam: e aí, você faz um plano de gestão de dados? A resposta ideal seria: não sei, não sei o que é isso, talvez ou faça?

Como devo fazer? Quem deve fazer? Existe modelo? Existe alguém que faça para mim? Essas são as perguntas que popula a nossa cabeça enquanto pesquisadores e bibliotecários.

Então a pergunta mais importante é: QUEM PODERÁ NOS AJUDAR?

Eu acho que o ideal seria ele, que tem tudo milimetricamente calculado, mas nós também temos tudo milimetricamente calculado, mas nós fazemos parte dos plano do profissional da Ciência da Informação, que também faz parte das Ciências Sociais e Humanas, por isso precisamos mesmo do Chapolin Colorado. Porque Nós somos uma área que desenvolve pesquisa sem dinheiro, consideradas pelas engenharias de fraca, e agora arrumaram um termo mais triste que é de small – além de fraco é pequeno, que o método que usamos é o hipotético-dedutivo na maioria das vezes.

E agora a gente começa a trabalhar com dados, e a gente nem sabia trabalhar com dados, porque quando a gente levanta as hipóteses, lá no meio a gente fala assim "puxa vida daria para fazer um questionário", e é lá no meio do projeto que a gente resolve isso. Aí acontece que a OLGA, vamos utilizar a OLGA que o Guilherme falou, a OLGA pega todos os pesquisadores, e nós temos uma OLGA em São Paulo chamada FAPESP, é uma super OLGA, porque essa OLGA diz assim ao pesquisador "se você não tiver você não recebe dinheiro. Seja pouco ou seja muito. Você tem que fazer.

Então nós descobrimos, pressionados pela possibilidade de financiamento, que nós pesquisadores devemos construir um plano de gestão ou de gerenciamento de dados. Mas o que é isso?

Aí o que é bacana eu trouxe para vocês olharem aqui, no que é que diz o que é um plano de gestão de dados, um PGD. Devem ser apresentados duas páginas, onde você deve apontar como será a descrição dos dados, que padrão de metadados que você usa., quando ele é aplicado, quais

as restrições legais e éticas, qual política de preservação e compartilhamento, como se dá a descrição dos mecanismos.

Você deve fazer isso em duas folhas antes de encaminhar o projeto de pesquisa. Aí quando a gente começa ler o que é um PGD, o pesquisador começa a descobrir que ele faz isso. Ele pode não fazer por escrito mas quando ele apresenta os passos metodológicos, os elementos que fazem partes dos materiais e métodos, provavelmente uma grande quantidade de resposta vão aparecer aqui.

Então o que o pesquisador tem que fazer? Tem que colocar no papel o que ele tem na cabeça que vai acontecendo durante o desenvolvimento da pesquisa. Ele vai ter que buscar conhecimento das áreas que já fazem isso com muita antecedência porque demanda muito recurso. Para receber recurso eu preciso dizer o que eu vou fazer.

Antes de qualquer coisa, nas outras áreas do conhecimento, das BIG, nós somos small, mas as BIG já tem uma certa experiência nisso e nós temos que aprender com isso e colocar por antecipação que caminho queremos na coleta, uso preservação e disponibilização dos dados. Então vamos fazer uma síntese do que nós fazemos, tornar palatável, escrever sobre como trabalharemos com os dados para uma criança de 6 anos, e você faz em duas páginas.

Você traz também condições para que isso seja transformado em um algoritmo, bem simples e fácil e cria possibilidade para gerar modelos conceituais dando condições para máquinas trabalharem.

Estávamos falando sobre dados de pesquisa, e o título diz dados de pesquisa e profissionais da informação. Aí eu falei, mas quem são profissionais da informação. Aí a gente tem um monte de ideias, são os jornalistas, bibliotecários, arquivistas.

Formos procurar oficialmente no Brasil quem são os profissionais da informação. na classificação brasileira de ocupações, nós temos as famílias ocupacionais, as ocupações e as famílias afinas.

Aí eu fiquei chocada quando descobri que existe uma família de profissões chamada profissional da informação. Está dentro do número 2612, e dentro de 2612 tem essas ocupações aqui como profissionais da informação: biblioteconomista, bibliógrafo, cientista de informação, consultor de informação, especialista, gerente e gestor da informação. Também tem documentarista, técnico de documentação, pesquisador de informação em rede. E nas famílias em fim nós temos os técnicos em biblioteconomia.

Cadê o museólogo? Cadê o jornalista? Não são considerados na nossa classificação com os profissionais da informação. Os profissionais da informação são esses.

A classificação brasileira de ocupações aconteceu em 2002, que é uma Lei que faça com que isso existe no Ministério do Trabalho. Em 2008 foi definida a família ocupacional aqui.

Diz no site que isso é atualizado anualmente, por adicionar, trocar ou complementar informações ou alterar os títulos e funções das atividades. A nossa não é mexida desde 2008, nunca foi alterada.

Aí, eu fui procurar, cadê o arquivista, e cadê o museólogo?. Eles pertencessem a outra família ocupacional, a de número 2613. Eu continuei aqui e fui ver quais são as atividades que esse profissional da informação, na classificação de ocupação, tem com relação a dados: desenvolver

base de dados, efetuar manutenção de base de dados, migrar dados, acessar base de dados, estudos cientométricos, bibliométricos e informétricos, coletar e analisar dados estatísticos.

Então está aí, diz que é para fazermos isso. Faz parte da categoria dos profissionais da informação onde estamos integrados, como bibliotecários, como cientistas da informação ou como documentados.

Isso chamou muita atenção porque não revela a ocupação do profissional da informação com clareza, e não teve nenhum movimento da área para ampliar as contribuições que estão aqui.

Aí se tem o cientista da informação aí, o que estamos falando o que é a ciência da informação ao longo dos anos. Então fui procurar lá no meu escritório o que estamos falando sobre a ciência da informação. Ela tem uma natureza interdisciplinar, uma relação estreita com as tecnologias da informação, desde a sua instalação, ela participa ativamente na evolução da sociedade da informação, e trabalha na construção de uma ciência mista, e na proposta de métodos práticos para solucionar problemas práticos tanto a vida profissional da ciência da informação como da vida profissional de outras ciências que trabalham com a ciência da informação.

As principais interfaces são aquelas que a gente já conhece: museologia, arquivologia, biblioteconomia, comunicação, linguística, antropologia, computação, computação, administração, ciências cognitivas, sociologia, essas são as mais faladas.

E aí vem algumas perguntas novamente. Lembra que nós não encontramos um Chapolin para nos ajudar enquanto pesquisadores, talvez ele precisa atuar aqui de novo nas perguntas que estão presente na área da Ciência da Informação.

As bibliotecas enquanto instituição de referência na área da Ciência da Informação, elas estão respondendo às mudanças apresentadas no contexto das investigações científicas? As bibliotecas estão envolvidas no gerenciamento de dados? Os bibliotecários estão aptos para atuar no contexto dos dados ou do quarto paradigma? Quais habilidades os bibliotecários podem trazer para esse contexto da gerência dos dados? O Brasil forma bibliotecário de dados?

E aí continuando nessa busca do que a gente vem falando para o pessoal que é formado na área da CI, eu tive algumas surpresas e uma das maiores foi que em 1995, eu apresentei um slide no COBID, e eu disse assim olha "precisamos abandonar a era dos dados, precisamos entrar na era da informação, precisamos gerar conhecimento.

E lá na época eu ainda usava um slide que dizia assim "nós tínhamos um combustível fóssil que era o petróleo e o combustível agora é a informação". E hoje o professor Guilherme falou que não, que o combustível é o dado, então aí conversando com o professor Ricardo ele me corrigiu, não os dados são a energia, porque a energia não acaba, diferentemente do combustível fóssil como o petróleo.

Então nessa época em 1995 eu tive a ousadia de falar para abandonar os dados, porque na época trabalhávamos com documentos e a característica da área era o tratamento do documento, e nós tínhamos que pôr na cabeça dos formandos que tínhamos que sair da era do documento e entrar na era da informação.

Mas o dado era visto até então como uma coisa sem sentido, ela era um conjunto de coisas e essas coisas não tinham significado, era assim que a gente via em 1995.

Em 1999 eu tive a oportunidade de conhecer uma pessoa que está na plateia que fez eu descobrir que os dados iam além dos conceitos apresentados na CI, que foi o professor Ricardo. O professor Ricardo me deu a oportunidade de conhecer a estrutura dos dados dentro de um contexto, e nesse sentido e caminhando muito hoje conversando com pessoas que fizeram parte deste evento e estão aqui na plateia, nós estamos tentando mapear os bibliotecários brasileiros que estão atuando nas atividades de coleta, tratamento, armazenamento, uso e reúso dos dados de pesquisa.

Então vocês tiveram a oportunidade de conhecer o professor Pedro, tem aqui o professor Guilherme que já apresentou dados de outros pesquisadores, o professor Ricardo que já está trabalhando com o conceito de ciclo de vida já há bastante tempo, e eu, e também tem o professor Marcelo da USP, e nós conseguimos construir um questionário para ser aplicado aos bibliotecários para mapear, da mesma forma como o professor Guilherme fez com os pesquisadores, a gente quer fazer com os bibliotecários para mapear o que está sendo feito na gestão dos dados.

Então veja, eu que em 1995 falava vamos abandonar os dados, agora eu falo por favor não abandone os dados, traga os dados para o presente, para nosso uso diário. Eu acho fantástico é a oportunidade que a gente tem de saber que as coisas são dinâmicas, e em 1999 depois que tive a oportunidade de conhecer o professor Ricardo, nós estamos no período do bug do milênio, e tudo o que a gente falava era o que vai ser, quem será o profissional da informação do século 21, e aí eu trouxe uma transparência que eu costumava apresentar dizendo assim, quem será o profissional da informação do século 21.

Eu coloquei em destaque as coisas que ainda são necessárias para o dia de hoje, quem é o profissional que vai trabalhar com a gestão de dados, é aquele que tem capacidade de comunicação, que consegue contextualizar os dados, viram a interferência do conhecimento do outro no compartilhamento? Lembra que em 1995 eu disse para abandonar os dados e 1999 eu disse que tem que ter a capacidade de contextualizar os dados.

A oportunidade da troca, conhecimento é uma coisa que a gente multiplica conforme troca. Então eu tive a oportunidade de aprender que o profissional da informação trabalha com dados e deve contextualizar os dados nessa época, e ela está em constante evolução, ética e flexibilidade.

No começo dos anos 2000, eu tive a oportunidade de participar, aqui na Paraíba, de um evento sobre ética da informação, vocês devem lembrar disso, e aí nessa época eu tive a oportunidade de publicar o primeiro artigo sobre dados em 2002 na revista DataGramaZero. Então justamente com o professor Ricardo nós começamos a ver a importância dos dados em determinado contexto no ambiente da CI.

Nesse evento de ético, eu trouxe as 6 propostas de Calvino, o que a pessoa deveria considerar para o século 21, e aí eu trouxe essa proposta para o profissional da CI, porque era uma época em que a questão das tecnologias estava ficando muito forte na Ciência da Informação, e houve uma divisão, que eu sei que já não há hoje, em que defendem e os que odeiam a tecnologia, que era muito presente naquela época, agora hoje não.

Naquela época era necessário manter uma leveza nos relacionamentos, era necessário perceber que as tecnologias impulsionaram um tempo em que a gente precisa fazer muito mais

em menos tempo, era necessário uma exatidão sobre onde você quer chegar, e uma exatidão na contextualização dos dados disponíveis e nas informações disponíveis para que não houvesse conflito na forma e na abordagem.

Era preciso uma visibilidade, quando não há visibilidade nas formas de representação, é isso que a gente faz com nossos dados quando eles estão em nossos armários, eles não tem visibilidade nenhuma, eles não podem ser replicados e nem comparados, mas também nos mantém seguros, puxa quando eu vejo meus dados eu penso que porcaria eu tinha feito aqui, poderia ter feito diferente, mas eles não estão visíveis então eu corrijo e eu mesmo ajuste.

Então precisamos pensar multiplicar as formas de disponibilizar os dados. Por último, é preciso promover a consistência, garantir a integridade e a completude da consistência e no instanciamento dos dados. Isso falávamos no início dos anos 2000.

Mas em que contexto isso tudo acontece, onde nós vamos parar com essa questão dos dados, porque fomos parar no quarto paradigma, o que aconteceu na história da humanidade.

Então eu trouxe aqui as ondas significativas de evolução desde a revolução industrial, e nós podemos perceber que as ondas de evolução eram longas, agora são mais curtas e estão se interconectando. Existem modificações que estão ocorrendo ao mesmo tempo, e o quarto paradigma acontece aqui onde tudo está acontecendo, as redes, a biotecnologia, a sustentabilidade, muita coisa que depende do uso de dados.

Interessante é saber também com se dá a questão da presença, porque quanto mais a gente explica e mais simplifica, e cria modelos conceituais e tratamento de dados muito efetivo, mais a questão da presença vai se distanciando, quantos de vocês já recebeu uma ligação e tem a certeza que está conversando com uma pessoa.

Não é, é uma máquina, e eu defino sua voz, se vai ser homem ou mulher, e você fica respondendo achando que tem um sujeito ali do lado. Tem, mas um sujeito não humano. Por que, as relações que se davam de modo presencial estão concorrendo para acontecerem de modo não presencial, a presença está sendo cada vez mais substituída por uma presença não humana.

Bom, onde é que nós entramos? Viram que eu disse que lá no meio das nossas ideias a gente tem um insight, ah vou fazer isso e ver o que acontece. Tem um bibliotecário que me ajudou muito nesse final de semana, eu falei pra ele fazer um levantamento para saber onde é que tem o termo "dado" nos periódicos da Ciência da Informação.

Na base de dados sucupira nós localizamos 72 títulos da Ciência da Informação, 20 estavam fora do ar e 52 nós consultamos para tentar identificar onde existe o termo dados nos artigos. E aí nós descobrimos que há uma incidência muito grande nos Estados Unidos, nas revistas Qualis A1, e quando o termo dado foi usado na Ciência da Informação pela primeira vez: 1950 nos Estados Unidos, 1951 na Alemanha e no Brasil pela primeira vez em 1989 num artigo da área da Ciência da Informação.

Aqui nós temos as revistas que mais utilizam o termo dados em seus artigos e nos identificamos a revista Information Science e no Brasil é a revista Pesquisa Brasileira em Ciência da Informação e Biblioteconomia. E no Brasil em 1989 foi a revista Transinformação, foi o primeiro periódico no Brasil, sem considerar os que estavam fora do ar. A Transinformação é da

PUC, e o primeiro curso de Pós-Graduação em Ciência da Informação foi lá no IBICT e na PUC. Então em 1989 já falávamos de dados lá em determinado contexto.

Com todas essas informações eu trouxe essa figura que tem acompanhado muitas apresentações da Biblioteconomia e da Ciência da Informação e do profissional de dados, bibliotecário de dados, pesquisador de dados, que é um diagrama que mostra se o bibliotecária se sente com competência e habilidade para oferecer uma pesquisa de dados de pesquisa.

E as perguntas são etapas de um ciclo de vida dos dados. E o bibliotecário se pergunta se é mesmo uma prioridade um serviço de dados de pesquisa, em que nível eu estou na participação dos dados, qual o nível de envolvimento de metadados, há um padrão de pesquisa, há regras para descoberta de dados pelos bibliotecários, em cada uma das etapas

A gente se encontra em um momento oportuno em que não há limites do que você pode e não pode fazer. Aquela habilidade da computação podem ser extrapoladas, o profissional da informação não precisa estar contido naqueles elementos apresentados ali pela tabela de classificação das profissões, ele pode ir além porque existe uma demanda social para isso.

Então nós estamos em um momento oportuno de reaprender, reequilibrar e reinventar, em um momento em que é necessário aprender a partir do pensamento crítico, fazer a partir do pensamento criativo, e conviver a partir do pensamento colaborativo.

Não temos condições de trabalhar em equipes isoladas, de profissionais que são mais ou menos, nós temos que atuar com um envolvimento colaborativo. É preciso aprender a ser, ter habilidade para inventar e reinventar.

Ainda em 2000, eu dizia que tínhamos alguns desafios que acontecem até hoje. Em 2015 eu dizia, sabe as tecnologias, que tem uma parte que ama e outra que odeia, é uma favorecedora das rupturas, é uma garantia de possibilidades, as rupturas nos trazem possibilidades, e possibilidades que envolvem pessoas, dados, tecnologia, conceitos, concepções e a capacidade de reinvenção.

Aprender a aprender, a identificar o contexto, a utilizar instrumentos, é uma necessidade tanto do pesquisador quando do profissional da informação em compreender melhor os dados disponíveis.

Em 2015 continuamos trabalhando professor Ricardo e eu, e publicamos um texto falando sobre o conceito de dados, como uma unidade de contexto necessariamente relacionada a um determinado contexto e composto por entidade-atributo-valor. Ao conseguir sistematizar isso, conseguimos perceber a importância dos dados na Ciência da Informação, foi possível notar que temos que trabalhar com isso, temos que trazer a questão dos dados para a Ciência da Informação.

E em 2002, tínhamos muita dificuldade em fazer com que o profissional da informação aceitasse o papel dos dados dentro da Ciência da Informação, e tínhamos discussões bem acirradas entre o nosso próprio grupo de pesquisa.

Em 2013 o professor Ricardo organizou um evento que foi o precursor deste evento aqui, que foi o DTI lá em Marília, e a gente teve a oportunidade de fazer com que o professor Guilherme participasse e foi um evento muito legal, foi uma sementinha colocada aí.

Mas aí qual foi a nossa surpresa, foi quando um dos convidados, colega de grupo, disse eu não sei o que estou fazendo aqui porque eu não trabalho com dados. Por isso nós sofremos muito para instalar essa coisa dos dados na Ciência da Informação.

O que a gente tem pra hoje? Temos uma superposição de atividades, como esforços na coleta, na manutenção dos dados, e temos um grande problema na vulnerabilidade dos dados disponíveis, e isso precisa ser resolvido. Um profissional da informação como atuaria nesse contexto? E aí eu estou chamando de profissional da informação aquele lá do contexto da tabela ocupacional. Ele atuaria no apoio dos pesquisadores, no gerenciamento, compartilhamento, orientação, treinamento prático para elaboração do PGD, elaboração de citação de dados, como vincular com a publicação, etc.

Para isso nós temos algumas exigências e desafios. Aprender sobre os princípios da gestão dos dados de pesquisa, identificar problemas, firmar parcerias, preparar material para capacitação, favorecer a construção do conhecimento e estabelecer diretrizes de metadados, outro tema delicado ainda hoje, tanto para documentos, recursos como principalmente para os dados.

Aí nós temos uma exigência, que foi a fala apresentada pela bibliotecária Maria José, nós temos um desafio e uma exigência, que é formar profissional da informação com experiência na curadoria de dados de pesquisa, de forma com que os bibliotecários assumam novos papéis, porque às vezes o profissional ele quer fazer mas como se ele não teve a orientação.

Então eu trago como fazer, e o professor Guilherme disse para aprender Inglês. Aprendam Inglês, se está com a dúvida fazer a pós-graduação ou aprender Inglês, primeiro aprenda o Inglês. Sabe por que? É uma informação de 2012, a Universidade de Edmond fez um curso para bibliotecários e pesquisadores, e nesse curso os tópicos abordados eram esses que a gente está debatendo agora no final de 2018.

Ah, mas eu não tenho condições de ir para a Universidade de Edmond, acesse seu computador e acesso o Mantra, que é muito legal e está na Internet, é um projeto velho, olha aqui, quem é esse sujeito, é um profissional da informação, é um membro da equipe que trabalha nos projetos de gestão de dados de pesquisa.

Aqui tem todos os módulos que você precisa, é de graça mas é inglês, e não tem nada em Português. Então nós temos um mundo de possibilidades em que o bibliotecário pode conquistar diversos papéis até mesmo de liderança, os bibliotecários e a biblioteca enquanto instituição pode ocupar um papel de liderança na orientação sobre projetos de gestão de dados.

E quais são os requisitos? São alfabetização e capacitação na manipulação dos dados, enfocando as habilidades de pensamento crítico, resolução de problemas, interpretar e avaliar dados, e conhecer padrões.

Para tudo isso se faz necessário uma parceria colaborativa entre os profissionais da informação e os pesquisadores. Aí eu trouxe para vocês a título de ilustração, a Boston Data Library, é uma das mais antigas do mundo, ela tem uma biblioteca de dados. Então não importa se é novo ou velho, importa o quanto você reinventa.

Por último eu trouxe um bibliotecário que diz que é preciso que a capacitação e alfabetização de dados tenha um lar, por que essa casa não pode ser a biblioteca? Muita gente não concorda

mas ele diz que pode ser, e que depende do profissional e de como essa instituição pode ser reinventada.

Essas são as referências, e muito obrigado.

Vídeo da apresentação

Título: Dados de pesquisa e o profissional da informação.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=35

A Ciência da Informação e os dados de pesquisa

Information Science and research data

Luana Farias Sales Marques[a]

Transcrição da apresentação

Obrigado Guilherme pela apresentação, obrigado pelo convite, estou muito feliz de estar aqui, adoro essa terra e falo para todo mundo isso. Então agradeço o convite pois fiquei super empolgada desde o primeiro momento em que o Guilherme me falou, e agradeço ainda mais por esse tema que o Guilherme sugeriu, porque me deu a oportunidade de rever, assim como a professora Plácida falou que voltou lá nos arquivos antigos, eu também acabei fazendo um mix das coisas que eu venho falando mas de uma forma de repensar e reconfigurar aquele conhecimento que a gente vem desenvolvimento, eu, o professor Sayão e o nosso grupo de pesquisa. Eu coloquei aqui o nome de todos deles, depois se alguém quiser participar e interagir com a gente tem e-mail aqui.

Eu preparei uma agenda, porque assim, a Ciência da Informação apesar de ser uma área pequenininha a gente tem um mundo de coisas para estudar. Então eu fiquei pensando no que eu vou falar sobre Ciência da Informação nas pesquisas, é muita coisa, como é que eu vou fazer esse recorte, como eu vou organizar isso.

Pensei bem e decidi organizar isso pelos GTs da ANCIB porque é a nossa organização das pesquisas em Ciência da Informação no Brasil, e aqui gente nós temos os nossos GTs. E eu agradeço a oportunidade ainda porque ontem quando saí daqui o pessoal achou que fomos passear mas não ontem eu estava tendo ideias, vocês vão falando aqui e a gente vai tendo ideias o tempo todo.

Eu queria trazer para vocês, como a gente está num ambiente de pós-graduação, perspectivas de estudo, trazer um monte de questões, questões que podem passar por todos os GTs da ANCIB, porque eu sei que aqui não deve ter pessoas só do GT8, eu mesma originalmente sou do GT2, de Organização do Conhecimento, agora estou interagindo com o pessoal do GT8 de tecnologia e com o de Comunicação Científica, e no meio de tanta coisa tentando organizar essas ideias e eu espero que vocês gostem e que a gente consiga aprender um pouquinho junto, porque eu estou no aprendizado também.

Então eu preparei uma agenda, um sumário da minha apresentação, eu vou começar falando primeiro do nosso lugar, mas é porque eu achei importante entender o que eu estava compreendendo por Ciência da Informação, porque eu sei que vocês estão estudando Ciência da Informação aqui na Federal da Paraíba.

Escolhi um autor para a gente partir dele, escolhi um clássico para definir. E depois o que são dados de pesquisa? Dados de pesquisa podem ser diversas coisas, então nós optamos por trazer uma definição também para falar um pouquinho nessa apresentação sobre os dados de pesquisa. Depois eu faço uma relação entre os dados de pesquisa e publicação científica, para a

a Universidade Estadual Paulista (UNESP). E-mail: placida@marilia.unesp.br. Currículo: http://lattes.cnpq.br/7408791408049766

gente compreender um pouco essa relação. Depois a gente apresenta um pouco da problemática dos dados de pesquisa. E aí a gente fala da Ciência da Informação no Brasil, às perspectivas de estudos, e os dados de pesquisa nesse passeio pelos GTs da ANCIB.

Eu escolhi uma frase do Borko que é uma definição que gente trabalha muito na Ciência da Informação do IBICT, e eu destaquei aqui uma parte importante da fala dele onde ele define a Ciência da Informação como aquela ciência que está preocupada em como este conhecimento relacionado a origem, correção, organização, armazenamento, recuperação, interpretação, transmissão e utilização da informação, e diz ainda que envolve pesquisas em representação da informação, uso de códigos para transmissão eficiente da mensagem, bem como o processamento das técnicas aplicadas aos computadores e sistemas de informação.

É bem o que a gente está estudando agora só que estamos falando ed dados de pesquisa, e a gente vai ver um pouquinho também desse caminho, dos dados até o conhecimento, o dado que se transforma em informação e a partir da informação a gente tem o conhecimento.

A definição da informação a gente trabalhou com outro clássico de Belkin e Robertson que dizem que a informação é tudo aquilo capaz de transformar estruturas, e o Buckland que apresenta três perspectivas da informação. Buckland fala da informação como processo que é o ato de transformar alguém, a informação como conhecimento que é aquilo que a gente percebe quando se sente informado, e a informação como coisa, que é a informação registrada e representada de alguma forma.

Eu trouxe também essa definição aqui de Belkin e Robertson onde eles falam que um texto é um conjunto de signos organizados por um emissor com o objetivo de mudar a estrutura da imagem do receptor. A gente compreende que um texto é um conjunto de signos organizados, e a gente vê que o signo é o significante que assume um significado, e isso é informação, a informação é o dado organizado, que é o dado mais o metadado.

A gente pensa que um conjunto de signos organizados se transforma em informação quando ele modifica a estrutura cognitiva do receptor, isso é o que a gente está compreendendo como dados. Então os dados é um conjunto de signos e para ele se transformar em informação ele precisa ser representado, organizado, ou seja, precisa de metadados, de ontologias, ele precisa de estrutura.

Afinal o que é dado de pesquisa? Segundo Christine que é uma pessoa muito citada quando a gente fala de dados de pesquisa, e ela fala assim, informação é um conceito complexo com dezenas de definições, já o dado por sua vez é um conceito simples, com poucas definições mas sujeito a muitas e diferentes interpretações.

Atribuir uma definição processual a dados de pesquisa é um fato idiossincrático que pode dizer muitas coisas diferentes para pessoas e coisas diferentes. Isso acontece porque o dado de pesquisa é independente de interpretação.

Tudo pode ser dado de pesquisa dependendo do conceito e da pessoa, e ele pode se configurar em formas muito diferentes. Aqui a gente traz um exemplo, uma sequência de bits provenientes de um sensor sísmico é dado de pesquisa para os sismólogos, às amostras de rochas podem ser dados de pesquisa para as geomorfológicas, às conversas gravadas são dados de

pesquisa dos sociólogos, então o dado de pesquisa é independente de interpretação e pode dizer muitas coisas diferentes para pessoas e circunstâncias diferentes.

Aqui a gente tem outro exemplo, um unicórnio por exemplo, pode ser dados de pesquisa para um ambientalista e também pode ser dado para um arqueólogo, e aí a gente começa a ver essa habilidade de reúso.

Os dados sísmicos também podem ser dados para os biólogos, e os dados são sempre tratados tomando como base algum interesse ou perspectiva e a prática que determina seu significado e sua prática em distintos contextos.

A gente trata por meio de metadado, ela é a base da representação, a forma de tratar o dado vai ser completamente diferente da forma como a gente representa a informação. Quando a gente pensa em informação a gente pensa naquela coisa já registrada, artigos de periódicos, os livros, que já tem um contexto e uma estrutura. É muito simples a gente tratar um livro ou uma obra bibliográfica que você tem lá todo tipo de data, agora como a gente faz o tratamento desse dado de pesquisa?

Dos dados de pesquisa a informação científica, entendendo um pouco essa relação. A informação científica e tecnológica eu trouxe aqui uma definição compreendendo isso, é aquela informação que serve como insumo para atividade de pesquisa ou tecnológica, e ela resulta resultados de atividades científicas. Eu gosto de falar sobre isso porque como a gente está falando de dados, eles aparecem em diversos contextos por exemplo Big Data, mas nós estamos falando sobre um dado específico que é o dado produzido sob resultados de pesquisa, que é diferente de você tratar dados comerciais e a gente tem que entender um pouco isso.

A informação científica ele serve para divulgar conhecimento novo obtido a partir de uma pesquisa científica, ela serve como insumo para novos projetos de pesquisa, serve para explicitar a metodologia empregada nos processos de pesquisa. Então os dados vão ser uma forma de você documentar e transformar aquele conhecimento produzido dentro dos laboratórios em uma informação científica.

É importante a gente lembrar de uma coisa, os dados de pesquisa eles são tanto insumo quanto produtos da pesquisa científica, a gente tem tratado muito dado como insumo mas a gente esquece que ele também é produto, e ele passa por diversas transformações. Eu costumo dar exemplo no trabalho com pesquisa na área nuclear, a gente lá um domínio da realidade virtual e eu tinha dados que eram diferentes, o dado que o cara coletava filmando às atividades do pesquisador dentro do reator, duvido que ele tenha um resultado que é o vídeo em 3D. Assim você tem os estágios de tratamento do dado que também era diferente.

Então você tem o movimento em que o dado é capturado, esse dado já passa por uma curadoria, e você tem os dados que depois são transformados a partir dessa curadoria, dessa análise. Sabia como dados, informações e conhecimento são definidos é saber quais são as formas de transformar dados em conhecimento, eu queria definir isso com vocês.

Dados representa fatos desorganizados ou processos. Já informação é uma agregação dos dados processados. O conhecimento é a compreensão humana sobre o assunto adquirido sobre o estudo ou experiência. Os dados também geralmente são de natureza estática, já a informação possui algum significado e propósito, como falei a informação é o fato mais o metadado, a

representação. Então a gente fala de representação de um dado que já tem uma representação e consequentemente um significado, e é representado para algum propósito específico.

Já o conhecimento é baseado na aprendizagem, e compreensão do problema, é a interpretação que a pessoa faz com essa informação. O dado pode representar um conjunto de fatos sobre eventos, já a informação precisa de um contexto, para o dado se transformar em informação eu preciso ter isso contextualizado. O dado é pré-requisito para que haja informação, já a informação é pré-requisito para que haja conhecimento.

Um exemplo, 45%, se eu falar apenas isso eu tenho um dado, mas 45% está relacionado a que? Ah, 45% da população consome doces e frituras, aqui eu já tenho a informação que é o dado contextualizado.

E aí o conhecimento é o que? 45% da população não é saudável, é a inferência que eu fiz aqui com a informação que eu recebi a partir do dado que me foi dado. A gente tem outro exemplo, os dados como caracteres ou imagens como atributos de um fenômeno, eles vão se transformar em informação quando combinados de maneira em potencial de regular padrões sobre um fenômeno. E o conhecimento é um sistema de inferências não triviais e verdadeiras acerca de um fenômeno. Aqui eu tenho os números medindo a altura de uma montanha, esses números são os dados, e aí eu tenho a fórmula que vai dizer que a altura do pico pode ser deduzida a partir dos dados se transformando em informação. Eu combino essas informações e aí eu tenho o conhecimento de que às rochas da montanha.

Aqui para falar sobre a problemática dos dados. Os dados com essa zona, o estudo a pesquisa sobre dados de pesquisa está uma zona, a gente ainda não sabe como vai organizar isso, eu fiz uma proposta de levar para um DT da ANCIB, porque a pesquisa em Ciência da Informação se dá através de programas de pós-graduação e o país possui uma instância de representação científica e política importante para o debate que é a ANCIB, e a ANCIB atua em duas frentes, nos programas de pós-graduação e no encontro de pesquisa através dos GTs.

A temática dos dados de pesquisa pode ser estudada sob vários aspectos, escolhemos a abordagem sob a perspectiva dos GTs. Aqui como falei para vocês são 11, e começaremos então essa organização por GTs.

O GT1 é o GT que trata dos estudos históricos e epistemológicos da Ciência da Informação e essa é a ementa. Eu levante algumas perspectivas de estudo que me veio na cabeça, mas talvez vocês analisando a ementa encontre outras questões. Eu percebi olhando aqui que nós estudar a epistemologia dos dados de pesquisa, quais dados de pesquisa são conceituados a medida com que são gerados, a gente precisa estudar a história dos dados e das bases de dados na Ciência da Informação, o conceito de dados de pesquisa, a cadeia dado-informação-conhecimento como eu mostrei, a necessidade de tratamento interdisciplinar de dados de pesquisa e a possibilidade de reúso.

É importante a gente compreender a partir da perspectiva da epistemologia da Ciência da Informação como os dados se originam para poder compreender a história dos dados, em uma determinada apresentação a gente criou essa definição para dizer que os dados podem ser observacionais, isso é só uma abordagem de classificação, tem diversas.

A gente classificou aqui os dados quanto a sua origem e percebeu que o dado pode ser observacionais como aqueles gerados através da erupção de um vulcão, eles são críticos porque não tem como reproduzir essa pesquisa e o levantamento desses dados. Então eles precisam ser armazenados e a gente tem um problema crítico aqui, os dados podem ser também experimentais, provenientes de situações controladas em laboratórios, e os dados podem ser computacionais.

Aí vamos ter algumas barreiras disciplinares para tratamento e organização desses dados, porque cada dado vai se manifestar de forma diferente de acordo com sua área e com o contexto de pesquisa, de acordo com a metodologia utilizada.

A professora Plácida mostrou aqui, os dados podem ser números ou diversas naturezas, o que é diferente de tratar um documento bibliográfico. E esses dados podem ser facilmente reutilizados em contextos diferentes, os dados podem ser reusados e transportados através mix setoriais, podem ultrapassar limites disciplinares.

Algumas perguntas: O que é um dado de pesquisa? Qual o valor dos dados na pesquisa contemporânea? Isso é importante a gente investigar, eu pus algumas dicas de pesquisa para vocês. Como os dados podem alimentar o interdisciplinar? E aí então nós entramos no GT2, que é meu GT de origem.

O GT2 estudo teorias, metodologias e práticas relacionadas à organização e preservação dos documentos e da informação enquanto conhecimento registrado em ambientes informacionais tais como arquivos, museus, bibliotecas e congêneres. Compreende também os estudos relacionados aos processos e produtos de representação do conhecimento e às relações inter e transdisciplinares verificadas. Então a perspectiva desse estudo eu levantei que é a curadoria de dados, que nada mais é que tratamento e representação do conhecimento, a gente às vezes confunde o conjunto de curadoria com o conceito de gestão mas é diferente, a questão da organização dos dados e da representação temática desses dados de pesquisa.

Aí então às pesquisas de metadados, taxonomias, vocabulários, e uma questão nobre que surge aqui é às anotações de dados, que são às anotações dos pesquisadores enquanto estão fazendo experimentos da pesquisa.

Aqui para mostrar um pouquinho do ciclo da curadoria dos dados nós temos perspectivas de estudos sobre todas essas fases do ciclo da curadoria, os metadados ele tem um forte capacidade para dados digitais de transmitirem conhecimento e possibilitam que estes sejam interpretados e usados.

Aqui tem alguns exemplos de padrão de metadados, cada área vai ter seu padrão de metadado, aqui é uma área que não tem seu padrão de metadados mas vai ter que constituir, e o profissional da informação vai ser importante para isso, lembrando que são os profissionais da informação que estivemos na base de criação do Dublin Core e hoje nós temos por exemplo o Darwin Core que é um padrão de metadados utilizados na área de Biodiversidade e que está apoiado no Dublin Core e às outras áreas também vão ter que começar.

Ainda sobre o GT2 eu trouxe aqui um monte de questão. Que padrões de metadados e ontologias são necessários e adequados para tratar dados de pesquisa? Como integrar semanticamente dados e publicações de outros objetos digitais, e esse foi meu tema de Tese de

Doutorado quando estudei as publicações ampliadas. Você tem que dar semântica, dar contexto e definição para as relações e links. Quais os padrões de metadados utilizados para tratar os dados nos domínios disciplinares? Como visualizar e modelar os sistemas para recebimento desses dados? Como integrar semanticamente dados representados sob a perspectiva de domínios distintos, e isso é muito importante porque a gente está pensando no reúso dos dados para promover pesquisas interdisciplinares que é um tema tão importante para a Ciência da Informação. Que padrões utilizar para anotar os dados e permitir o processamento inteligente, porque o cara está anotando no laboratório mas está fazendo tudo sem padrão, e quando a gente criar as bases de conhecimento utilizando ontologia e a gente precisar processar esse conhecimento, essa linguagem precisa ser padronizada, precisa de um formato para essa anotação.

E a gente entra então no GT3, Mediação, Circulação e Apropriação da Informação, que estuda os processos e relações da mediação, circulação e apropriação da informação em diferentes contextos e tempos históricos, considerando sua complexidade e abrangência, bem como relacionado com a construção do campo científico da Ciência da Informação.

Perspectivas de estudos, a relação da Big Science e da Small Science e a geração de dados, são formas distintas de gerar dados científicos e que precisam se relacionar, o Sayão falou um pouquinho no primeiro dia dos dados gerados lá na cauda longa que são dados heterogêneos que precisam se combinar com dados lá da cabeça da ciência que é a Big Science para que a inovação seja gerada no meio da ciência.

Falei um pouco disso da Big Science e Small Science, essas duas ciencias precisam estar integradas para a geração de conhecimento, e reúso desses dados em contextos diferentes para gerar inovação. Isso é um ecossistema de dados, e nós temos às perguntas: Quais às diferentes na gestão de dados gerados pela grande e pela pequena ciência? Como vou integrar dados diferentes e gerar inovação? Quais dados devem ser preservados para sempre? Como avaliar o potencial de reúso de dados e estabelecer prioridade para coleções de dados. Na prática a gente gera tantos dados e às vezes não tem tempo, por isso precisa priorizar como estabelecer as prioridades.

GT4, que é o GT de Gestão da Informação e do Conhecimento, acaba sendo meu GT também porque eu estou muito na área de gestão do conhecimento nuclear, abre um parêntese, é a Ciência da Informação que trabalha com outro nome, porque para reunir um grupo de pessoas que tratassem dessas informações, mas para mim é tudo Ciência da Informação, e que lá eles chamam de gestão do conhecimento por conta das modalidades de financiamento internacionais.

Esse GT4 trabalha com ambientes, sistemas, ambientes, produtos de informação, estudos de fluxos e processos em ambientes de informação como instrumento de informação, gestão de conhecimento e aprendizagem informacional na Ciência da Informação, Marketing da informação, estudo de redes para gestão.

Perspectivas de estudo: gestão de dados de pesquisa como um viés para gestão do conhecimento, aqui a gente tem trabalhando lá na área nuclear na gestão de dados mas é um caminho para a gestão do conhecimento e a gente tem que entender isso, porque a cadeia dado-informação-conhecimento, sem o dado não chega até o conhecimento. Estudo e mapeamento dos fluxos de pesquisa nos laboratórios, documentar para criar memória da instituição,

compartilhamento de dados, curadoria digital como serviço de disseminação seletiva, é um tema que não gosto muito mas que está sendo usado muito na área da computação e agora na área de gestão que é o evangelismo de dados, que é você divulgar a importância da gestão dos dados e da curadoria. Curadoria de dados é isso e às pessoas ainda não conseguiram se conscientizar da importância disso. Apesar do nome esquisito o Guilherme e o Sayão dizem que vai se criando uma igreja universal dos dados, [risos].

Para fazer a gestão do conhecimento precisa-se fazer a gestão dos dados e da informação, o conhecimento é derivada da informação da mesma maneira que a informação é derivada do dado, e a gestão dos dados é uma parte essencial dessa gestão do conhecimento.

E quais são as questões que nós temos aqui. Quais as diferenças entre gestão de dados, gestão da informação e gestão do conhecimento, e como integrar esses processos? Como mapear os fluxos de dados e informação nos laboratórios? Quando a gente faz esse mapeamento das atividades de pesquisa dos pesquisadores é importante porque aí a gente vê onde os dados são gerados, onde esses dados estão sendo transformados, como eu apresentei no slide anterior os dados passam por estágios de geração. Eu tenho um dado gerado por um experimento científico que é o primeiro estágio da geração, aí esse dado passa por um processamento e se transforma em outra coisa, são os dados de segunda geração. Aí o pesquisador vai, analisa, e tira às conclusões, eu tenho dados de terceira geração, isso é muito legal para a gente saber como coletar os dados.

Os dados de pesquisa podem servir como um mecanismo de preservação do conhecimento das instituições? Gerenciar o fluxo de dados de pesquisa pode servir como um mecanismo de transformação do conhecimento tácito em conhecimento explícito?

GT5. É o GT de Política e Economia da Informação. Esse GT estuda às políticas emergentes de informação, propriedade intelectual, acesso a informação, poder e cidadania, ética da informação, informação e poder, agora olhando aqui já lembrei de outras questões. Quais as perspectivas de estudo: ambientes de geração de dados, humanidades digitais, e-Science, ciência da cauda longa, que são ambientes que geram dados de pesquisa, assim como a grande ciência e pequena ciência, que são outras formas de classificar esses ambientes de geração de dados. Políticas de gestão de dados, políticas nacionais, locais, políticas de repositórios, porque a gente fica sempre pensando na política nacional e quer que a situação venha de cima para baixa, mas podemos começar criando às políticas para repositórios. A questão da sustentabilidade na gestão dos dados, a criação de laboratórios e redes de colaboração de dados, ética no compartilhamento e no reúso, reúso de dados como mecanismo de economia de recursos.

Aqui como falei os dados de pesquisa existem para serem usados, então a gente tem que transformar esses dados em coisas que podem ser recusadas, se os dados de pesquisa não estão sendo reutilizados perdem o sentido por isso precisam ser estudados também.

Eu trago aqui que nem algumas questões de ética que precisam ser estudados, coletar, usar e compartilhar os dados em ambientes de pesquisa que envolva pessoas obrigam que condições éticas e legais sejam respeitadas, isso deve permear toda a pesquisa incluindo a fase de compartilhamento de dados. Nesse contexto também é importante estudar as diferenças dos

dados pessoais, quais são os dados confidenciais e como disseminar isso, dados sensíveis são outros tipos de dados que precisam ser estudados.

Aqui tem algumas questões: Como criar coleções de dados que atenda a necessidade de públicos específicos? Como se configura o regime de informação nesses ambientes de geração de dados, na e-Science, Ciência Aberta, na Ciência da Cauda Longa? Como garantir a sustentabilidade desses dados? Como se organizam às redes de colaboração e compartilhamento de dados? Como a curadoria de dados pode otimizar os investimentos de pesquisa?

E aí entramos no GT6, que entra um pouco no que a professora Plácida falou aqui a questão do perfil do profissional. A ementa do GT6 eles estudam competências, habilidades requeridas, sociedade do conhecimento, tecnologia e trabalho, saúde no mercado de trabalho e ética nas profissões de informação, formação do profissional em Ciência da Informação, paradigmas predominantes. Então coloquei como perspectivas de estudo esses cenários de geração de dados, e-Science, Ciência Aberta, Ciência da cauda longa, e os atores, quem são os atores que trabalham com esses dados? Qual o perfil do profissional que vai consumir os dados, que pode ter mais de um perfil de acordo com a área? Quem é esse bibliotecário, qual o perfil desse bibliotecário que vai trabalhar com dados, arquivista, profissional de TI, e aqui estão algumas questões tão importantes sobre competência e a gestão de dados.

Qual o perfil do profissional que vai trabalhar com esses dados? Qual o currículo mínimo para formação desse profissional? Nós temos diversos papéis nos dados de pesquisa, temos o papel do pesquisador, do bibliotecário de dados, são novas roupagens para as profissões tradicionais.

Nós temos também o cientista de dados como um papel novo que é o profissional da área de computação, a gente tem o gerente de dados que é o cara da TI responsável pela manutenção e criação de bases de dados. E tem o curador de dados, que pode ser o próprio pesquisador, o cientista da informação com conhecimento interdisciplinar que vai adicionar valor aos dados através da curadoria, representação, anotação, compartilhamento e reúso desses dados. E a competência com dados de pesquisa a gente vem trabalhando isso por conta da pesquisa de uma aluna que é a capacidade de ler, entender, criar e comunicar dados como informação. E como sendo às competências envolvidas no trabalho com os dados de pesquisa desde a coleta até o compartilhamento passando pela rotina de curadoria e tratamento de dados, nós pegamos a literatura e criamos uma definição própria porque partimos de algum lugar para começar nossos estudos.

E a questão da competência de dados, a gente tem duas questões super importantes, que é que habilidades de curadoria e gestão são necessárias para o pesquisador que desenvolve pesquisas no âmbito da e-Science? E como os bibliotecários podem aplicar seus conhecimentos de recuperação, disseminação e preservação da informação para ensinar essas competências para os pesquisadores. Então a gente tem que saber qual o conhecimento o pesquisador precisa, qual o conhecimento o bibliotecário precisa, e treinar esse pessoal.

Qual o papel do GT6. Aqui algumas perguntas: Qual o valor da competência informacional nos dados de pesquisa? Qual o papel do profissional da informação na gestão de dados e quais outros atores importantes? Qual o perfil do profissional para trabalhar com dados de pesquisa?

E aí a gente entra no GT7 que também é um pouco meu GT, agora que eu venho trabalhando muito pesado nas questões de comunicação científica, que estuda os estudos teóricos, metodológicos e aplicados sobre a produção e o uso da informação sobre ciência e tecnologia da informação. Inclui pesquisas relacionadas aos processos de comunicação e análise de indicadores para planejamento e avaliação de C&T.

Tem como perspectivas de estudo novos padrões de comunicação científica, a gente tem alteração no ciclo da comunicação científica, nova configuração do fazer científico que foi reformulada, antes tinha às hipóteses e depois íamos coletar os dados, agora nós temos os dados e a partir dos dados a gente observa e cria novas hipóteses. Nós temos novos modelos de publicação, publicação composta, publicação ampliada, e outros modelos como data papers, em que eu compartilho os dados e os metadados e indico nesses artigos o artigo que apresenta a pesquisa.

Temos os cadernos de laboratório, periódicos de resultados negativos, porque a gente precisa dar visibilidade a esses dados e temos estudado a questão da ciência invisível, que é a ciência que está sendo produzida nos laboratórios e ninguém tem conhecimento, tem uma pesquisa que diz que 50% dos achados da pesquisa não são publicados, quais os motivos para o pesquisador não compartilhar?

E aqui algumas questões, como promover visibilidade para esses dados de pesquisa, esses que estão lá na ciência invisível dentro dos pendrives ou no HD dos pesquisadores? Como se configuram os novos modelos de publicação e seu impacto na comunicação científica? A gente vai ter novos periódicos com avaliação por pares abertos, modelo aberto, e tudo isso vai reconfigura a comunicação científica porque não terá mais que esperar porque no futuro esse processo será importado. Hoje a gente começa a produzir uma pesquisa e a gente manda para a revista, e mesmo com toda a tecnologia e automatização ainda é lenta, porque precisa de uma revisão por pares. Como a gente também está do outro lado, quando você recebe um pedido de avaliação e às vezes a gente se enrola com outras atividades e acho que esse é um dos motivos. Como citar esses dados e garantir que o pesquisador receba créditos pelo compartilhamento? Às vezes o cara não quer compartilhar porque ele não vai ser citado, e existem normas e padrões para citação de dados, os bibliotecários da plateia precisa saber como citar esses dados para auxiliar os pesquisadores.

Aí a gente entra no GT8, nosso GT também que é o GT de Informação e Tecnologia, e estuda pesquisas teóricas para desenvolvimento de tecnologias de informação e comunicação, processos de recuperação, armazenamento, disseminação, uso, gestão, segurança e preservação e ambientes digitais. Nós temos aqui a questão dos dados de pesquisa e os metadados, os protocolos de pesquisa de campo, os processamentos de ontologia, processamento dos dados, repositórios e bases de dados, a gente volta com esse conceito de base de dados que ficou esquecido, a gente vem falando muito dos repositórios institucionais como se eles fossem resolver o problema dos dados e estamos começando a ver que não, ele é muito bom para por lá a produção científica e o Google fazer lá o processo de indexação. Quando a gente fala de bases de dados a gente precisa de ambientes específicos para que esses dados sejam recuperados, processados e transformados em conhecimento.

A questão das redes, da representação digital, da gestão dos dados de pesquisa, o armazenamento em nuvens, em quantidade como tera ou petabytes. Às aplicações e geração de novos serviços, muitas vezes os repositórios não estão sendo utilizados porque não tem serviços, então essas são questões a serem discutidas no GT8, e aqui eu já falei dos repositórios e bancos de dados científicos, a Sun Foundation já definiu em 2003 os repositórios como bases de dados científicos digitais para pesquisa e agora no futuro tendo como perspectiva primordial o acesso aberto que é considerado hoje patrimônio da humanidade. A primeira exigência para curadoria é o dado está disponível em um repositório ou base de dados.

Aqui alguns exemplos, como serviços de visibilidade aos dados, serviços de compartilhamento, reúso da informação, serviços de crédito ao autor, serviço de transparência a memória científica, segurança dos dados, outros tipos de serviços inovadores, interoperabilidade, redes de repositório, indicadores de qualidade e produtividade, para citar alguns.

Aqui nós temos algumas questões subjacentes a algumas plataformas de gestão de dados de pesquisa, Quais as tecnologias para promover a interoperabilidade entre as plataformas de gestão de dados? Como a tecnologia pode apoiar a criação de serviços para compartilhamento de banco de dados? Como garantir preservação a longo prazo aos dados em formatos digitais? Quais as tecnologias para armazenamento seguro de grandes quantidades de dados? Aposto que o Guilherme pensou em várias outras questões e vocês também, mas essas foram questões que vieram do meu insight.

E aí a gente vem para o GT9 – Museu e Patrimônio da Informação, que tem como ementa análise das relações no museu, patrimônio, bem simbólico, e informação como processo em múltiplas perspectivas teóricas e práticas de análise. Estuda museus e patrimônios de informação, criação e representações. A gente colocou aqui como perspectiva de estudo: curadoria digital de dados de pesquisa e os dados da pesquisa como patrimônio de ciência e tecnologia, como patrimônio da humanidade.

Eu trouxe isso daqui porque em um determinado momento a gente fez um estudo do termo curadoria e ele nasce na área de arquivologia e a gente usa por empréstimo. Acredita-se que os museólogos também tem a contribuir com a pesquisa de curadoria, é você criar coleções de dados e integrar o público específico. Antes das práticas acadêmicas se deslocarem para o meio digital, para o paradigma do Big Data, os museus de história nacional já tinham criado conceito de curadoria antecipando a demanda por gestão e aprimoramento dos dados digitais. Eu lembro das bases de dados de um museu que a um tempo atrás era em papel sobre primatas, eu busquei muito essa base durante o doutorado e não tive acesso a ela.

Eu trouxe como perguntas, quais as técnicas de curadoria utilizada em museus podem ser aproveitado na curadoria de dados? Como os dados de pesquisa podem configurar patrimônio para ciência e tecnologia.

Aí a gente entra no GT10 de Informação e Memória, que estuda a relação entre os campos do conhecimento e a Ciência da Informação na memória social, às pesquisas transdisciplinares que envolvem o conceito e prática da informação e memória, memória coletiva, coleções, discurso e memória, preservação da memória social. Quando eu falo que os dados e que a curadoria digital estão sendo estudados nesses GTs que eu recebi já no último GT para avaliar

sobre dados de pesquisa desses GTs, então tem material sendo produzido dentro desses grupos de trabalho.

Dados de pesquisa seria uma questão de estudo como memória da pesquisa científica, como memória institucional, então eu trouxe os dados de pesquisa como possibilidade da gente entender a memória da pesquisa científica.

A questão da preservação dos dados de pesquisa, mas como disse Sayão os dados de pesquisa são incompreensíveis e portanto sem uso a menos que haja uma descrição detalhada e clara de como e quando foram obtidos, e de como foram produzidos. Os dados de pesquisa não falam por sí só, e a gente tem uma interação entre os GTs, por exemplo, o GT de organização do conhecimento auxiliando na descrição desses dados para que eles realmente venham ser memória da pesquisa científica.

Perspectivas de estudo no GT de Memória, a questão da preservação, porque a informação digital não sobrevive naturalmente, a gente precisa trabalhar essa questão da preservação. A mesma tecnologia que muda a pesquisa científica coloca os dados gerados em risco como desafio estratégico, gerencial e político de criar, arquivar e tornar disponíveis esses dados. Mas aí tem outra questão, o que tem quer preservar, tem que preservar tudo? Aqui a gente tem uma complexidade crescente da preservação.

Como preservar esses dados de pesquisa considerando toda essa complexidade? Quando a gente fala de preservação vai para além dos metadados descritivos, a gente tem outros metadados que precisam ser considerados. Como incorporar os dados de pesquisa às memórias das instituições de pesquisa, por ser uma outra questão trabalhada.

E aí passamos para o último GT, o GT de Informação e Saúde que estuda as teorias e os métodos informacionais no contexto da saúde considerando a complexidade, estudo da tecnologia, informação e saúde, informação na representação da saúde, informação saúde e sociedade, políticas de informação em saúde, tudo que a gente tem aqui são da área da saúde.

Qual perspectiva de estudo, por exemplo, os dados de pesquisa com genética, e às peculiaridades próprias dos dados da área da saúde. E às perguntas, quais são as peculiaridades dos dados na área da saúde, os dados são gerados de forma diferente, são usados de forma diferente, então precisa ter um estudo específico sobre esses dados. Dados de pesquisa em saúde podem ser baseados em evidência? É uma questão que eu deixo.

Para chegar ao final, a organização da ANCIB em GTs auxiliou a ter uma visão global das pesquisas desenvolvidas no contexto do Brasil, a gente fez apenas uma análise superficial das temáticas abordadas, e a gente concluiu que as pesquisas sobre dados de pesquisa perpassa todas às áreas da Ciência da Informação. Isso revela o potencial das contribuições da Ciência da Informação para os estudos em dados de pesquisa e a solução de diversos problemas dentro dessa temática.

Eu lembrei aqui também quando falei do GT de saúde, que eu acho assim, é uma sub interdisciplinaridade, porque a Ciência da Informação já é interdisciplinar mas é preciso ter trabalho em conjunto desses GTs em que a ANCIB é organizada.

Então é isso, não sei se falei muito rápida, se foi bom para vocês, estou aberta a perguntas e discussão.

Vídeo da apresentação

Título: A Ciência da Informação e os dados de pesquisa.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=36

A questão da identidade da Ciência da Informação frente aos cenários apresentados do paradigma dos dados

The question of Information Science identity in relation to the presented scenarios of the data paradigm

Sandra de Albuquerque Siebra[a], Ricardo César Gonçalves Sant"Ana[b], Plácida Leopoldina Ventura Amorim da Costa Santos[c] e Luana Farias Sales Marques[d]

Transcrição da apresentação

Abertura:

Boa tarde, vamos para nossa última atividades de exposições e debates, com a mesa redonda intitulada "A questão da identidade da CI frente aos cenários apresentados do paradigma dos dados". Para tanto, convidamos para compor essa mesa a professora doutora e professora da Universidade Federal de Pernambuco a professora Sandra Siebra; do Programa de Pós-Graduação em Ciência da Informação da UNESP, professor Ricardo Sant'Ana; também do PPGCI/UNESP professora Plácida Santos; completando a mesa da Comissão Nacional de Energia Nuclear e do IBICT professora Luana Farias Sales.

Sandra:

Com as instruções que Guilherme me deu, gostaria de fazer alguns comentários e algumas provocações a alguns colegas, ele me pediu para dar a vocês uma breve fala sobre a temática abordada, que é a questão da identidade da Ciência da Informação frente aos novos cenários apresentados pelo paradigma dos dados, e depois a gente entra nessa nossa conversa da mesa redonda. Vou começar com Plácida.

Plácida:

Obrigada por fazer parte dessa mesa, obrigada pela organização por permitir isso, obrigada Sandra por conduzir esse trabalho, e obrigada por vocês estarem aqui logo depois do almoço, porque é difícil a gente conseguir almoçar todo mundo, bater um papo que é uma das partes mais profícuas do momento que são às reuniões dos cafés, do almoço, dos bates papos que a gente consegue ter somente naquele momento. Por vocês estarem aqui gera para nós uma grande responsabilidade, especialmente quando a gente vai falar da identidade de um profissional de uma área do conhecimento no caso da área da Ciência da Informação.

E por falar disso, eu me dou o direito de relatar um pouquinho aqui a experiência que eu tive como formadora na área da Ciência da Informação ao longo dos anos, desde 1983 que eu

a Universidade Federal de Pernambuco (UFPE). E-mail: sandra.siebra@gmail.com. ORCID: https://orcid.org/0000-0002-0078-6918. Currículo: http://lattes.cnpq.br/4923627544089379

b Universidade Estadual Paulista (UNESP). E-mail: ricardo.santana@unesp.br. ORCID: http://orcid.org/0000-0003-1387-4519. Currículo: http://lattes.cnpq.br/1022660730972320

c Universidade Estadual Paulista (UNESP). E-mail: placida@marilia.unesp.br. Currículo: http://lattes.cnpq.br/7408791408049766

d Centro de Informações Nucleares (CNEN). E-mail: lsales@ien.gov.br. ORCID: https://orcid.org/0000-0002-3614-2356. Currículo: http://lattes.cnpq.br/9090064478702633

venho trabalhando na área da Ciência da Informação. Ao longo desse caminho longo eu percebi algumas ações dentro da área especialmente na questão da formação do profissional, e algumas alterações que aconteceram no desencadeamento da formação profissional e algumas situações que geraram alguns desconforto, e depois uma estabilização profissional. Uma delas é provocada pela característica da área por ser interdisciplinar e multidisciplinar, isso significa que nós nos relacionamos, nós convivemos e procuramos trabalhar com diversos profissionais, ou trabalhar para esses profissionais ou trabalhar com esses profissionais.

Na minha história de atuação na Biblioteconomia e na Ciência da Informação eu percebi dois momentos marcantes. Um deles aconteceu nos anos 1980, no início da minha vida profissional como formadora. Havia nesse momento a inserção muito grande de profissionais de outras áreas que não da Biblioteconomia, Arquivologia e Museologia, mas havia uma inserção muito grande de profissionais da Letras, Linguística, História, e das Artes. Esse momento dos anos 1980 aqui no Brasil houve um desconforto profissional, em que o profissional da área se sentia acuado ou desconfortável achando que tudo que estavam fazendo não era bom, porque a concentração de outras áreas gerava esse desconforto.

Houve nesse momento uma crise de identidade que alguns aqui devem lembrar do animador cultural, não sei se vocês vivenciaram isso mas nós tivemos na área a figura de animador cultural. Eu tive muitos alunos que terminavam o curso e faziam concurso para bibliotecário das bibliotecas públicas do interior do estado de São Paulo, e eles se incumbiam mais com as questões que não fazia parte da instituição biblioteca mas com as questões culturais da cidade, no interior do estado de São Paulo às festas de rodeios. E uma das vezes eu peguei ex alunos super ansiosos porque naquele momento eles estavam fazendo doce caseiro, organização de feira, e eu falava e o trabalho na biblioteca, e eles diziam que o trabalho hoje em dia era a animação cultural. E aí todo mundo que procura um bibliotecário que algumas coisas muito claras, ele quer saber onde está a informação, como é armazenada e como é que eu recupero, e não é na festa de peão de boiadeiro que você vai aprender fazendo doce caseiro, então espera aí, vamos voltar porque havia uma confusão e desestabilização no que estava organizada.

Foi em uma época que os bibliotecários deixaram para um segundo momento todas as atividades técnicas, o sujeito que estava envolvido com atividade técnica era um sujeito menor. Então a catalogação, indexação, e outras atividades técnicas passou para segundo plano e ninguém queria fazer isso.

Depois de uma década, final da década de 90 e começo dos anos 2000, as tecnologias começam a entrar fortemente na biblioteconomia, no sistema de gerenciamento de bibliotecas, e na Ciência da Informação no setor de tecnologia. E no final dos anos 80 eu tive a oportunidade de receber como parceira no departamento a professora Silvana Vidotti e nós construímos um grupo de informação e tecnologia, e foi uma grande discussão trazer as questões tecnológicas para o interior da Ciência da Informação.

Trazer às questões tecnológicas para interior da Ciência da Informação sem perder a consciência da Ciência da Informação, e perceber que a análise de software em gerenciamento de biblioteca passava pela função primária da biblioteconomia que eram aqueles procedimentos que tinha sido deixado de lado como menor, a catalogação, a classificação, indexação, estruturas que

permitiam o processamento por máquina, estruturas que vinham apesar não terem sido desenvolvidas para computadores já traziam lá na construção dos códigos de catalogação elementos que eram algoritmos: se tiver mais de 3 autores faça assim, se tiver tradutor utilize tal coisa, se às informações forem para bibliotecas infantis, públicas ou especializadas defina um nível de catalogação.

Veja que essa estrutura é a estrutura do código de catalogação, ele não foi feito para ser utilizado na linguagem de máquina mas ele já tem uma estrutura de máquina. Às áreas primárias ou core da biblioteconomia foi chamada novamente e nós tivemos aí a partir do núcleo a percepção da renovação dessas estruturas técnicas para melhorar recuperação, disponibilidade e acesso, isso aconteceu no final de 80 e começo de 90 até o século XXI.

No século XXI e especialmente agora nós temos outra perturbação na área, nós temos as tecnologias como elementos perturbadores do que estava tudo arrumado. E temos novamente o ingresso de outros profissionais na área da Ciência da Informação, o que é muito bom e salutar, assim como foi bom e salutar o ingresso dos historiadores, museólogos, linguistas.

Hoje nós assistimos o ingresso do pessoal da Ciência da Computação, o que é muito bom, mas nós temos uma identidade na área que precisa ser preservada, porque senão vamos nos transformar em algo que não é nem Ciência da Informação nem a Ciência da Computação, nem uma coisa nem outra, existe um ponto onde chegar com a Ciência da Informação que não é a Ciência da Computação, e existe um ponto que a Ciência da Computação pode entrar que não é a Ciência da Informação. Mas cada uma delas defendendo suas características específicas, defendendo os conhecimentos da essência da área.

Então a nossa preocupação é sim o usuário, é saber quais são às necessidades do usuário muito mais do que entrar na seara da Ciência da Computação, nós somos usuários críticos das tecnologias mas no sentido de atender às nossas necessidades dos usuários. E agora quando a gente tá falando de dados, de uma Ciência de Dados, de uma gestão de dados, aí que nós precisamos mais e mais identificar qual é a identidade da Ciência da Informação para que ela trabalhe junto com outros profissionais.

A Luana fez um trabalho brilhante hoje de manhã, demonstrando dentro da Ciência da Informação onde é que nós podemos transitar com uma atividade nova de gestão e gerenciamento de dados sem perder a identidade da área, ela utilizou os GTs da ANCIB, que é uma associação que precisa rever também algumas coisas, porque ao longo do texto não se fala em dados. Nós estamos propondo essa inserção dos dados, é claro que como eu apresentei na questão das produções não ter havido nenhuma atualização desde 2008 na nossa família de ocupações, na ANCIB também não houve muita modificação.

Como é que deve ser feita? É em plenário a alteração das ementas? Mas nós precisamos encaminhar essa demanda. Precisamos ter claro isso, porque nós vamos ter cada vez mais equipes multidisciplinares e não é porque nós fazemos errado o que fazia mas é que hoje pode ser feito diferente com mais gente, nós precisamos das colaborações que recebemos lá em 1980 dos historiadores e dos artistas, e nós precisamos trabalhar em conjunto com Ciência da Computação hoje, mas em um trabalho multidisciplinar e interdisciplinar, para que a essência da área fique claro para todos os envolvidos.

Então a minha participação na constituição do profissional da Ciência da Informação percebeu isso ao longo de minha jornada e era isso que eu queria compartilhar com vocês.

Sandra:

Obrigado Plácida. Antes de passar para a Luana eu queria destacar coisas partes da fala da Plácida que me tocaram muito. Minha origem toda e Ciência da Computação e o que é engraçado nessa multi e interdisciplinaridade é que trabalhamos com coisas parecidas, ferramentas parecidas chamando por nomes diferentes. Então eu confesso que quando eu decidi entrar para área da Ciência da Informação eu levei uma surra, tive que estudar muito para poder me adaptar à nomenclatura.

Até para as duas áreas dialogarem existia uma dificuldade por causa das questões de nomenclatura e como fazer esse diálogo entre as áreas para fazer às colaborações acontecer. Então eu acho importante essa multi e interdisciplinaridade vivida na prática, para a gente ter como fazer essa colaboração efetivamente. As outras áreas como Linguística também estão trabalhando com a gente e várias outras, vejo também diversos estudos voltando como a semiótica que voltando com uma força maior atualmente.

Então a gente entrar nesse espírito e identidade da Ciência da Informação é considerar muito essa vocação multidisciplinar e a gente poder realmente desenvolver trabalho para isso. Nós temos ferramentas para isso, temos profissionais para isso mas muitas vezes há uma série de dificuldades causadas ou por problema de comunicação entre equipes, ou por vaidades que não combinar, e a gente precisa vencer essa barreira. Eu vou passar para a Luana agora.

Luana:

Agradeço também mais uma vez o convite, é uma responsabilidade grande estar aqui compondo essa mesa com grandes nomes da área, professora Plácida, professor Ricardo, enfim fico muito feliz em estar com vocês.

Então a gente fala um pouco sobre identidade do profissional e em relação aos dados de pesquisa o Guilherme falou mais cedo e o engraçado que eu tinha tentado uma outra apresentação porque eu achei que isso daqui seria uma segunda palestra, eu começaria exatamente apresentando aquela situação do The Economist que fala os dados como um novo petróleo. Então a gente vê o mundo da ciência mas a gente traz nesse contexto da ciência os dados de pesquisa configurando uma nova forma de fazer ciência. Isso é claro com um impacto forte na nossa forma de gerenciar dados, gerenciar informação, que foi o que eu tentei trazer para vocês hoje de manhã que e apesar desses dados apareça estar se reconfigurando, a gente vê uma necessidade ainda maior de uma base sólida da biblioteconomia e da Ciência da Informação que a Plácida falou disso um pouco agora. A gente vê a necessidade dos teóricos consistentes e a Ciência da Informação tem isso para nos oferecer. Eu espero um pouco também a fala do professor Sayão no primeiro dia quando ele fala daquilo que a gente vê o fim do triângulo amoroso a gente fala do pesquisador, informação e bibliotecário.

O bibliotecário na verdade é um mediador que vai fazer aquele papel de intermediar o usuário e a informação, e quando a gente chega à web e que essas informações vão para web o

que acontece? O bibliotecário tente a ficar um pouco de fora desse cenário, porque as pessoas se preocupam com pesquisa e recuperar e esquecem que a informação a ser recuperada tem uma pessoa por trás dela fazendo isso.

Isso coloca em voga mais uma vez a necessidade de retomar a nossa base teórica porque se por um lado a gente pensa que o bibliotecário não está aí, que o usuário não está vendo o bibliotecário mas o bibliotecário está ali sim. Eu vou até o sistema da biblioteca e eu não consigo encontrar a informação que eu estou procurando é completamente diferente de como a gente fazia anteriormente, que ia lá com o bibliotecário e fala que não achei você pode me ajudar. Hoje o usuário vai até a biblioteca e não recupera ele não volta mesmo, ele vai fazer outras buscas e outros caminhos.

Em relação aos dados de pesquisa eu venho defendendo uma atuação do bibliotecário que eu venho comparando um pouco o que a gente faz com os médicos da família e eu venho defendendo o bibliotecário do ponto de vista da pesquisa. Eu sei que quando eu falo isso o pessoal fala como você vai fazer isso porque eu já vi tanto serviço na minha biblioteca, mas eu acho também que isso abre uma série de possibilidades para o profissional da informação.

O bibliotecário vai fazer exatamente isso que a gente conversou na manhã, ele vai gerenciar os fluxos dos dados de pesquisa, porque o pesquisador precisa desse auxílio, precisa porque ele está enrolado com as pesquisas dele e o bibliotecário pode oferecer esse tipo de serviço. E o bibliotecário por outro lado não pode trabalhar sozinho porque ele não tem conhecimento daquelas técnicas e daquelas tecnologias porque o pesquisador não tem conhecimento específico, mas conhecimento das técnicas e teorias que vem da Ciência da Informação podem auxiliar o bibliotecário e o pesquisador.

Quanto eu estou falando isso eu estou falando dos metadados, das cópias tradicionais de descrição de documentos que hoje se aplica também aos dados de pesquisa, aos vocabulários controlados e ontologias, e que precisam ser construídas para possibilitar a comunicação, de como esses dados vão ser recuperados, como o conhecimento pode ser retirado desses dados, enfim, o que eu acho que é importante a gente deixar claro é a necessidade da gente voltar a focar nos estudos teóricos, como o Buckland que é um pouco antigo e acaba ficando um pouco esquecido, e os nossos teóricos da organização do conhecimento, quando eu digo que os dados precisam ser reusados.

A gente sai da perspectiva do documento como a minha primeira orientadora costumava dizer para mim, e vai para a perspectiva do uso, da informação em si. A ideia é essa, é trazer e recuperar essas teorias antigas e aplicá-las ao contexto da gestão dos dados de pesquisa.

Sandra:

Obrigado Luana, eu passo agora para o Ricardo, vou deixar para fazer os comentários depois.

Ricardo:

Boa tarde a todos, quero agradecer também a organização do evento, parabenizar pela possibilidade de refletirmos sobre esse tema, é uma honra fazer parte dessa mesa, eu quero

continuar um pouco aquela fala que eu fiz na abertura e trazer de volta essa questão da identidade. Para isso eu gostaria de falar um pouco sobre como eu cheguei na Ciência da Informação, eu venho da área de Computação e Matemática mas eu tive empresa de consultoria então atuei na área durante a década de 80 e 90.

Quando eu tive contato com a Ciência da Informação eu percebi o potencial que havia nos conhecimentos que se discutia, na forma com que se encaravam os problemas, e mesmo sendo na época de escovador de bits, meu grande prazer era passar noites de como compactar dados para caber em um disquete. Eu me lembro que no final da década de 80 nós fizemos uma solução que consegue encapsular em poucos disquetes toda a legislação da previdência emulando, porque na época não tinha esse recurso de hipertexto, mas a gente emular essa questão do acesso por palavras-chave e ia navegando pelo teclado com um highlight na telinha a gente conseguia navegar.

Mesmo com esse perfil tecnológico, quando eu tive contato com a Ciência da Informação foi amor à primeira vista, porque eu percebi que havia algo de muito valioso na forma com que se encaravam os problemas, na maneira como se tratavam às questões, diferente da computação. Não que uma fosse mais valiosa que a outra, mas eu percebi algo com potencial muito alto de contribuição para a Administração e para as soluções práticas que a gente desenvolvia.

Foi uma surpresa para mim porque mesmo atuando a muitos anos na área eu não tinha ouvido falar da Ciência da Informação, nem lido nada sobre Ciência da Informação. Isso me chamou muito atenção, por que é que isso não chega até as outras áreas?

E refletindo sobre isso já na época eu comecei a perceber que o que realmente tinha de diferente era uma perspectiva diferente de olhar o problema, uma perspectiva que se aproximava mais do usuário, que se aproximava mais do impacto social daquilo, uma perspectiva que buscava construir pontes entre o conteúdo e uma necessidade do usuário, autonomia do usuário e uma série de questões que na Ciência da Computação também são tratadas mas a partir de um ponto de vista mais tecnológico, principalmente quando a gente está na aplicação, na realização, na implementação, a gente vê nestas questões aspectos muito mais voltados ao usuário quase como um obstáculo. Então tinha umas brincadeiras que se faziam na época, e até hoje a gente ainda escuta uma certa arrogância, um certo sentimento de superioridade por controlar a situação.

Então existe essa noção muito forte quando a gente está desenvolvendo a aplicação de que nós controlamos o processo, de que nós temos a solução, e isso pode ser muito ruim na interação entre conteúdo e usuário, porque eu passo a ver com menos importância às características de quem realmente precisa. Você não estava pronto para a minha solução? Ela é maravilhosa e fantástica [ironia].

Então sem perder o valor de uma ou da outra, a Ciência da Informação é diferenciada ao tratar das mesmas questões, por isso a dificuldade de compreender esse degradê ou essa linha que divide e é muito tênue entre uma área e outra, como nesse caso como a gente está discutindo agora, como a professora Plácida apresentou, como a professora Luana discutiu.

E isso me levou a derivar ou aprofundar muito mais na área da Ciência da Informação do que na Computação, mesmo na minha livre-docência quando eu trabalhei Sistemas de

Informação o meu olhar já era um olhar muito mais da Ciência da Informação do que da própria Computação.

Eu trabalho com outras questões sempre tentando levar o olhar da Ciência da Informação como contribuição para outros olhares, porque isso faz com que a gente possibilite a construção colaborativa que a gente tava conversando hoje de manhã.

Outra questão que sempre me preocupou foi que eu ouvia, já no início dessa minha trajetória na Ciência da Informação, algumas referências, que eu não vou citar porque senão eu posso ser injusto com outras, mas que colocaram uma questão de se realmente a Ciência da Informação era uma ciência? Isso até me angustiava, porque ao inter-relacionar com outras áreas você pode ficar subutilizado se você não tiver isso muito fortemente consolidado.

Se você não tiver a noção clara de quem você é, do porque você é diferente do outro e no que você pode contribuir, mesmo em questões similares mas apresentando uma visão distinta que apresente novidades e possa contribuir com o desenvolvimento de uma solução, o entendimento de uma situação na relação entre o acesso à informação e o usuário, necessidade e conteúdo, essa questão da assimetria entre aqueles que acessam a informação, você pode perder a capacidade de colaborar e participar do grupo. Se você não sabe realmente quem você é, você acaba contribuindo pouco ou tendo que aderir ao discurso do outro, e aí você passa a não contribuir mais com esse processo do conjunto, mas para fazer ciência a gente precisa lembrar que precisa além de ter muito claro qual é o seu papel, qual é o seu lugar, você precisa atender alguns fatores como por exemplo o próprio vocabulário.

Então muitas vezes você percebe uma defesa muito forte do seu vocabulário e isso é natural e pode ser ressaltado, desde que você não esteja bloqueando inserções ou aportes de outras áreas, como uma simples questão de manutenção daquilo que você considera como um vocabulário final, mas você precisa ter esse vocabulário comum senão você não consegue dialogar dentro da área.

Esse diálogo é fundamental e eu já estou começando a tratar na questão interna da Ciência da Informação, então você precisa ter um vocabulário para que você possa estabelecer um diálogo, esse diálogo vai permitir então que você possa validar dentro da área aquilo que você propõe, porque senão vai ficar uma situação muito estranha. Uma banca, um parecerista, ou alguém pode estar validando um conteúdo sem ter uma noção clara de que aquilo realmente, sem ter conhecimento prévio sem ter experiência para ter uma forma de validar aqui de forma concreta e clara, para que isso vá para outras áreas e não sofra com pequenos conjuntos. Uma queda de um elemento ali que não válida e que acabou escapando por validação interna.

Tudo isso vai permitir a reprodutibilidade, tudo isso vai permitir inclusive o próprio ensino, que a gente tinha colocado hoje de manhã que é a questão de pensarmos e repensarmos, como a professora Plácida muito bem colocou a questão do repensar a área. Temos repensar os currículos, às competências, o escopo de até aonde a gente pode ir sem prejudicar o perfil do egresso, sem prejudicar essas outras questões de vocabulário, de validação. Porque isso internamente vai poder propiciar a questão, por exemplo, de ampliar a nossa participação, percebe-se muito pouca participação dos profissionais da Ciência da Informação em grupos que trabalham a Ciência dos Dados. No centro de desenvolvimento da USP eles recorrem a Poli, às

Engenharias. Qual é o grau de participação da Ciência da Informação lá dentro, de quem é a culpa?

Eles não vão sair procurando por nós, se a gente fica sentado aguardando, porque eles nem sabem que nós existimos, provavelmente eles vão passar pelo mesmo processo de vislumbramento que eu passei lá atrás ao ver nosso potencial de contribuição. Mas nós precisamos nos apresentar, e para nos apresentarmos temos que ter muito claro o que significa ser um profissional da Ciência da Informação, o que significa ter essa perspectiva diferente.

Por que em uma parceria eu serei útil? Qual será o ROI do investimento, o retorno sobre o investimento da minha participação naquele grupo? O que se espera da participação de um pesquisador da Ciência da Informação nesse grupo vai contribuir e eu só vou perceber isso se o próprio pesquisador e a própria área tiver isso muito claro.

E tudo isso de novo cai em outra questão que é a questão da divulgação. Eu sinto muito falta por isso que eu estou pondo vários pontos, eu sinto muita falta de divulgação da área para a sociedade em geral, apesar de ser a Ciência da Informação nós divulgamos muito bem dentro da área, fora da área nós somos poucos visíveis, quase invisível como a professora Plácida colocou no slide. A visibilidade nossa é pequena e parece pouco valorizada pela ação daqueles que trabalham na publicação científica.

Eu desafio aqui os presentes a pensarem cinco nomes de divulgadores de ciência que são da área de Ciência da Informação. Poderia até citar um que se diz da Ciência da Informação mas a gente pode pensar se realmente é da área. Será que nós estamos divulgando externamente? Para divulgar externamente precisamos saber quem somos.

Um evento como esse, por exemplo, poderia estar sendo coberto por uma Rede Globo, entrevistando os participantes estrangeiros que poderiam estar dando entrevista. Como nós gostaríamos de nos apresentar a eles e dizer, olha nós estamos aqui e somos da Ciência da Informação. A primeira coisa que eles iriam perguntar: quem é você? Qual a área que vocês atuam?

Nós tivemos uma experiência parecida com essa questão que eu acho que é muito emblemática e que a gente percebeu o que isso significa, quando nós trouxemos o evento graças a uma grande contribuição da professora Ana Alice, nós conseguimos trazer um evento desse porte para o Brasil em 2014 e convidamos uma pessoa da Reitoria para falar no evento, foi uma grande surpresa porque nós temos o programa de pós-graduação de lá nota 6 com grande renome na área, e a primeira fala dele foi "olha eu estou surpreso porque a Ciência da Informação eu muito já ouvi falar, deve ser muito interessante e contribuir com a área. De que é a culpa, é dele? Ou é nossa? O que é que nós estamos fazendo para divulgar as nossas contribuições? Como é que nós estamos deixando melhor a ponto de permitir que isso seja divulgada para meios de comunicação de massa para fora da área.

Quantas vezes nós publicamos fora da área para trazer visibilidade para aquilo que nós contribuímos? Quando é que nós participamos de eventos, por exemplo, na área de Ciência da Computação para propor caminhos, e não para analisar o que já foi feito. Nós temos potencial para isso e temos que começar a pensar agora na ponteira, temos que começar a pensar nas

indicações de caminhos a seguir indicando para onde e não mais ficar analisando o que já foi feito, mas construindo melhores meios para utilizar o que já foi construído.

É um potencial muito grande que temos e que está sendo subutilizado de forma muito visível, pelo menos na minha percepção de quem chegou de fora. Isso tudo vai permitir que nós tenhamos reconhecimento, esse reconhecimento pode legitimar às nossas publicações, então às nossas publicações poderiam ser mais citadas na área da Ciência da Computação, e como nós somos muito pouco citados a Ciência da Computação por desconhecimento deles.

Senão tivesse esse duplo caminho, essa troca, nós seremos avaliadores ou estaremos testando aplicações, seremos eternos testadores de aplicações para a Ciência da Computação.

Então tudo isso vai permitir inclusive que a gente consiga uma visibilidade para nossas áreas de formação, eu acredito que os nossos cursos a maioria tem uma baixa procura em função do potencial que ele tem paro mercado, porque os alunos também não tem essa noção de como contribuir com as outras áreas. Então a gente vai ter uma formação mais valorizada, a gente pode se adequar a forma mais profunda às necessidades de outras áreas, porque agora não dá mais para pensar em atuar somente naquilo que eu gosto mas como a professora Plácida colocou, de forma interdisciplinar. Claro que existe uma grande barreira que é a questão da zona de conforto.

Nós temos a zona de conforto da Ciência da Informação, então é tentando manter a situação que estamos, a segurança daquilo que eu venho fazendo desde sempre, e tem a zona de conforto de quem chega de fora, porque a primeira reação que eu tive quando cheguei na área era tentar fazer às coisas do mesmo jeito que eu fazia antes, sem me dar conta de que se fosse para fazer do mesmo jeito que eu fazia antes, seria melhor eu ter ficado na Ciência da Computação, porque eu iria ter diálogo, validação, replicação, de forma mais sólida do que na Ciência da Informação. Então eu comecei a perceber que eu tinha que buscar conteúdos e referenciais que me permitissem subir nesse ponto de perspectiva e me desse um olhar diferente.

São questões muito amplas e abertas mas que são, infelizmente nós não temos muito tempo para ficar tentando encontrar soluções para isso. Não é algo novo mas se agravou com as novas tecnologias.

A questão dos dados, na minha percepção, sempre existiu e sempre foi uma questão da ciência, o que nós temos agora é uma questão do volume, mas mais do que isso, assim como o professor colocou de manhã a questão da cauda longa, o que está acontecendo agora é que os dados estão sendo vendidos mas não é para o próprio pesquisador, estão sendo vendidos por escrutínio. Nós não teremos no futuro breve possibilidades que haviam antes séculos atrás, porque agora os dados não estão mais disponíveis nem mesmo nos registros em papel. Então vamos perder definitivamente dados, dados que nunca mais serão recuperados.

São muitos os exemplos de coisas que são recuperadas a posteriori e que a partir desse resgate pode gerar novos conhecimentos. Nós não teremos novidades construídas a partir de pesquisas como o Mendel que fez lá observações dele no mosteiro porque isso não vai estar em um livro envelhecido numa prateleira, vai estar lá perdido num registro digital na máquina de alguém.

Então são questões muito prementes, nós precisamos atuar, dados do ministério público devem estar presentes em todos os GTs da ANCIB, e nós precisamos identificar claramente que

somos para poder conversar com os outros e poder colaborar de forma simétrica. Eu acho que esse é o ponto de partida que eu queria colocar para nossas discussões.

Sandra:

Eu queria destacar alguns pontos a partir dessas palestras aqui. O Sayão trouxe a cauda longa onde você tem muitas pequenas pesquisas produzindo quantidade enorme de dados, você tem muitos pesquisadores fazendo pequenas pesquisas. E ele nos mostra nos levantamentos que ele fez que boa parte desses pesquisadores geram esses dados com amadorismo. Está no pendrive, está no HD externo, está na planilha, no Word, não está autorizado, nunca pensei nisso, são respostas que nos assustam um pouco porque tem a questão do financiamento e do dinheiro que está sendo investido nessas pesquisas, e tem até a questão que Ricardo colocou muito bem aqui de que há dados que você levanta que são muito difíceis de ser replicado, você tem aquele evento de novo e conseguir coletar exatamente aquilo que por algum motivo de não ter sido feito a gestão adequada foi perdido porque não existiu uma curadoria. Ou você tem um dado que quando recuperado você não consegue recusar, não consegue interpretar porque ele não está documentado, não tem informações como por exemplo, você tem uma planilha cheia de números e assim, foi o que, em que momento, coletou como, instrumentos, de que maneira, como eu posso continuar a utilizar a partir dali se eu não tenho aquela informação.

Então esse amadorismo na questão dos dados pode trazer cada vez problemas mais sérios que talvez começaram a ser sentidos agora com a pontinha do iceberg de perdas e de tudo que ainda pode acontecer. Aí Plácida nos traz o papel do profissional da informação nesse contexto, que você tem um problema que é uma oportunidade, você tem um momento em que nós temos que a Ciência da Informação pode com o que ela já fazia, se aprimorar, se reinventar para dar acesso a causa.

A gente tem uma atuação que leva isso em consideração, da nossa associação, onde ela pode rever como essa questão dos dados vem sendo tratada nos GTs, que Luana trouxe muito bem, e identificar quais competências que a gente tem que se adequar, a gente faz uma coisa muitas vezes começam como arquivistas e bibliotecários, eles colocam elementos que eles se adéquam perfeitamente na gestão dos dados mas que eles mesmo não conseguem enxergar que aquilo se adequar àquele contexto.

Por exemplo, você fazer a descrição, você preencher os metadados, uma atividade falada mas que dentro do contexto da gestão dos dados é um elemento extremamente importante que já é feito e estudado na profissão, mas de repente você tem que ter um padrão novo, uma forma nova, ir além e se aprimorar para aquele novo contexto.

Luana reforça também que o profissional da informação tem um perfil e um conhecimento que se adéquam mas que tem que ganhar um novo bibliotecário de dados, arquivista de dados. Ele poder ser um elemento que vai ajudar o pesquisador, ser um mediador.

O Ricardo traz outra coisa muito importante também que é essa falta de visibilidade da área que a gente vê, a gente utiliza às outras áreas em nossos estudos mas a gente não torna nossa área tão visível em alguns dos estudos que são realizados para mostrar o quanto a gente pode colaborar também com outras áreas.

Faltam cursos para capacitar os profissionais que já estão a um tempo, ajustar currículos, desenvolver novas competências, e os que estão aí nas universidades, e os que já saíram e estão no mercado a um tempo, o que é que a gente tem para oferecer para eles agora para eles se prepararam para esse novo contexto que eles acabam tendo que atuar.

Como fazer sair dessa zona de conforto nesse desafio que a gente pode colaborar, o que é que nós enquanto pesquisadores da área que publicamos e trabalhamos com curadoria de dados, gestão de dados, o que é que a gente tem feito para melhorar esse contexto e ajudar nas competências desses profissionais e melhorar nossas próprias práticas para atender esse novo cenário.

Guilherme apresentou os resultados da pesquisa dele e Ricardo perguntou, você teve um plano de gestão de dados nesta pesquisa? Não. Então ele apresentou uma falta que tem nos profissionais que ele que estava pesquisando estava fazendo também. Então o que é que nós estamos fazendo em nosso cotidiano, e a gente é casa de ferreiro espeto de pal.

A gente apontar caminhos e não ser exemplo do que a gente pode fazer, de como a gente pode trabalhar nesse novo contexto, esse novo desafio e identidade da Ciência da Informação. Também destaque nos projetos de gestão de dados, muitas vezes você tem dentro de nossa área Ciência da Informação, então a gente coloca entre áreas ilhas de dados, você tem dados que estão sendo geridos de maneira que não conversa com nenhum outro. Eu coloco a palestra de Ana Alice porque ela falou que falta interoperabilidade e falta a possibilidade de fazer um reúso desses dados, porque eles estão pobremente documentados, porque às ferramentas não se comunicam ou porque você tem seus dados bem organizados e documentados mas não compartilhou, não deu acessibilidade para ninguém, que é uma das respostas que eu achei engraçado na pesquisa que Guilherme apresentou que disse tenho tudo organizado em meu HD, guardei em diretórios tudo documentado durante anos, como ninguém procurou eu deixei para lá. Como alguém iria procurar se não sabia se existia.

Então como questionamento sim, não basta só gerir seus próprios dados, mas para eles se tornarem efetivamente úteis eles têm que ser disponibilizados. Aí eu trago outro ponto aqui, não adianta a gente conversar de fazer uma proposta se a gente não ajudar na capacitação dos profissionais, mas a gente tem que também como pesquisador assumir a responsabilidade de tentar só mudar às políticas ao menos nas instituições que a gente participa. No seguinte sentido, a gente pode preparar os profissionais, mas se cada um começar a trabalhar de uma maneira diferente a gente continua com esse cenário de falta de interoperabilidade.

Então se cada um tem seu próprio repositório, não tem a questão da visibilidade dos dados que foram produzidos pela instituição. Temos que pensar nas questões de políticas, de como a gente pode influenciar nisso daí, e não de pensar na implementação da gestão do dado no momento atual, mas no ciclo de curadoria como um todo. Onde você vai pensar desde o momento em que o dado foi criado, passando pelo momento com que você faz a descrição desse dado, armazena, faz a preservação, tem um contexto maior que precisa ser considerado para realmente facilita o reúso, a manutenção, o compartilhamento, o dar acesso.

Há várias questões que temos que considerar nesse contexto de gestão de dados, nesse novo cenário para qual os dados se apresentam. Uma coisa que eu penso muito, o que é dentro

de tudo que conversamos aqui, que a gente pode fazer nesse momento, que ações práticas e efetivamente como a gente pode colaborar nesse momento para mudar esse cenário e contribuir efetivamente com a área. A gente tem que publicar, mas além de publicar o que mais a gente pode fazer?

Então eu deixo esse questionamento para a gente refletir, fazer do meu cotidiano enquanto pesquisador, seja professor, seja aluno de graduação, mestrado ou doutorado, como eles podem efetivamente contribuir com isso se ele fazer e começar a ser o exemplo, começar a praticar essa gestão de dados. Não estou dizendo que é fácil, mas é o que se põe para nós nesse momento. Como a gente pode colaborar com esse cenário?

Plácida:

Não há resposta. Eu penso que o que nós podemos fazer como parte nessa questão, porque nós temos poucas oportunidades de reunião de pessoas que estão com essa preocupação, então é nessa oportunidade que daqui cada um de nós vai ser um divulgador de alguma possibilidade, um replicador de alguma possibilidade, eu creio que cada um de nós pensou em alguma coisa para fazer em seu ambiente, o que eu vou fazer com meus orientandos com relação a isso. Quem dá aula na graduação como vai ficar essa questão, mesmo que não fazendo parte oficialmente do currículo, como é que isso vai acontecer?

Na disciplina optativa que nós temos para oferecer na graduação, será que gestor de dados não é uma indicação de disciplina optativa? Então eu penso que aquilo que nós estamos comentando, a oportunidade de algumas ações que poderíamos levar no nosso ambiente de trabalho e cotidiano.

Luana:

Eu também acho que há um lugar certo, quando eu penso nos bibliotecários que são pós-graduandos, isso aconteceu comigo eu era bibliotecária, trabalhava em uma biblioteca de pesquisa, e todos os bibliotecários que estavam lá também.

Eu acho que um diferencial que eu tinha era que eu passei a conhecer às formas de pesquisa, então eu conseguia conversar com o pesquisador na linguagem dele, e acho que vocês que estão aqui hoje na Ciência da Informação possuem essa possibilidade, atuar na biblioteca com esse conhecimento do que é a pesquisa de verdade, e propondo novas soluções.

Acho importante registrar a importância desses eventos, porque mesmo em nossa área de Ciência da Informação ainda existem pesquisadores que não se convenceram da importância do compartilhamento dos dados porque tem suas questões, estão preocupados com questão de citação, de como isso vai ser feito. Então os eventos são os locais onde temos a oportunidade de criar esses diálogos.

Quando eu comecei na área nuclear eu via muito isso da Ciência da Informação, a gente via acesso aberto, acompanhamos todo esse movimento dos periódicos, agora uma área que tradicionalmente tem a questão do sigilo trabalhando em alguns domínios como a Engenharia Química que tem a gestão das patentes, uma área que no Brasil surgiu em uma época que o

militarismo estava no poder, então tinham aquelas questões do que não podia ser divulgado, mas enfim.

Os pesquisadores ainda tinham problemas muito mais complexos que a Ciência da Informação, e o caminho que eu escolhi seguir foi esse, fazer eventos e levar pessoas da Ciência da Informação junto às pessoas que trabalhavam com dados, era um cafezinho às vezes no almoço e eu tinha essa vantagem com o Sayão, porque a gente trabalhava assim no local que era no meio do nada e os pesquisadores eram obrigados a sentar no meio da mesa do bibliotecário e eram obrigados a ouvir os bibliotecários a dizer "olha eu preciso dos seus dados, eles vão ser insumos para outros pesquisadores", ou até para sua própria pesquisa.

Porque às vezes você pensa em compartilhar os dados, se é ciência aberta vou ter que dar meus dados para todo mundo, mas não existem os níveis de abertura e você pode convencer o cara dentro disso, de repente dentro de uma palestra é mais complexo, levando nas trocas você fala "e se você precisar dos seus dados para pesquisas no futuro", "mas será que você ainda vai ter ao longo dos anos", e aí ele começa a questionar e destacar situações em que teve que jogar tudo fora e aí dentro desse discurso você vai conseguindo convencer o cara dessa importância.

Então acho que temos uma oportunidade boa enquanto bibliotecários, temos possibilidade de pós-graduação em Ciência da Informação espalhada pelo Brasil inteiro, alguns anos atrás nós tivemos bem poucas pessoas, era difícil para o pessoal do Nordeste conciliar trabalho com pós-graduação em Ciência da Informação como em outros lugares como o sudeste.

Hoje quando os bibliotecários se especializam, e aprendem o poder da pesquisa científica, como a pesquisa é conduzida, ele volta com esse linguajar mais próximo ao pesquisador, ele volta de uma outra maneira. Essa é uma oportunidade e a questão também dos eventos e da conversa pessoal com nossos pares.

Sandra:

E destacar até Luana o valor dos eventos menores, porque o evento menor que é realizado em sua própria instituição é o que proporciona maior troca e é o que vai plantar aquela semente com a raiz mais forte. Porque se você tem um evento grande, aquela palestra e você não tem tanto tempo para discutir, não tem tanto tempo para colocar suas dúvidas e inseguranças. Aí no evento pequeno você discute e conversa, tem um formato que eu participei de um projeto na área da saúde que fazer uma coisa chamada projeto com café, o que é isso?

Era uma mesa redonda onde se colocavam questões e a toalha da mesa era o papel, e você ia tomando café e trocando ideias, e se anotasse as ideias e às dúvidas na toalha de mesa. Depois tinha que ter alguém que recolhe e organiza esses dados, mas o que era interessante era quando se trocava de ideias naqueles eventos, eu participei de alguns e o que a gente recolheu não tinha evento, congresso ou capacitação que tinha tido o mesmo efeito, porque eles ajudaram a construir uma metodologia que precisava, eles colocaram às dúvidas e inseguranças e quando todo mundo saia com aquele espírito de colaboração e engajamento. Podia estar só na mesa tomando um café pelo menos ele se sentia incluído naquele processo de constituição, e também eu vejo muitas vezes no projeto que falta envolver a comunidade desde o início do projeto.

Porque você chega, vou dar uma ideia, chega com o repositório pronto e fala deposite aí. Você não colaborou, não mostrou sua necessidade, quais os dados você trabalha, você não se enxerga como participante daquele projeto, naturalmente você pensa que não se sente na obrigação de colocar nada lá. Eu não me sinto parte daquela iniciativa, então a gente encontra muitas vezes isso na instituição, não chegou nem no repositório de dados mas no repositório institucional, que foi criado e instalado por um pequeno grupo da própria biblioteca, não envolve muitas áreas, depois de instalado chegaram e falaram que você tem que depositar lá.

Existe uma divulgação e está tendo uma reação a isso, os pesquisadores se perguntam porque eu tenho que colocar lá, então isso começando com as teses e dissertações, imagina quando chegar nos dados que alguns se sentem mais inseguros com os dados que geraram em sua pesquisa, será que vão achar erro nos dados que eu vou publicar? Será que tem alguma coisa lá que vão extrair e eu não vi e vão fazer melhor do que eu fiz?

Então existe um lance que pode talvez estar melhorando isso são esses eventos que dão bastante segurança, capacitando também e mostrando esse desafio que vai chegar um momento que você não vai conseguir fugir disso, vão estar se aproximando cada vez mais, já existem órgãos de fomento que cobrar e tem aí CAPES e CNPq que logo vão pedir aos programas de pós-graduação isso aí. Que você tenha os planos de gestão dos dados das pesquisas da instituição e que isso esteja guardado e de novo vai chegar em uma coisa que vai cair aqui e dizer que todo mundo tem que cumprir, faça-se cumprir.

Seria muito melhor se a gente fosse se preparando do cenário que já se encontra mas que a gente tem uma preparação urgente.

Ricardo:

Queria retomar a questão da emergência com que nós estamos passando. Os contextos mudam muito rápido, e eu concordo com a mesa que esse tipo de evento é o caminho para gente iniciar essas discussões, por isso que eu sempre fui defensor, tentar encontrar caminhos para construir esses eventos. Hoje parte da área já entende e percebe isso mas a gente sabe que grande parte da área tem resistência por esse tipo de evento, a gente sabe o que isso significa estar aqui participando desse evento, a gente sabe os impactos das nossas falas nas próximas vezes que a gente encontrar com o pessoal, a gente sabe o que vai acontecer.

Eu quero deixar bem claro isso que esse esforço do evento de vários estarem aqui participando já é uma questão que eu acho que é um primeiro passo muito importante. Eu volto a questão que foi colocado aqui hoje dessa onda que vem vindo e nós vamos ter que acelerar isso de alguma forma, temos que encontrar algum caminho por isso hoje de manhã a questão da proposta de um curso onde a gente possa estabelecer muito mais do que um curso, um espaço de construção de conhecimento colaborativo onde nós possamos trocar expertise e entender o que cada um desse grupo pode contribuir.

Mas na perspectiva geral de acesso a dados qual é a possibilidade de contribuição de cada um de nós na construção desse novo conceito da participação da Ciência da Informação no acesso a dados, porque a gente precisa, não sei se é porque eu vim do mercado, mas eu acredito muito na questão da demanda, muitas áreas que não tinham nenhuma relação com dados utilizam dados

porque houve a demanda. A área de pesquisa genética por que eles conseguem usar dados de uma maneira tão eficiente, existe um modelo que foi desenvolvido, porque existe a percepção de que aquilo é importante.

Então eu identifiquei pelo menos três elementos que a gente precisa trabalhar, e o primeiro deles é essa questão da conscientização. Muitos dos pesquisadores ainda não se deram conta da importância dessa questão da visão dos dados. Eu vou além, há a necessidade de compartilharmos esses dados, de mantermos esses dados disponíveis independente do que nós vamos conseguir tirar deles.

Imagine na área de saúde, a importância que tem se a gente conseguir compartilhar facilmente os dados das pesquisas que estão em desenvolvimento. Então a questão da conscientização é o primeiro pilar que eu penso que vamos ter que trabalhar de forma muito ardilosa e estratégia, desenvolvendo uma conscientização dos pesquisadores de outras áreas e não somente da nossa área, desenvolvendo a questão da necessidade dessa gestão de dados mas também a questão do potencial de gestão de dados que nós temos para oferecer a eles.

Por isso a importância desse diálogo, dessa importância de ter algo que nos una, que nos permita ter esse espaço de diálogo. Se não vamos chegar em nossas respectivas bases e o que vai acontecer, seremos engolidos pelo dia a dia como sempre acontece. Você chega lá tem quinhentas pareceres atrasados, é o aluno que está esperando nota, é o projeto de pesquisa que você tinha que entregar o relatório, é o aluno que entrega a tese nos últimos momentos. Todos passamos pelos mesmos problemas, se não tivermos algo que exija de nós essa participação, não vamos conseguir estruturar essa ação estratégica.

A segunda dimensão que eu penso é a questão da preparação. Uma vez gerada a demanda, nós temos que estar pronto para atender essa demanda e o mercado a gente tem uma preocupação muito grande com isso, você não divulga algo que você não vai conseguir entregar, isso vai ficar mais caro do que se você não tivesse vendido.

É doloroso quando chega no pedido e você ter que dizer não tenho mais isso no estoque, então qual vai ser o nosso estoque de competências, porque nós temos que estar preparados. Nós vamos começar a gerar esse estoque de competências para quando essa demanda vier, a gente tem que começar a preparar isso e colocar lá na estantezinha nossa ao passar os mesmos, na Ciência da Computação eu tenho isso, na Ciência da Informação eu também tenho esse elemento que eu posso colocar junto aqui com meu grupo para desenvolver uma solução.

E uma terceira é justamente o que vocês já colocaram, essa questão que retorna o discurso da identidade, do discurso, do compartilhamento, essa necessidade de encontrarmos um modelo, não impositivo, nada que seja top down, mas, pelo menos, uma base mínima de conceitos e caminhos que permitam que essa competência se aplique de forma pelo menos estratégia e arquitetada de tal forma que ela possa realmente convergir para um reúso e resultados que realmente levem a convergência entre áreas. A gente tá percebendo um pouco que por sermos de uma área que trabalha a informação, nós temos a capacidade de fazer com que áreas distintas que tratam dados de forma distinta como o professor Sayão falou dos repositórios distintos, que nós temos um repositório para cada área, mas temos a possibilidade de propor modelos e soluções

para que isso possa compor um cenário que exista a possibilidade inclusive de compartilhamento desses dados entre áreas distintas.

Nós vamos estar olhando de fora, vamos estar sem a contaminação da densidade imediata da área, isso era muito comum quando fazíamos integração de sistemas. Você dentro de uma própria empresa dissonância semântica entre próprios departamentos, o mesmo conceito era visto em departamentos distintos de forma completamente diferente.

Com um olhar de fora você conseguia fazer essa composição e fazer com que eles conversassem mesmo sem um esforço, sem que eles percebessem que estavam criando o encapsulamento dessas soluções e eles nessa camada de abstração mais superior estavam interagindo com essas soluções e trocando semanticamente e interagindo.

Então eu fico muito preocupado porque eu acho que a gente precisa encontrar soluções mais ideais, e se a gente perder um pouquinho esse diálogo e essa comunicação que está acontecendo, nós vamos tentar em um momento que não vai ser mais possível. Eu vejo um grande potencial, uma grande necessidade, uma grande oportunidade com os eventos, os eventos são um primeiro passo, precisamos tentar articular outra coisa que possa ser um start, a gente precisa desse start que vai ser como o professor Guilherme colocou hoje cedo o spin off do spin off, precisamos pensar em alguma coisa.

Plácida:

Em relação ao que o professor Ricardo apontou, eu tenho uma visão dos próximos passos. Em 1990 nos instalamos na UNESP o primeiro grupo de informação e tecnologia, que foi o nosso Grupo de Pesquisa Novas Tecnologias de Informação, instalado na área da Ciência da Informação junto ao CNPq. Isso causou muita estranheza e nós sempre éramos vistos como a ovelha negra da área da Ciência da Informação porque para tratar de tecnologia na Ciência da Informação. Durante os anos de 98, 99 e 2000, nós tivemos a luta na CAPES para a aprovação do programa de pós-graduação em Ciência da Informação da UNESP.

Quando nós levamos isso para discussão, tecnologia não faz parte da área da Ciência da Informação. Tivemos que lutar muito para a instalação da linha de Informação e Tecnologia em um programa da Ciência da Informação, que depois foi muito bem-visto e a gente tem alegria de saber que 90% dos programas de pós-graduação em Ciência da Informação hoje tem uma linha de tecnologia.

Especialmente em 2005 e 2006, tivemos uma luta muito acirrada dentro da ANCIB para colocar o GT8, e participaram dessa luta o professor Guilherme, o professor Sayão, o professor Ricardo, participamos de cinco ENANCIB para poder autorizar a instalação do GT8. Parece horrível não ter sido uma autorização imediata, como existiu em outros momentos na situação de outros grupos, mas não é. Se você for pegar a história, e é importante relatar isso aqui, na história das tecnologias nós tivemos um grupo de tecnologia instalado no histórico do ENANCIB, mas em um determinado momento esse grupo de tecnologia ficou exatamente um grupo da Ciência da Computação dentro da Ciência da Informação.

Era só Ciência da Computação mas era uma Ciência da Computação fraca, não tinha identidade na computação e nem aderência na Ciência da Informação, então o grupo foi se

esvaziando por ele mesmo. A fala na época do GT8 foi que a tecnologia não tem a ver com a Ciência da Informação porque ela perpassa todos os grupos, não dá pra ter um grupo só estudando tecnologia, essa era a fala da época em que nós lutamos muito para que o GT8 fosse instalado.

E temos que lutar para que isso não aconteça, para que a gente não transforme o GT8 em uma Ciência da Computação fraca e uma não aderência a Ciência da Informação, por isso é importante essa questão da identidade, a interação, a interdisciplinaridade presente nos tópicos estudados pela Ciência da Informação em conjunto com uma equipe multidisciplinar na gestão de dados.

Em 2013 nós tivemos o primeiro DTI, depois tivemos em 2014, 2015, e 2016 nós notamos que todo mundo falava em dados. A partir daí todo mundo fala em dados na Ciência da Informação, pode não saber o que é dado, mas ele coloca ali como palavra-chave ou faz parte do título.

Aí em 2017 e 2018 tem o WIDAT e cada vez maior a aderência com a questão dos dados. O que eu estou notando que os espaços entre o lançamento da ideia e a coesão está sendo muito curto. Lembra das ondas de evolução, nós estamos percebendo isso na área. E me preocupa como nós vamos fazer isso na graduação, o meu problema é sempre na graduação porque é dali que sai os profissionais, como vai atuar, em que momento eu vou tratar dessa questão na graduação, era só uma ponderação para vocês verem como as coisas estão se estreitando.

Sandra:

Aqui um ponto que gostaria de destacar antes de abrir para quem quiser fazer questionamento, é que além dos conhecimentos que a gente está falando e colocou aqui, que a professora Plácida também chamou a atenção, é a questão do desenvolvimento de competências, fora o conhecimento a competência de querer aprender sempre, de saber se comunicar, de ética, de responsabilidade, de buscar sempre atualização, isso é coisa que a gente tem que comentar desde o início, tem que motivar nesse sentido e investigar profissionais.

Vamos sair de nossa zona de conforto, sempre adicionar esse elemento novo e como nossas pesquisas podem colaborar com esse campo novo. Então agora eu queria abrir para ver se tem algum questionamento que queiram fazer.

Vídeo da apresentação

Título: A questão da identidade da CI frente aos cenários apresentados do paradigma dos dados.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=37

A emergência dos dados de pesquisa na ciência contemporânea

The emergence of research data in contemporary science

Wagner Junqueira de Araújo[a], *Ana Alice Baptista*[b], *Marcello Peixoto Bax*[c], *Pedro Luiz Pizzigatti Corrêa*[d] e *Luís Fernando Sayão*[e]

Transcrição da apresentação

Abertura:

Vamos dar início a mesa-redonda intitulada "A emergência dos dados de pesquisa na ciência contemporânea", para moderar gostaria de convidar o professor Dr. Wagner Junqueira, do Programa de Pós-Graduação em Ciência da Informação da Universidade Federal da Paraíba. Convidamos a professora Dra. Ana Alice Batista, professor Marcello Bax da UFMG, professor Dr. Pedro Luiz Corrêa e professor Dr. Luís Fernando Sayão.

Wagner:

Boa noite a todos, é um imenso prazer estar aqui, agradecer o professor Guilherme e todos que estão organizando. Surgiu um assunto muito interessante e que a Ciência da Informação vem trabalhando já a alguns anos com isso daí, e o contexto da ciência no Brasil é uma coisa delicada com esse compartilhamento de dados que nós vimos durante o dia. Então eu vou fazer alguns questionamentos aqui na mesa, vou passar para cada um para comentar, porque nós vimos alguns desafios, como dos metadados descritivos, o professor Sayão fez uma exposição sobre os elementos que convergem na área de ciência, e Pedro expôs algumas dificuldades e desafios desse tema.

Mas aqui no Brasil a gente teve alguns processos que foram superados, um exemplo seriam os periódicos eletrônicos, a alguns anos atrás ninguém falava em publicar em periódico eletrônico porque não tinha estruturada. Hoje a quantidade de revistas são incontáveis. Por outro lado nós tivemos uma experiência muito ruim que foram os repositórios digitais das instituições de pesquisa das universidades e no final a gente acabou todo mundo nadando e morrendo na praia.

Aí minha pergunta é na seguinte linha, aqui no Brasil, como é que nós fazemos para gerenciar uma infraestrutura de dados, e não discorrer sobre os ciclos de dados que nós discutimos hoje, mas o que esperar das instituições de pesquisa, dos órgãos de pesquisa, de grupos de interesse comum, algum órgão de governo, a gente tem o arquivo nacional que o Sayão e conselheiros estão trabalhando nas questões de repositórios digitais, quem seriam esses órgãos?

a Universidade Federal da Paraíba (UFPB). E-mail: wagnerjunqueira.araujo@gmail.com. ORCID: http://orcid.org/0000-0002-2301-4996. Currículo: http://lattes.cnpq.br/6762905361803183

b Universidade do Minho (Uminho). E-mail: analice@dsi.uminho.pt. ORCID: https://orcid.org/0000-0003-3525-0619. Currículo: http://www.degois.pt/visualizador/curriculum.jsp?key=4103065722022437

c Universidade Federal de Minas Gerais (UFMG). E-mail: bax@eb.ufmg.br. ORCID: https://orcid.org/0000-0003-0503-3031. Currículo: http://lattes.cnpq.br/1864473087690223

d Universidade de São Paulo (USP). E-mail: pedro.correa@usp.br. ORCID: https://orcid.org/0000-0002-8743-4244. Currículo: http://lattes.cnpq.br/3640608958277159

e Centro de Informações Nucleares (CIN). E-mail: lsayao@cnen.gov.br. Currículo: http://lattes.cnpq.br/3422623122948389

Porque esperava parte de nossa política que a gente tenha uma atividade dos profissionais da área que começam a trabalhar e percebem esse problema e desafio, então quem seria esse órgão gestor ou se teria algum órgão para trabalhar isso aí?

Mas a ideia é essa, nós teremos alguma organização para isso, alguma organização de pesquisadores no Brasil que criam estruturas, o Sayão citou o ResearchGate que além de rede social de pesquisadores serve como repositório, plataforma de serviço, como é que seria, eu vou passar para vocês. Passar primeiro para a professora Ana que tem uma visão de fora porque a gente aqui no Brasil fica um pouco angustiado com essa situação.

Ana Alice:

Eu não vou falar especificamente sobre a organização, a coisa que eu queria dizer é que eu gosto dos modelos brasileiros. Eu acho que a gente precisa atuar em vários momentos, agora precisa de alguém para administrar alguém, alguém fazendo as coisas andarem. Essa é minha primeira perspectiva, sem pensar muito vamos dizer assim.

Marcelo:

Eu acho que esse evento é fundamental para a Ciência da Informação, a gente precisa continuar e precisa ser estudado porque é uma grande oportunidade, acho que todos nós que estamos aqui enxergamos esse tema como uma grande oportunidade que a Ciência da Informação não pode perder.

Obviamente sem se descaracterizar, sem perder identidade como o professor Ricardo colocou, mas abraçando com toda legitimidade que a Ciência da Informação tem para lidar com esse problema dos dados. Diria até sobrevida das fases iniciais do ciclo de gestão dos dados, dados científicos, dados de negócio, principalmente dados científicos, que são aquelas fases de aquisição e preparação dos dados.

As palestras do professor Sayão, do professor Pedro, foram na direção de mostrar que há muita coisa a ser feita antes de que o dado possa ser analisado. A questão de métrica, de registro, proveniência, alinhamento semântica, a importância das ontologias nesse tema para integração e reuso dos dados científicos, para preservação dos dados científicos.

Essa pergunta em questão do Wagner foi interrogada por alguém da plateia, alguém que deve ser monitor de um repositório de alguma instituição de uma universidade, eu fiquei pensando nisso e a ideia aqui é que fazemos um bate-bola e vocês também participem, opinem, que a mesa seja bem aberta aqui para ouvir vocês. Então alguém perguntou isso e a minha opinião é que deve ser bottom up e top down, a gente tem que ter às sociedades científicas de alguma forma se organizando como a gente vê em países mais desenvolvidos, isso acontecendo massivamente. Acabo de retornar de um pós-doc nos EUA onde tem milhões e milhões de dólares investidos no desenvolvimento de repositório, sobretudo na saúde, porque às pesquisas na área de saúde são extremamente caras, então é muito importante utilizar os dados em questão econômica de racionalização de gastos é fundamental para a economia da pesquisa americana hoje. São milhões de dólares no apoio a construção desses repositórios.

Acho que nesse ponto nós temos que ter iniciativas de todos os lugares, eu acho que é legítimo que a área como de repente metodologia em uma universidade se valha de uma ferramenta de software livre e promova dentro da área o incentivo de compartilhamento de dados. Mas é importante também que a Reitoria da universidade estejam pensando no sentido de comentar, formar recursos humanos, eu acho que é uma oportunidade gigantesca de informação, formar bibliotecários de dados com todos os conhecimentos, e isto não está restrito a nenhuma disciplina específica. Lá na computação e administração me parece que é uma ação da Ciência da Informação, acho que mais uma vez legitimar deve surgir de vários locais.

Eventos como esse, eu acho que deve um futuro brilhante para a Ciência da Informação, fico contente em participar e estar aqui falando com vocês sobre um tema que é importante para a Ciência da Informação.

Pedro:

Mais ou menos na linha que foi colocada aqui, seguindo a questão de ser distribuída, orquestrada, a questão de que a gente tem hoje instituições preocupadas com o tema no Brasil, cada um tem sua responsabilidade. Acho que esse evento tem responsabilidade no sentido de criar demandas de pesquisa pro Brasil, começar a mostrar visões, eu acho que esse é o papel desse evento, e articular a comunidade da Ciência da Informação com a Computação e outras áreas, tem esse papel, e os órgãos de fomento eles têm um papel importante no sentido de valorizar a disponibilização e qualidade dos dados científicos, começar a reconhecer a questão da disponibilização dos dados para ofertar bolsas, na questão do reconhecimento da carreira do pesquisador, a gente precisa começar a colocar isso de maneira mais incisiva e cobrar isso dos órgãos de fomento.

As instituições de pesquisa de uma maneira geral, tem conversado muito com as entidades para que os seus pesquisadores passem a gerar dados, disponibilizar esses dados com qualidade, e tenham mecanismos de revisão, esse é um ponto importante, não significa apenas disponibilizar mas significa saber da qualidade daquilo que está sendo disponibilizado.

As universidades também tem que se preocupar com o tema, eu vejo por exemplo, na USP a gente conhece um programa que eu gosto muito porque ele não só cria na universidade baseado em modelos, mas disciplina e envolve a comunidade o tempo todo, a comunidade ativa com relação aquele assunto, define às boas práticas. Isso é fundamental para as instituições de pesquisa e universidades criarem. Repositório novo a gente não vai ter com um intuito só, nós vamos ter vários repositórios, o importante e aí vem a visão do profissional em Ciência da Informação de identificar junto com a demanda do seu usuário qual é a melhor solução.

O importante é você publicar esses dados e deixar disponível seus dados e seus metadados. Eu vejo assim, protagonismo da Ciência da Informação nessa área é fundamental na área de Ciência dos Dados que tem uma demanda enorme, a gente está vendo um levantamento de Recursos Humanos, só na Europa nos próximos anos a demanda de 100 mil profissionais na área. A média de salário dessa área gira em torno de 10 mil dólares por mês, então é um profissional valorizado.

O profissional da informação tem um papel fundamental na gestão dos dados científicos com a habilidade na área de negócio, essa gestão de dados acabam gerando conhecimento para outra, as áreas se conversam. Só para vocês terem uma ideia, nos projetos que a gente participa no pós-doc as pessoas da Ciência da Informação no nosso projeto de pesquisa acabaram sendo contratados no meio do projeto para fazer a gestão, e a gente tava perdendo gente do time para as empresas, porque é normal isso.

A valorização tanto do pesquisador quanto do profissional, o mercado vai colar rapidamente, eu vejo a questão do profissional da Ciência da Informação com o papel de protagonista nessa área, e a gente não pode perder essa oportunidade no sentido de gerar condições para que tudo isso aconteça, do ponto de vista da legislação, do ponto de vista da estrutura, do ponto de vista do fomento, do ponto de vista da formação de recursos humanos, a gente tem que olhar nossas responsabilidades para não perder essa onda.

Porque essa onda uma hora passa, nós já vimos várias ondas mais importantes passando na vida da gente, então essa onda vai passar também. Se a gente não for protagonista e assumir nós vamos perder essa oportunidade. A gente está com a faca e o queijo na mão como relação a esse tema.

Sayão:

Eu queria falar um pouco de algo que eu acho importante nos dados, especialmente esses dados da cauda longa, é em relação às bibliotecas de pesquisa ou especializadas, a investigação das literaturas têm mostrado que às bibliotecas de pesquisa estão em uma crise terrível. A gente observou em um artigo alguns anos atrás, será que o futuro da biblioteca de pesquisa não é o e-Science, e a gente fez um levantamento dos problemas e desafios. Um dos problemas é que acabou o relacionamento amoroso entre os usuários e sistemas de bibliotecas, e a biblioteca não é um lugar que o pesquisador procura para descobrir informação. Ele sempre procura na Internet e na Web e a biblioteca acaba sucumbindo e não acompanha esse desenvolvimento.

A crise da biblioteca de pesquisa não foi uma coisa local, é universal, às instituições que tem pós-graduação de alguma forma tem mas os pesquisadores não vão à biblioteca. E assim acaba que essa questão dos dados traz de volta o protagonismo dos objetos científicos, especialmente por não ser retrabalho nessa questão da cauda longa.

O que eu observo é que no mundo todo as bibliotecas de pesquisa começam a retomar esse papel importante em relação ao status. Isso se dá diante da seguinte situação, meu lugar, a gestão de dados, ela é pró-comunicação, sempre divulgou, tratou e são publicadas, só que agora a biblioteca tem que preocupar com a pré-comunicação, com o planejamento dos dados, com um plano de gestão de dados, tem que ajudar o pesquisador a fazer o plano de gestão de dados quando ele cria o projeto dele para o CNPq ou FAPESP.

Você tem que ter essa preocupação e a biblioteca passa a atuar junto, em uma fase anterior à publicação, e nessa situação ela vai ter que atuar muito próxima ao pesquisador, aí aquele clima amoroso em biblioteca, bibliotecário e usuário retoma. A gente teve essa experiência e impulsiona, a biblioteca é parte do processo dentro dos centros de pesquisa, a biblioteca oferece

cursos de gestão de dados, cursos para o pesquisador do bibliotecário de dados, e vai ser também uma referência.

O autor da referência muda nessa situação, então a gente tem uma aproximação do bibliotecário da biblioteca de pesquisa com o pesquisador, a gestão de dados dentro da biblioteca vai funcionar dessa forma, senão a gente volta a situação anterior desse distanciamento. Essa aproximação também se dá com o profissional da informática, então a gente tem uma nova situação em que essa aproximação é fundamental. Isso que tem que levar para dentro da biblioteca, a biblioteca como um apoio a gestão, como apoio a treinamento do pesquisador, como uma referência.

Essa iniciativa de gestão de dados ela renova a Ciência da Informação sem esquecer os pressupostos, todos os pressupostos que parte da Biblioteconomia, Arquivologia e Ciência da Informação, são tomados e são valorizados pelas áreas de informática e de pesquisa. Você tem uma renovação apoiada nos pressupostos básicos desta metodologia. Então nós temos duas coisas positivas que podem ser atendidas, é isso que eu tinha em relação a isso.

Wagner:

Obrigado Sayão, recentemente a gente fez um trabalho de gestão de dados dentro das bibliotecas e a gente entrou em contato o pessoal do STI, com o pessoal da reitoria e da biblioteca central, então na visão do bibliotecário eles não percebem que isso está mudando, na cabeça deles parece que vão trabalhar com livro pro resto da vida. Mas isso está mudando e o bibliotecário tem que se renovar.

Um outro questionamento para vocês que são questões que me angustiam aqui nessa universidade, como é que a gente busca financiamento para tirar essas ideias do papel? Através de parcerias ou financiamentos coletivos? Talvez esse seja o caminho que a gente consiga seguir, ou vocês que pensam em fazer um pós-doc fora, como é que a gente trabalha essa questão. Aqui no Brasil a gente vê que sem ter um órgão fomentador as coisas acontecem muito esparsa. Então qual seria o caminho para conseguir esses financiamentos e esses recursos, até mesmo como treinamento para o pessoal, não para comprar equipamento mas para preparar o pessoal, treinar essa nova geração de bibliotecários, arquivistas e cientistas da informação, cientistas de dados que estão sendo preparados para os próximos anos. Depois eu abro aqui para os participantes fazerem suas questões para mesa.

Marcelo:

Eu acho que uma questão bem pertinente essa questão de como é que a gente ensina esses agentes. Uma coisa é verificar os agentes envolvidos nesses processos, então olhar tudo. A gente tem o olhar dos financiadores, o olhar das agências de pesquisa, as escritoras, as empresas, existe um ecossistema ai.

Nesse ecossistema cada um tem muito interesse, primeiro uma coisa que a gente identificou é que o setor privado tem interesse nessa área. Por exemplo, as empresas de consultoria montam modelos e times de ciência dos dados hoje. O banco Itaú foi montar um setor de ciência dos dados, por exemplo.

Agora qual é o perfil do profissional que eu preciso? As empresas teriam colocado um profissional da Ciência da Informação porque é ele que vai articular e saber o fluxo de dados na empresa, como ocorre o acesso. Então a gente precisa começar a trabalhar mais com o mercado, acho que isso é um ponto importante. O mercado vai financiar isso porque ele tem interesse nisso, ele precisa desse skill, ele precisa ter essa habilidade.

O problema é os entraves que existem para as instituições e universidades, por exemplo, na USP a gente demorou para montar o projeto quase um ano, porque a coisa vem e volta, e a passa, em um dois anos as pessoas passam. A gente precisa melhorar um pouco os nossos mecanismos de trabalhar os recursos privados, mas existe e a gente precisa aproveitar essas oportunidades, a demanda é grande.

Em termos de instituições do governo eu não vejo muito a possibilidade de aumentar recursos que a gente tem, os recursos são escassos, o que o governo tem são as facilidades e esse é um ponto. Criar mecanismos que viabilizem esse tipo de coisa, da mesma forma que existem mecanismos de isenção de impostas, você criar ações para ter outras estratégias de financiamento.

A gente falou que existe esse interesse do setor privado, e um outro ponto que a gente identificou, é que os órgãos de financiamento de uma maneira geral, eles têm criados esses programas especiais. A gente na universidade fica muito aquém disso, por exemplo, o pessoal do ORCID, que desenvolve os verificadores de objeto hoje eles estão trabalhando e querem valorização, é importante no Brasil e qual é a colaboração do Brasil nisso, como a gente está colaborando de fato. Nós estamos participando das discussões?

E tem recursos internacionais envolvidos hoje, a gente precisa estar atento nisso. Existe disponibilidade de recursos por isso é importante a gente ter essa articulação internacional. Eu sei que a gente não está no mesmo nível que eles, a gente pode participar de projetos com ele para entender os problemas e começar a ajudar e contribuir nas soluções.

Em termos de recursos eu vejo essas duas oportunidades que estão disponíveis, é questão da gente olhar para essas oportunidades e começar a trabalhar de maneira mais colaborativa com o exterior e com o setor privado. E um ponto que eu queria falar mais é sobre como nossa comunidade colabora, eu mesmo acho que sou culpado disso, mas é a primeira vez que estou em um evento oficial da área de Ciência da Informação e eu estou sentindo falta de ter esses eventos e participar desses eventos. Eu preciso ter uma colaboração maior com nossa comunidade, uma maior articulação. Isso não é financiamento, mas é importante convencer os órgãos oficiais de ter programas nessa área.

Infelizmente a gente não pode ficar dependendo de um programa da FAPESP, quais são as opções do CNPq que existem nessa área para financiar recursos de projetos colaborativos, a gente precisa começar a olhar para isso e a gente como comunidade aqui pode estabelecer essas demandas, então eu vejo essas três oportunidades aqui, obrigado.

Sayão:

Eu queria colocar aqui alguns números importantes nessa questão de dados e financiamento. Nós temos uma situação muito complicada aqui no Brasil que é financiar os dados com verbas de projetos que incluam no máximo 3 anos. Uma coisa que é perene, por

exemplo na área pública, você tem o dinheiro aplicado a 3 anos. Na verdade você está dando dinheiro do projeto para poder criar estruturas de gestão de dados, isso é um complicador.

Mas tem uma coisa que é importante que um relatório que saiu o ano passado fala o seguinte, uma plataforma de dados ou um repositório de dados, custa quatro vezes mais caro que um repositório de publicações, então o custo para tratar os dados é mais caro. Outro ponto é que os custos da gestão de dados é 14% do custo do projeto, da verba para pesquisa. Outro número importante, o pesquisador para poder organizar, limpar, processar, retrabalhar os dados antes de publicar, segundo o pessoal do FAIR ele gasta metade do tempo fazendo isso.

Existe aí uma coisa super complicada, é que o pesquisador gasta muito tempo e muito recurso para poder organizar os dados e publicar. Só que ele não tem uma contrapartida em termos de recompensa, então ele prefere fazer o artigo e deixar os dados desorganizados para lá.

A gente precisa de uma política que considere essa organização dos dados com valor de uma forma que você no artigo ou revista de qualis A é importante, senão a gente não vai adiante nisso. Precisamos ter uma política ampla no nível elementar até as políticas comunitárias para poder ir adiante. Publicar é complicado, gerenciar dados é muito mais complicado, então é essa questão.

Marcello:

Só complementando o que o Sayão acabou de dizer, há uns dois anos atrás eu participei durante um ano e meio da COEP na UFMG, você sabe que toda instituição que realiza pesquisa tem que ter um comitê de ética, isso é uma resolução nacional e eu me lembro bem que nessas discussões do aspecto ético da pesquisa, acho que todos que coletam dados sobretudo dados relativos ao ser humano, não necessariamente da área de saúde mas desde que haja alguma relação ética entre o pesquisador, deve passar pelo comitê de ética. Eu quero dizer o seguinte, a comissão de ética uma das coisas que ela exige é o que o pesquisador pretende fazer com os dados, e isso a gente analisava lá durante um ano e meio participando, e todo pesquisador que submetia pra COEP mas todo pesquisador deve dizer o que ele vai fazer com os dados depois no final da pesquisa.

Sabendo o que ele vai fazer com os dados é importantíssimo para obter sucesso lá na coleta, então eu acho que eu vejo aí um potencial enorme de auxílio nas bibliotecas, assim como o pesquisador envia para COEP ele deveria chamar um bibliotecário e perguntar o que fazer com os dados, que ferramentas de software livre existe. A Ciência da Informação precisa formar esse sujeito para auxiliar os pesquisadores.

Só terminando eu acho que a gente está vivendo uma revolução na área de comunicação e informação, a gente está vendo o Washington Post foi salvo pela Amazon, que comprou o Washington Post e mudou o modelo de negócio e salvou o Washington Post.

A gente tem a Saraiva uma das maiores empresas de cultura de informação quebrando, a Saraiva pediu judicial por 350 milhões de reais, e a Saraiva tem mais de 100 anos. Será que a Ciência da Informação não está vendo isso, eu acho que não. Acho que eventos como esse que vão abrir os olhos.

Eu acho que as bibliotecas, o próprio jornalismo precisa usar as irmãs Ciência da Informação e a Comunicação, também há uma crise no jornalismo a gente viu recentemente, que são movimentos que estão por trás de uma revolução muito maior, que a Ciência da Informação precisa enxergar e as bibliotecas têm protagonismo e potencial gigantesco, mas é preciso formar as pessoas

Eu fico muito feliz que tem 21 anos que eu estou na Ciência da Informação, e eu vejo hoje depois de 21 anos meus alunos se submetendo a fazer BPM e ciência dos dados dentro das empresas mas com uma legitimidade interessantíssima, porque a legitimidade é marcada porque alguém da computação que veio para a Ciência da Informação diz que essas pessoas estão explorando os processos, a própria gestão de documentos eletrônicos, esses domínios, a gente vê os alunos se despontando.

O mercado está demandando mas o mercado não sabe muito bem o que demandar, a verdade é essa, então a reação natural do mercado é ir para a computação, mas não é na computação na verdade eles tem desenho por essa questão, não pela ciência dos dados mas por todas essas questões de organização, da ciência, é secundário. A Administração também não está se preocupando com isso, então é uma área que a Ciência da Informação precisa retornar, e eu acho que eventos como essa mais uma vez fazem isso, portanto tem-se a importância aí.

É explorar novas formas de fomento junto ao mercado, sem dúvida alguma. A CAPES está com um programa agora que acabou com esse negócio de bolsa de pós-doutorado, se quiser fazer parceria internacional vai seguir um edital. Na UFMG tem um movimento enorme lá da pró-reitoria de pós-graduação juntando os PPGs para juntos fazerem parcerias com as instituições internacionais. Precisa ter dinheiro para enviar pesquisadores, mas não é mais aquela coisa de balcão de pedir o pós-doc, porque o grande problema da CAPES é o seguinte, eu dou uma bolsa de pós-doc e o sujeito vai para o exterior, volta e nunca mais, não dá continuidade, por isso eles querem acabar com isso.

Portanto agora quem quer ir para o exterior vai ter que se articular com outros programas para ter parcerias externas e assim nesses contextos institucionais que são contextos que predispõem uma manutenção da evolução da parceria acontecer.

Eu acho que do ponto de vista do fomento, as coisas também estão mudando, e vão mudar drasticamente daqui para frente, e vamos ter que pensar em formas para conseguir isso.

Ana Alice:

Queria dizer que eu concordo com tudo que foi dito, todas as formas de financiamento são interessantes, eu penso também que o Estado deve financiar pelo menos parte dos dados que são disponibilizados ou do processo de investigação, etc. Porque senão tem coisas que não vão ser disponibilizadas.

Wagner:

Obrigado a todos, eu passo então para plateia interagir.

Vídeo da apresentação

Título: A emergência dos dados de pesquisa na ciência contemporânea.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=38

Slides da apresentação

Título: A emergência dos dados de pesquisa na ciência contemporânea.

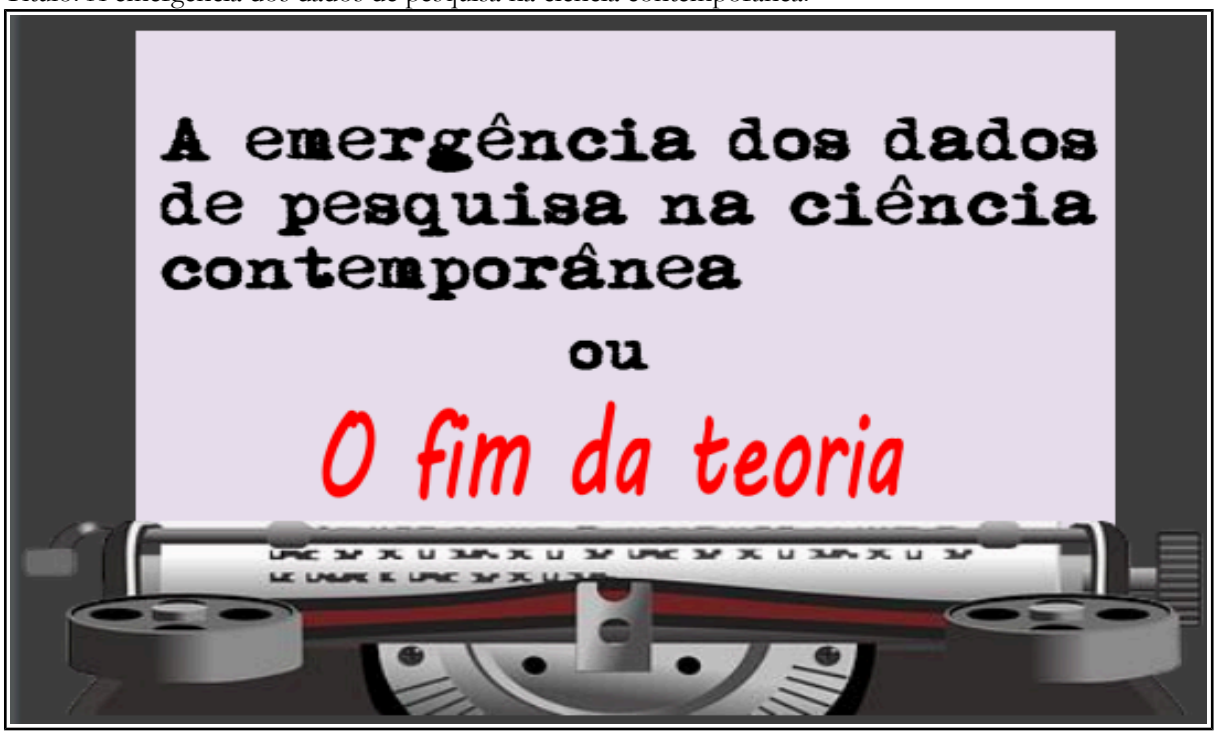

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=38

Os princípios FAIR como diretrizes para maximizar o uso e (re)uso dos dados de pesquisa: traçando um paralelo com a gestão de documentos arquivísticos digitais

Pedro Jácome de Moura Jr.[a], *Maicon Henrique Ferreira Aragão*[b] *e Bruno Cesarino Soares*[c]

Resumo: Aborda o que são os princípios FAIR, seu surgimento e sua aplicação para maximizar o uso e reúso de dados de pesquisa. Buscou-se traçar um paralelo com a gestão de documentos arquivísticos digitais e como ambos podem contribuir na gestão de dados de pesquisa. É por isso que o objetivo principal deste artigo consiste em compreender como os princípios FAIR e a gestão de documentos arquivísticos digitais podem contribuir para tal gerenciamento. Metodologicamente, a pesquisa é de natureza aplicada, possui caráter exploratório, e seu procedimento técnico é de uma pesquisa bibliográfica. Foram então estudados os princípios e diretrizes do FAIR, como também da gestão de documentos arquivísticos digitais. Estabelece-se as semelhanças e os pontos em comum das ferramentas usadas para gerir dados e documentos digitais. A partir do paralelo traçado conclui-se que por mais que os objetos digitais (dados e documentos) possuam diferenças, existem semelhanças em relação a sua curadoria, procedimentos em comum em relação ao encontro, acesso e reúso de dados e documentos.

Palavras-chave: Princípios FAIR. Gestão de dados de pesquisa. Gestão de Documentos Arquivísticos Digitas.

FAIR principles as guidelines for maximizing the use and (re) use of research data: Drawing a parallel with the management of digital records

Abstract: It addresses what FAIR principles are, their emergence, and their application to maximize the use and reuse of research data. It sought to draw a parallel with the management of digital archival documents and how both can contribute in the management of research data. This is why the main goal of this article is to understand how FAIR principles and the management of digital records can contribute to such management. Methodologically, the research is of an applied nature, has an exploratory character, and its technical procedure is a bibliographical research. The principles and guidelines of FAIR were studied, as well as the management of digital archival documents. It establishes the similarities and points in common of the tools used to manage data and digital documents. From the parallel traced it is concluded that although the digital objects (data and documents) have differences, there are similarities with respect to their curatorship, common procedures in relation to finding, accessing and reusing data and documents.

Keyword: FAIR principles. Managing search data. Management of digital archival documents.

a Universidade Federal da Paraíba (UFPB). E-mail: pjacome@sti.ufpb.br. ORCID: https://orcid.org/0000-0001-6548-4614. Currículo: http://lattes.cnpq.br/5392174861908041

b Universidade Federal da Paraíba (UFPB). E-mail: maiconhenriq_ilhadg@hotmail.com. Currículo: http://lattes.cnpq.br/3154990148316655

c Universidade Federal de Minas Gerais (UFMG). E-mail: brunocesarino@hotmail.com. ORCID: https://orcid.org/0000-0002-4122-2051. Currículo: http://lattes.cnpq.br/8435050057210820

1 Introdução

Os princípios FAIR foram desenvolvidos em uma conferência sobre Ciências da Vida. Nessa conferência foram propostas e aprovadas pela comunidade científica um conjunto de diretrizes que tratassem da encontrabilidade, acessibilidade, interoperabilidade e reúso da vasta quantidade de dados produzidos pela ciência. Os princípios propostos têm como objetivo fazer com que um conjunto de dados possa ser encontrável (findable), acessível (acessible), interoperável (interoperable) e reusável (reusable) (WILKINSON et. al, 2016). Os princípios FAIR surgiram a partir dos fenômenos da e-science, da ciência aberta e principalmente da necessidade do gerenciamento de dados de pesquisa. É primordial entender o que são dados de pesquisa para saber como tratá-los e preservá-los. Conhecer como surgem, suas fases e sua natureza é essencial para compreender os princípios FAIR.

A OECD (2007) conceitua dados de pesquisa como registros, sendo eles: escores numéricos, registros textuais, imagens e sons que são utilizados como fontes primárias da pesquisa científica de forma a validar seus resultados. Um conjunto de dados de pesquisa é a constituição da representação do sujeito ou objeto investigado. Tal termo não se refere a cadernos de laboratório, análises preliminares, rascunhos de artigos científicos, planos para pesquisas futuras, revisão por pares ou comunicações com colegas ou objetos físicos (por exemplo, amostras de laboratório, bactérias e teste em animais como ratos). Tais princípios e diretrizes estão voltados, principalmente, para os dados de pesquisa legíveis por computador, pois neste formato é que reside o potencial de melhorias na distribuição eficiente dos dados e sua aplicação para pesquisa.

Dataone (2018) ressalta que o ciclo de vida de dados compreende as fases do planejamento, coleta, asseguramento, descrição, preservação, descobrimento, integração e análise de dados. Isso tudo é cíclico, pois os dados podem ser úteis não só para a pesquisa que os gerou, mas para outras pesquisas com diferentes intenções do original. Para que a gestão de dados seja aplicada corretamente, é necessário termos um plano de gestão de dados. O planejamento então é essencial para a gestão, deve-se começar a partir do início da pesquisa, considerando como os dados serão gerenciados e como serão compartilhados futuramente. Ou seja, o plano de gestão de dados é um documento formal no qual se estabelece o compromisso de como tais dados serão tratados durante o desencadeamento da pesquisa, como também após a sua conclusão (SAYÃO; SALES, 2015).

Em paralelo aos princípios FAIR, ciclo de vida de dados e o plano de gestão de dados, tem-se a Gestão Arquivística de Documentos Digitais. Por mais que o conceito do que são dados de pesquisa, seja diferente do significado de documento arquivístico digital, os conjuntos de dados e os documentos digitais possuem algumas semelhanças na forma em como devem ser gerenciados.

A preocupação sobre serem encontráveis, interoperáveis, acessíveis, reusáveis e preservados existem em ambos objetos digitais. Paes (2005, p.26) conceitua documento como "registro de uma informação, independentemente de sua natureza do suporte que a contém." Logo complementa que o documento de arquivo é aquele que é produzido e/ou recebido por instituição pública ou privada no exercício de suas atividades, que tem como objetivo constituir como elemento de prova ou informação. Também pode ser produzido ou recebido por

indivíduos ao longo de sua existência (PAES, 2005). O Arquivo Nacional (2005, p.75) traz a seguinte definição sobre documento digital: "documento codificado em dígitos binários, acessível por meio de sistema computacional." Um dos fatores que preocupa o gerenciamento de documentos digitais é em relação a sua preservação, visto que os meios digitais são bastante voláteis afetando questões como fragilidade do suporte, obsolescência de produtos de software ou programas de computador, formatos de arquivo, falta de confiabilidade e do espaço de armazenamento.

Em síntese, constata-se que apesar de diferentes, conjunto de dados e os documentos arquivísticos digitais possuem características em comum. Ambos os gestores procuram exercer cuidados em relação a sua curadoria. Este trabalho procura explorar como é feito o uso e reuso de dados de pesquisa a partir do princípio FAIR e como é feita a gestão de documentos arquivísticos digitais, mostrando então suas semelhanças e como estes podem contribuir para a gestão dos dados de pesquisa.

2 Objetivos

Objetiva-se compreender como os princípios FAIR e a gestão de documentos arquivísticos digitais podem contribuir para o gerenciamento de dados científicos. Em relação aos seus objetivos específicos têm como intenção: conhecer os princípios orientadores FAIR; entender as diretrizes e princípios sobre gestão de documentos arquivísticos digitais e; estabelecer as semelhanças entre os princípios FAIR e a gestão de documentos arquivísticos digitais.

3 Procedimentos Metodológicos

Esta pesquisa classificada como de natureza aplicada, pretende gerar conhecimentos sobre os princípios FAIR associados a gestão de documentos arquivísticos digitais, visando sua aplicação na prática para solucionar os problemas de gerenciamento de dados. Caracteriza-se como exploratória, pois traz à tona o problema do gerenciamento de dados de pesquisa, e levanta estudos bibliográficos para a construção de soluções que possam colaborar com a gestão e preservação dos dados de pesquisa. Em relação aos seus procedimentos técnicos é classificada como uma pesquisa bibliográfica, porque "é desenvolvida com base em material já elaborado, constituído principalmente de livros e artigos científicos." (GIL, 2002, p.44).

4 Discussões

Primeiramente abordaremos sobre o que são os princípios FAIR e como se desenvolve a gestão de documentos arquivísticos digitais. Trata da comparação entre o gerenciamento de dados de pesquisa e o de documentos arquivísticos digitais.

4.1 Princípios FAIR

No início deste trabalho foi mencionado que os princípios FAIR surgiram e foram desenvolvidos em uma conferência de Ciências da Vida. Os pesquisadores presentes propuseram e elaboraram quatro princípios para maximizar o uso e reúso dos dados, são eles: Findability (encontravéis), Acessible (acessível), Interoperable (interoperável) e Reusable (reusável). Wilkinson et al (2016) relata que tais princípios servem para orientação dos produtores e editores a como navegar em torno dos obstáculos dos dados.

Estes princípios ajudam a maximizar o valor adquirido nas publicações acadêmicas contemporâneas em formato digital. Em resumo, todos os objetos de pesquisa digitais dos dados para a análise de conduta acadêmica, também devem aplicar os princípios FAIR, pois todos os componentes do processo da pesquisa deverão estar disponíveis para garantir a transparência, reprodução e reúso dos dados. A iniciativa FORCE 11 (2018) publicou diretrizes para seguir os princípios FAIR. A seguir um quadro especificando o que é necessário para se cumprir estes princípios.

Quadro 1 – Diretrizes dos princípios FAIR.

Princípio	Especificações
Encontrável (Findable)	Reencontrável em qualquer ponto no tempo; dados digitais devem ser persistentes, com ênfase em seus metadados; minimamente conter metadados acionáveis por máquina que permitam distingui-lo de outros objetos de dados; uso de identificador único e persistente.
Acessível (acessible)	Devem ser acessíveis, pois devem ser obtidos tanto por máquinas, quanto por humanos; mediante autorização apropriada; por meio de protocolo bem definido; assim máquinas e humanos serão capazes de julgar se o objeto é acessível.
Interoperáveis (interoperable)	Metadados devem ser acionados por máquinas; os (meta) formatos de dados devem utilizar vocabulários compartilhados e ontologias; os metadados dentro dos objetos de dados devem ser sintaticamente reproduzíveis e semanticamente acessíveis.
Reusáveis (reusable)	Os objetos de dados devem estar em conformidade com os princípios da encontrabilidade (encontrável) e interoperável; metadados devem ser ricos para que com o mínimo de esforço humano possam ser ligados ou integrados com outras fontes de dados; deve-se referir as suas fontes com metadados ricos para permitir a citação apropriada.

Fonte: Adaptado do FORCE 11 (2018).

As diretrizes são claras quando enfatizam o uso de metadados e identificadores persistentes, autorizações e licenças para publicação e acessibilidade, como também o uso de vocabulários compartilhados e ontologias para o acesso em geral aos dados.

4.2 Gestão de Documentos Arquivísticos Digitais

O Conselho Nacional de Arquivos (2011) relata que a gestão de documentos arquivísticos trata de procedimentos e técnicas da produção, tramitação, uso, avaliação e arquivamento dos documentos produzidos e recebidos por entidades ou indivíduos no decorrer de sua existência em fase corrente e intermediária. Os documentos então podem passar por até três fases, são elas: corrente, intermediária e permanente.

A fase corrente se refere aos documentos usados com frequência e que são mantidos perto do setor que os produziu. Na fase intermediária os documentos são pouco utilizados e são mantidos longe de seus produtores aguardando prazos prescricionais, em que dependendo de avaliação pode ser eliminado ou recolhido para o arquivo permanente.

Por fim, a fase permanente custódia os documentos que devem ser preservados por seu valor histórico, científico, cultural e informativo. Com o advento das Tecnologias da Informação, os documentos começaram a ser produzidos e armazenados em meio eletrônico.

Para isso, é necessário que a gestão de documentos possa também ser aplicada em meio digital. A seguir o quadro 2 demonstra os procedimentos e ações da gestão de documentos arquivísticos digitais elaboradas pelo Conselho Nacional de Arquivos (2011).

Quadro 2 – Gestão de documentos arquivísticos digitais (procedimentos e ações).

Procedimento	Ações
Captura Consiste no procedimento que declara um documento como documento arquivístico, este procedimento incorpora o documento ao sistema.	Registro, classificação, indexação, atribuição de restrição de acesso e arquivamento.
Avaliação Uma atividade essencial para a gestão de documentos, pois por meio da avaliação é possível racionalizar o grande número de documentos nas fases corrente e intermediária, fazendo então que só os documentos essenciais cheguem a fase permanente.	Retenção dos documentos, eliminação, transferência e recolhimento.
Pesquisa, localização e apresentação dos documentos O sistema deve possuir funções para recuperação e acesso aos documentos e as informações contidas neles, como forma de facilitar o dia a dia das atividades das instituições.	A partir de parâmetros definidos que são selecionadas entre as informações coletadas no momento do registro do documento e entre os metadados associados a ele.
Segurança: controle de acesso, trilhas de auditoria e cópias de segurança. O sistema deve conter controles de acesso e procedimentos de segurança que possam garantir a integridade dos documentos.	Controle de acesso, uso e rastreamento, trilha de auditoria, cópias de segurança e segurança da infraestrutura.
Armazenamento O armazenamento deve garantir autenticidade e o acesso aos documentos pelo tempo estabelecido pela tabela de temporalidade (define o tempo de guarda dos documentos, seja por tempo determinado ou guarda permanente) e sua destinação.	Fatores mais importantes para a seleção das opções de armazenamento: volume e estimativa dos documentos, segurança dos documentos, características do suporte e do ambiente, frequência de uso e custo relativo das opções de armazenamento dos documentos.
Preservação Devem se manter acessíveis e utilizáveis pelo tempo necessário para sua guarda. Deve ter garantido sua longevidade, funcionalidade e seu acesso contínuo.	Prevenção de obsolescência tecnológica e de danos físicos ao suporte que se encontra armazenado, técnicas como migração, refreshing, conversão, emulação, encapsulamento e preservação a tecnologia.

Fonte: Conselho Nacional de Arquivos (2011).

4.3 Pontos em comum

No apêndice A é demonstrado detalhadamente em um quadro, quais os pontos em comum entre os princípios FAIR e a gestão de documentos arquivísticos digitais. Em resumo, notar que a gestão de dados de pesquisa a partir do uso dos princípios FAIR e a gestão de documentos digitais arquivísticos apresentam algumas diferenças em sua forma de administrar seus objetos digitais, contudo, ambas partilham de ferramentas e ações semelhantes na forma de recuperar, acessar e reusar suas informações.

5 Considerações Finais

Os princípios FAIR trazem como pilares serem encontráveis, acessíveis, interoperáveis e os reutilizáveis como preocupações da gestão de dados de pesquisa. Estes princípios focam potencialmente em administração para o uso e reúso dos dados, não abordando a questão da preservação, que também é uma preocupação da gestão dos dados de pesquisa. A gestão de

documentos arquivísticos digitais têm como prerrogativas não apenas a administração, mas assuntos que envolvem a política institucional e preservação dos documentos. Não é intenção fazer uma crítica aos princípios FAIR, pois estes foram criados para maximizar o uso e reúso de dados. A preservação aparentemente não é seu foco. Contudo, os princípios FAIR aliados aos princípios da gestão de documentos arquivísticos digitais demonstram qualidades essenciais na administração e preservação de dados de pesquisa. Quem tende a ganhar com isto é a ciência, pois terá acesso e preservação para o desenvolvimento presente e futuro.

Referências

ARQUIVO NACIONAL (BRASIL). **Dicionário brasileiro de terminologia arquivística**. Rio de Janeiro: Arquivo Nacional, 2005. 232 p.

CONSELHO NACIONAL DE ARQUIVOS (BRASIL). **e-ARQ Brasil**: Modelo de Requisitos para Sistemas Informatizados de Gestão Arquivística de Documentos/ Câmara Técnica de Documentos Eletrônicos. 1.1 versão. Rio de Janeiro: Arquivo Nacional, 2011. 136p. Disponível em: <http://www.siga.arquivonacional.gov.br/images/publicacoes/e-arq.pdf>. Acesso em: 24 set. 2018.

COMISSÃO EUROPEIA. **Guidelines on FAIR Data Management in Horizon 2020**. Versão 3.0. [S.l.: s.n], 2016. 12 p. Disponível em: <http://ec.europa.eu/research/participants/data/ref/h2020/grants_manual/hi/oapilot/h2020-hi-oa-data-mgt_en.pdf>. Acesso em: 24 set. 2018.

DATAONE. **Data Life Cycle**. 2018. Disponível em: <https://www.dataone.org/data-life-cycle>. Acesso em: 24 set. 2018.

FORCE 11**. Guiding principles for Findable, Acessible, Interoperable and Reusable data publishing version b.1.0**. 2018. Disponível em: <https://www.force11.org/fairprinciples>. Acesso em: 24. set. 2018.

GIL, Antônio Carlos. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002. 176 p.

OECD. **OECD Principles and Guideliness for Acess to Research Data from Public Funding**. Paris: OECD Publications, 2007, 24p. Disponível em: <http://www.oecd.org/science/scitech/38500813.pdf>. Acesso em: 24 set. 2018.

PAES, Marilena Leite. **Arquivo**: teoria e prática. 3. ed. Rio de Janeiro: FGV Editora, 2005. 228p.

SAYÃO, Luiz Fernando; SALES, Luana Farias. **Guia de Gestão de Dados de Pesquisa para bibliotecários e pesquisadores**. Rio de Janeiro: CNEN/IEN, 2015. 90p. Disponível em: <http://carpedien.ien.gov.br/bitstream/ien/1624/1/GUIA_DE_DADOS_DE_PESQUISA.pdf>. Acesso em: 24 set. 2018.

WILKINSON, Mark D. et al. *The FAIR* Guiding Principles for scientific data management and stewardship. **Scientific Data**. Nature. 2016. Disponível em: <https://www.nature.com/articles/sdata201618#article-info>. Acesso em: 24 set. 2018.

APÊNDICE A – Semelhanças entre os princípios FAIR e a gestão de documentos arquivísticos digitais.

Princípios FAIR	Gestão de documentos arquivísticos digitais	Pontos em comum
Dados encontráveis	Encontrabilidade de documentos.	Pontos em comum sobre encontrabilidade. (serem encontráveis)
Encontrável a partir dos metadados, uso de identificador persistente, uso de palavras- chave, nomenclatura apropriada.	Uso de identificador, descrição informativa = metadados, recursos de indexação, uso de palavras-chave, documentos encontrados a partir dos metadados.	Uso de identificador, encontrável a partir de metadados, uso de palavras-chave.
Dados acessíveis	Acessibilidade de documentos.	Pontos em comum sobre acessibilidade.
Mediante autorização apropriada, protocolo bem definido, controle de acesso, especificar onde se depositam os dados, metadados, documentação e códigos.	Controle de acesso dos documentos, atributos de segurança, administrador do sistema determina quem pode ter acesso aos documentos.	Acesso mediante a autorização apropriada, controle de acesso.
Dados interoperáveis	Interoperabilidade de documentos.	Pontos em comum sobre interoperabilidade.
Metadados acionados por máquinas, metaformatos utilizam vocabulários controlados e ontologias, metadados dentro dos objetos de dados deve ser reproduzíveis e acessíveis, especificar dados, vocabulários, padrões e metodologias deverá seguir.	Consulta, recuperação, importação e exportação de documentos e seus metadados, operações de interoperabilidade devem respeitar a legislação vigente e a política de segurança, capaz de interoperar com outros sistemas por meio de padrões abertos.	Não foram encontrados pontos em comum neste aspecto.
Dados reusáveis	Reuso de documentos.	Pontos em comum sobre reúso.
Devem estar em conformidade com os princípios de encontrabilidade (encontráveis) e interoperabilidade (interoperáveis), bem descritos para que possam ser integrados a outros dados, referência a fonte e metadados, processo de garantia de qualidade de dados, cumprimento de tempo da validade de dados.	Os documentos arquivísticos devem possuir valores de autenticidade, confiabilidade, organicidade, acessibilidade e unicidade. No plano de classificação e destinação deve estar atribuído o tempo de guarda do mesmo para fins administrativos ou históricos.	Deve ser estabelecido o tempo de guarda e validade dos dados/documentos. Garantia de qualidade, confiabilidade da informação.

Fonte: Adaptado do Conselho Nacional de Arquivos (2011), Comissão Europeia (2016) e Force 11 (2018).

Vídeo da apresentação

Título: Os princípios FAIR como diretrizes para maximizar o uso e (re)uso dos dados de pesquisa: Traçando um paralelo com a gestão de documentos arquivísticos digitais

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=39

Transcrição da apresentação

Boa tarde, sou representante do artigo "Os princípios FAIR como diretrizes para maximizar o uso e (re)uso dos dados de pesquisa: Traçando um paralelo com a gestão de documentos arquivísticos digitais".

A princípio as pessoas podem perguntar o que são os princípios FAIR. FAIR é uma sigla em inglês que significa Findable, Accessible, Interoperable e Reusable, que quer dizer encontrável, acessível, interoperável e reutilizável. O conjunto de dados sobre o princípio FAIR foram elaborados a partir de uma conferência, eles foram propostos no ano de 2014.

O que esses pesquisadores propuseram? Que grande parte da quantidade de dados que está sendo produzida pela ciência precisava de princípios que regeram e que os pesquisadores pudessem fazer gerência dos dados.

Os princípios Encontrável, Acessível, Interoperável e Reutilizável são primordiais para dados de pesquisa serem tratados e preservados. Conhecer como surgem suas fases e sua natureza é essencial para reger os princípios FAIR. Ou seja, temos muito para entendermos o que são dados de pesquisa, como são conceituados, qual são os tipos, qual sua natureza, para saber como aplicar esses princípios.

Os dados passam por um ciclo de vida que vai desde o planejamento da coleta, da preservação, descoberta, integração, análise e isso vai sendo continuado como um ciclo. É muito importante dizer que esses dados não serve apenas para aqueles pesquisadores naquela pesquisa em especial, mas os princípios FAIR dizem para os pesquisadores para compartilhar esse conjunto de dados produzidos pela ciência.

Aparentemente vocês podem perguntar mas o que isso tem a ver com a gestão dos documentos arquivísticos digitais. Vou começar com uma definição de arquivo e documento que é muito clássica no meio arquivístico que é o conceito de documento como logística de informação, independente de sua natureza ou suporte. Um documento pode ser aquele de papel, pode ser digital, pode ser um áudio, uma imagem.

Essa nova perspectiva digital o arquivo nacional, o dicionário de arquivística diz que os documentos digitais são aqueles documentos originários em discos binários, presentes em sistema computacional que são parte dos documentos produzidos hoje.

Os documentos digitais e os arquivos digitais trazem inúmeras possibilidades para nosso dia a dia, principalmente em questão de acesso. Só que também nós temos problemas na questão da perturbação, da vibração, que está ligada a preservação, problema da segurança onde muitas pessoas falaram sobre, então existem preocupação no meio digital com os arquivos.

Então qual o objetivo geral desse artigo, é entender como os princípios FAIR e a gestão de documentos arquivísticos digitais pode contribuir para o gerenciamento de dados científicos. Os objetivos específicos são conhecer o que são os princípios FAIR, entender as diretrizes e princípios aplicados a gestão de arquivos digitais e estabelecer semelhança entre os princípios FAIR e a gestão de documentos arquivísticos digitais.

Quanto aos procedimentos metodológicos, essa pesquisa tem natureza aplicada, característica exploratória, é classificada como uma pesquisa bibliográfica.

Como eu falei logo no começo, os princípios FAIR foram elaborados em uma conferência em que foram pesquisadores científicos que propuseram esses princípios para reger o conjunto de dados. Teve duas entidades que tiveram a preocupação de que OK, tem que ser encontrável, tem que ser acessível, tem que ser interoperáveis e reutilizáveis, mas como a gente vai aplicar isso na prática.

Então por exemplo, o princípio dos dados serem encontrados eles devem ser encontrados em quanto tempo, os dados digitais devem ser consistentes, ter seus metadados, deve ter metadados processáveis por máquina, que permitam interagir com outros objetos de dados, uso de identificadores únicos e persistentes.

Quanto a ele ser acessível, como ele pode ser acessado por máquinas e por humanos, segurança, quem vai acessar esses dados.

Interoperável porque, por exemplo, ele diz que os metadados devem ser operados por máquinas, os meta formatos de dados devem utilizar vocabulários compartilhados, metadados registrados dentro dos objetos de dados.

E por exemplo, reutilizáveis porque eles devem estar em conformidade com os princípios de serem encontrados e interoperável. Também tem a questão dos metadados que são super importantes.

Já a gestão de documentos arquivísticos digitais se a gente for pegar do Conselho Nacional de Arquivo que é um documento, que foi elaborado por vários órgãos internacionais e nacionais. Nesse documento ele vai falar sobre todos os processos da gestão de documentos e como deve acontecer a gestão de documentos arquivísticos digitais, que vai desde o processo de captura, avaliação, a segurança e controle de acesso, armazenamento e preservação.

Como vocês podem ver não dá nem tempo de falar porque são muitos requisitos, mas a gente vem para a parte principal aqui, que são quais são os pontos em comuns entre os princípios FAIR e a gestão de documentos arquivísticos digitais?

Ambos têm, por exemplo, algo em comum quanto a encontrabilidade de documentos e dos dados serem encontrados, eles fazem uso de verificador e a partir dos metadados e uso de palavras chaves. Tanto os dados quanto os documentos são acessíveis por método de controle ampliada, deve haver um controle de acesso.

Em relação a interoperabilidade foram muitos pontos que não tiveram nada em comum, porque enquanto os dados interoperáveis levam muito a questão de ontologias e os metadados que sejam acessíveis a linguagem também devem ser entendidas por outros pesquisadores que não estão originalmente naquela pesquisa, com a interoperabilidade de documentos ela fala muito sobre a questão da legislação vigente e a política de segurança, a gente tem que operar com outros sistemas por meio de padrões abertos. Nesse ponto não foi encontrado nenhum ponto em comum nesse aspecto.

Já por exemplo para os dados reutilizáveis e os documentos também, deve ser estabelecido tempo de guarda, e a garantia da qualidade e confiabilidade da informação.

O que a gente levanta como considerações finais? Que os princípios FAIR eles trazem como pilares ser encontrados, acessíveis, interoperáveis e reutilizáveis, com preocupação na gestão de dados de pesquisa. Estes princípios podem potencialmente ser usados na administração para uso

dos dados, não se preocupando com a questão da preservação que é uma preocupação da gestão de dados de pesquisa.

Já a gestão de documentos arquivísticos digitais, eles têm uma prerrogativa que por exemplo, envolve a política institucional e a preservação dos documentos. Não foi a intenção de fazer uma crítica aos princípios FAIR, pois eles foram criados para maximizar e reutilizar os dados de pesquisa, a preservação aparentemente não é seu foco. Mas, com os princípios FAIR aliados aos princípios da gestão de documentos arquivísticos digitais demonstram qualidades que são essenciais na administração entre a relação de dados de pesquisa.

Quem tente a ganhar com isso é a ciência, pois ela terá acesso e preservação para seu desenvolvimento no presente e futuro. E aqui são as referências, e muito obrigado.

Slides da apresentação

Título: Os princípios FAIR como diretrizes para maximizar o uso e (re)uso dos dados de pesquisa: Traçando um paralelo com a gestão de documentos arquivísticos digitais.

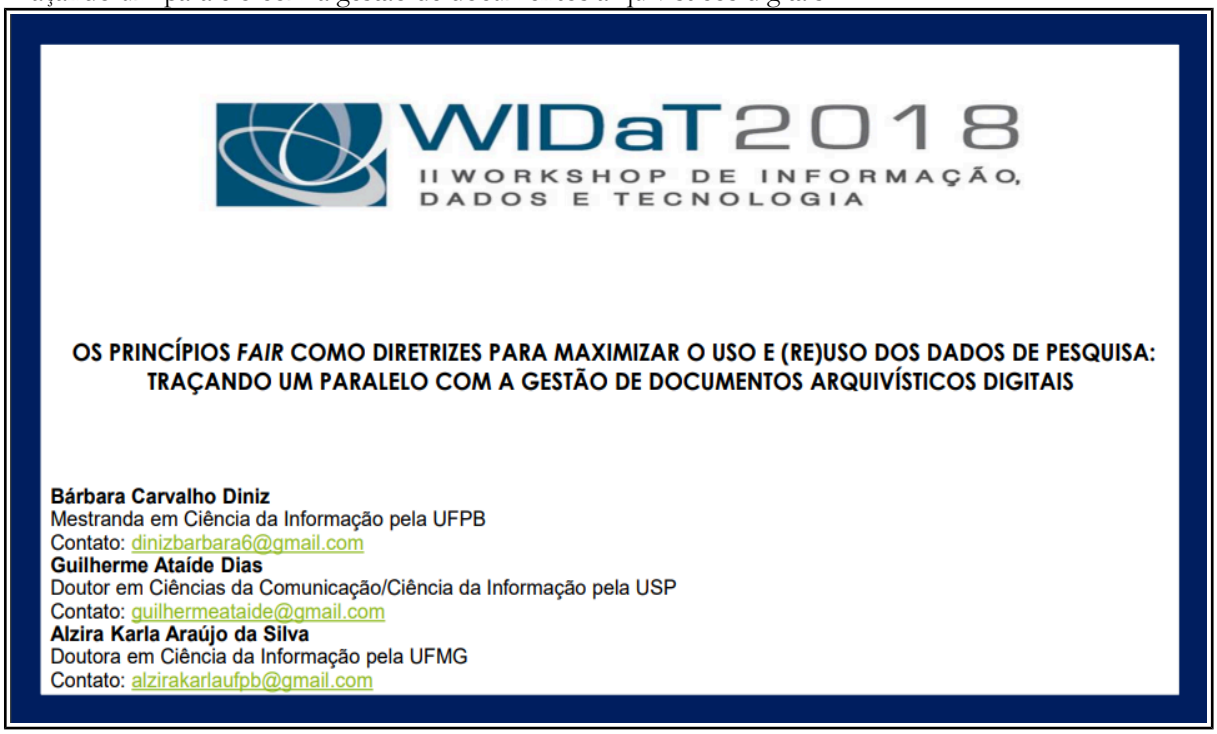

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=39

Práticas de gestão de dados: uma revisão da literatura sobre o termo Data Life Cycle

Débora Gomes de Araújo[a]

Resumo: Este trabalho realiza uma revisão bibliográfica sobre o termo "data life cycle", com enfoque na área da Ciência da Informação, tendo as bases de dados Emerald, LISA e LISTA como fontes de pesquisa. Nesse estudo foi utilizada uma abordagem quantitativa, de cunho exploratório e bibliográfico. Foram utilizadas as ferramentas Zotero e QDA Miner na condução da investigação. Quanto aos resultados, ficou evidenciado que a base de dados que mais indexou sobre a temática em questão foi a LISTA no período de 2013 a 2018, porém ainda apresentou uma quantidade pouco expressiva de indexações. O autor que se destacou na quantidade das produções científicas sobre o tema foi Vardigan, enquanto que o periódico que teve o maior número de publicação foi o americano International Association for Social Science Information Service and Technology Quarterly e o Reino Unido foi o local que mais publicou. Por meio dos artigos recuperados foi possível identificar a importância da gestão de dados em cada etapa do ciclo de vida de dados. Desta forma, este trabalho contribui para facilitar o entendimento da área pelos pesquisadores que investigam o tema.

Palavras-chave: Big data; Ciência da informação; Ciclo de vida dos dados; Gestão de dados científicos.

Data Management Pratices: A review of the term data life cycle

Abstract: This work review the term "data life cycle" in the literature focused in the field of Information Science. Emerald, LISA and LISTA databases were used as sources of research. The study applied a quantitative approach with exploratory and bibliographic efforts. Zotero and QDA Miner tools were used to support the research. Although a little expressive amount of indexations have been found from 2013 to 2018, the results evidenced LISTA as the most indexed database. In addition, the recovered papers highlighted Vardigan as the most productive author in the field. The results also evidenced the American International Association for Social Science Information Service and Technology Quarterly as the most published periodical and the United Kingdom as the most published place. Through the retrieved papers it was possible to identify the importance of data management in each step of the data life cycle. This work will contribute to understanding the subject by the researchers in the field.

Keyword: Big data; Information Science; Data life cycle; Scientific data management.

a Universidade Federal da Paraiba (UFPB). E-mail: debora.g.de.araujo@gmail.com. ORCID: https://orcid.org/0000-0003-2283-0833. Currículo: http://lattes.cnpq.br/5802239149965368

1 Introdução

Nos dias atuais, cada vez mais a gestão de dados gerados a partir das pesquisas científicas vem ganhando espaço, devido as necessidades de uso e reúso dos mesmos. O que é facilitado pelas tecnologias contemporâneas. Neste sentido, com a disseminação da tecnologia da informação e comunicação (TIC) em nosso cotidiano, a pesquisa científica também evoluiu, em um contexto relacionado com o uso intenso dos dados, através da obtenção de informações de grandes volumes de dados digitalizados (AYDINOGLU; DOGAN; TASKIN, 2017).

O estudo em questão tem o seu foco nos dados de pesquisa, que de acordo com Patel (2016) estes constituem o centro de qualquer investigação científica, pois as descobertas e

onclusões dos estudos são totalmente dependentes deles.

Dados de pesquisa incluem-se no processo dinâmico de investigação científica. Neste cenário, eles podem ser distinguidos por meio de duas funções: dados como materiais (input),está relacionada com a fase inicial, momento em que os dados são coletados e analisados e os dados como resultado (output), refere-se aos dados que são produzidos no decorrer dos processos, levando a publicações, como finalidade da pesquisa (SCHÖPFEL et al., 2016).

As práticas de pesquisas atuais exigem novas formas de tratamento dos dados por parte dos pesquisadores, de forma a acompanhar as mudanças constantes. Diversas áreas do conhecimento desenvolvem planos de gestão de dados por exigências de agências fomentadoras de pesquisa. O ciclo de vida de dados (CVD) se apresenta nesse cenário como uma ferramenta que pode promover habilidades e conhecimento para o pesquisador conduzir de forma apropriada a sua pesquisa, oferecendo etapas que contemple todo o percurso dos dados, de forma a serem detectáveis e utilizáveis em outros estudos.

Desta forma, é fundamental compreender o CVD, pois além de ser essencial em seu próprio trabalho, contribui com os pesquisadores, ao possibilitar soluções para as barreiras que podem ser encontradas na coleta e análise de dados, assim como na organização de conjuntos de dados e na descoberta de conjuntos externos relevantes (GOBEN; RASZEWSKI, 2015).

Segundo Rice e Southall (2016), um ciclo de vida de pesquisa mapeia a atividade de um pesquisador durante um projeto de pesquisa. Analogamente, um CVD representa o percurso dos dados ou as ações necessárias para que a pesquisa evolua para o estágio seguinte.

Na literatura existem algumas iniciativas que representam os ciclos de vida dos dados. De acordo com Goben e Raszewski (2015), existem vários modelos capazes de descrevê-los, porém eles citam como exemplos mais populares o Digital Curation Center (DCC) e a iniciativa do Data Observation Network for Earth (DataONE). Outras iniciativas podem ser evidenciadas como o Data Documentation Initiative (DDI), apresentada por Vardigan (2013), assim como os modelos destacados por Rice e Southall (2016), da Joint Information Systems Committee (Jisc) (2016) e do Imperial College London Library RDM Workflow, cujo autor é Barnes (2016), Existem ainda diversos modelos de ciclo de vida de dados.

Da realidade da coleta, armazenamento, recuperação e descarte de dados, Santa'Ana (2016) desenvolveu um modelo voltado para a ciência da informação (CI), uma vez que, enfatiza o papel desta área no estudo e na proposta de caminhos para lidar adequadamente com os dados, ao

revelar que a área pode trabalhar com um novo enfoque, sendo uma aliada nesse processo de otimização de dados.

2 Objetivos

Diante destas considerações iniciais, o objetivo da presente pesquisa foi realizar uma revisão bibliográfica sobre o termo data life cycle, na literatura concentrada na área da Ciência da Informação (CI), nas bases de dados Emerald eJournals Premier (Emerald), Library and Information Science Abstracts (LISA) e Library e Information Science & Technology Abstracts (LISTA). Uma vez que, estas bases registram de formas variadas e focam de forma específica na CI.

3 Procedimentos Metodológicos

O estudo em questão é de cunho quantitativo, exploratório e bibliográfico. Teve como fonte de dados os metadados dos artigos de arquivos abertos encontrados nas bases de dados supracitadas. A fase de coleta compreendeu o período de 01/07/2018 a 23/07/2018. Foram adotados os seguintes critérios de busca: utilizou-se apenas o termo "data life cycle", o qual foi coletado entre aspas, o espaço temporal de levantamento foi entre 2013-2018, com a finalidade de identificar o que vem sendo trabalhado sobre o tema nos últimos cinco anos.

Os dados revelaram que a base que mais indexou artigos de arquivos abertos sobre o data life cycle no período em questão foi a LISTA, pois através dela foi possível recuperar 35 artigos. Sendo 22 provenientes da Emerald e 14 da LISA. Em 2015 houve um avanço nas produções, o que pôde ser verificado nas três bases. Em 2016 o volume foi significativo. Apresentou uma queda em 2017 na base LISTA, pois não houve indexações. Em 2018 as referidas bases continuam disponibilizando artigos sobre a temática. Desta forma, o tema é alvo de discussão no cenário atual.

Os artigos oriundos da busca bibliográfica foram exportados para a ferramenta ZOTERO, através desta foi possível constatar na opção itens duplicados, os artigos recuperados que se repetiam entre as bases de dados. Através dessa análise, verificou-se que dos 14 artigos encontrados na base de dados LISA, 12 deles estão presentes nas bases de dados Emerald e LISTA, sendo 10 na Emerald e 2 na LISTA. Em seguida, os registros duplicados foram eliminados, passando do total de 71 para 59 artigos.

4 Resultados

A partir do levantamento dos autores que produziram sobre o tema, constatou-se que apenas 13% deles publicaram mais de uma vez sobre o termo data life cycle. Enquanto uma quantidade significativa de autores, representada por 87%, discorreu pouco sobre o tema, pois apresentaram apenas um artigo. Infere-se que uma quantidade reduzida de estudiosos produziu um pouco mais sobre a temática, ao passo que um número considerável de pesquisadores está publicando pouco.

A autora que se destacou na quantidade de artigos sobre o tema foi Mary Vardigan, produziu 4 artigos nos períodos de 2013 a 2016, no periódico americano IASSIST Quarterly, sendo que a

produção de 2013 foi apenas de sua autoria e as demais envolveram outros pesquisadores, sendo duas delas com Ionescu.

Constatou-se que os autores Borgman, Darch, Sands, Wallis e Traweek produziram dois artigos juntos. Os pesquisadores Schöpfel, Južnič, Prost, Malleret, Češarek e Koler-Povh em conjunto produziram dois artigos e os autores Si, Xing, Zhuang e Hua também tiveram dois trabalhos juntos. Desta forma, a maioria dos estudiosos que apresentaram mais de um artigo tiveram seus trabalhos em parceria com outros que se enquadraram nas mesmas condições, com exceção de Harris que publicou sozinho dois artigos e Li que desenvolveu suas pesquisas com outros pesquisadores que tiveram apenas 1 publicação.

A análise possibilitou levantar os periódicos que apresentaram mais produções no período sobre a temática. Destacamos os que têm acima de uma publicação, conforme o Quadro 1.

Quadro 1: Distribuição dos periódicos por países no período de 2013-2018.

Título de publicação	**Número**	**Países**
IASSIST Quarterly	8	Estados Unidos
International Journal on Digital Libraries	3	Alemanha
Information Services & Use	3	Holanda
Journal of Map & Geography Libraries	3	Estados Unidos
Information & Computer Security	2	Inglaterra
Journal of The Association for Information Science and Technology	2	Estados Unidos
Library Hi Tech	2	Inglaterra
New Review of Information Networking	2	Inglaterra
Program: electronic library and information systems	2	Inglaterra
The Electronic Library	2	Inglaterra
The Canadian Journal of Library and Information Practice and Research	2	Canadá
The Grey Journal	2	Holanda

Fonte: Dados da pesquisa, 2018.

Através do levantamento dos Títulos de publicações, foi possível constatar que o maior número de publicações ocorreu no periódico americano IASSIST[1] Quarterly, ao apresentar 8 produções.

Ao incluir os artigos de outros periódicos que tiveram apenas uma produção, foi possível verificar os países que trataram da temática. O que está expresso na Figura 1.

Diante dos dados apresentados, é possível identificar que o data life cycle é um tema discutido no cenário nacional e internacional, com uma concentração de publicações em periódicos do continente europeu, representando 60%, o que pode ser resultado de iniciativas como o Horizon 2020 (H2020), que consiste em um programa de pesquisa e inovação que tem por finalidade aperfeiçoar o acesso à informação científica, no que tange aos artigos de pesquisa científica e aos dados de pesquisa. Em um contexto digital de Open Acess (HORIZON, 2018).

1 International Association for Social Science Information Service and Technology.

Nesse cenário, observa-se que o Reino Unido se destacou com um percentual de 39%, o que pode remeter a ser um local de referência na criação de ciclos de vida de dados, como por exemplo, o DCC, a iniciativa da Jisc e a do Imperial College London Library RDM Workflow. Além dessas estratégias voltadas para lidar corretamente com os dados de pesquisas, Hua et al. (2015) destacam que a biblioteca da Universidade de Cambridge oferece treinamentos para os pesquisadores gerenciarem seus dados.

Figura 1: Países que publicaram sobre data life cycle no período de 2013-2018.

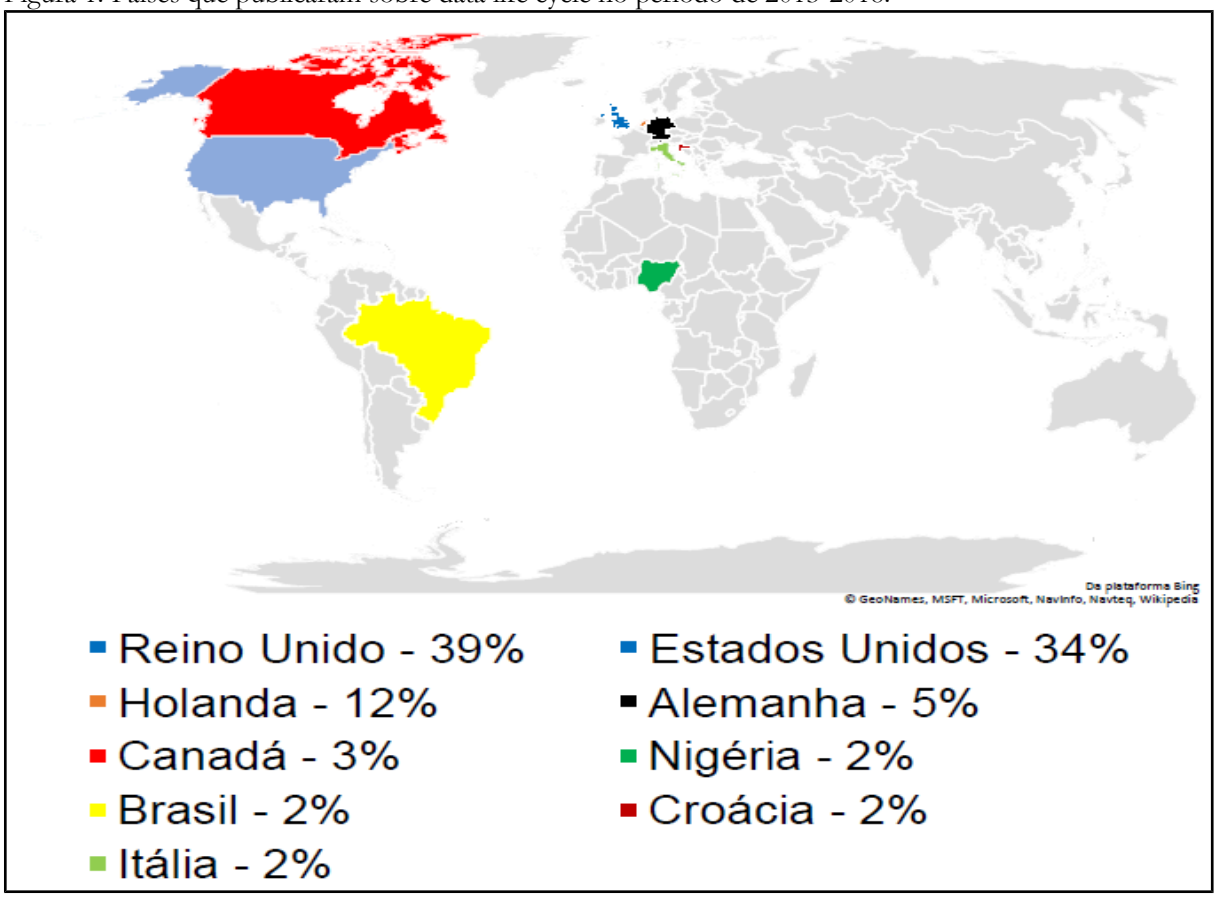

Dados da pesquisa, 2018.

Posteriormente, aparece o continente americano com 39% das produções, sendo 34% dos Estados Unidos. Diante desta realidade, constata-se a presença de iniciativas que visam a gestão de dados no cenário americano, como a criação dos ciclos de vida de dados DataOne e o DDI. Com uma participação reduzida de 2%, encontramos também uma produção brasileira, que também apresenta um modelo de ciclo de vida de dados com o foco na CI, do autor Sant'Ana (2016).

O estudo revela que apesar do autor com maior número de publicações e o periódico que mais se destacou serem americanos, o local que mais produziu atualmente sobre o data life cycle é o Reino Unido, seguido dos Estados Unidos.

Tomando como base as palavras-chave dos artigos citados pelos autores que publicaram em mais de um artigo, por meio da ferramenta QDA MINER, foi realizada uma pesquisa, a partir da

criação de códigos nomeados pelas palavras data life cycle (ciclo de vida de dados), big data, cujo termo se refere a volume, variedade, velocidade e veracidade dos dados, segundo Dale (2015), research data management (gestão de dados de pesquisa), data repositor (repositórios de dados), metadata (metadados), open data (acesso aberto) e data management plan (plano de gestão de dados), para verificar a frequência desses termos em todos os arquivos recuperados, exceto os que estavam presentes nas referências dos artigos analisados (Gráfico 1).

Gráfico 1: Frequência dos termos encontrados nos artigos sobre data life cycle utilizando a ferramenta QDA Miner.

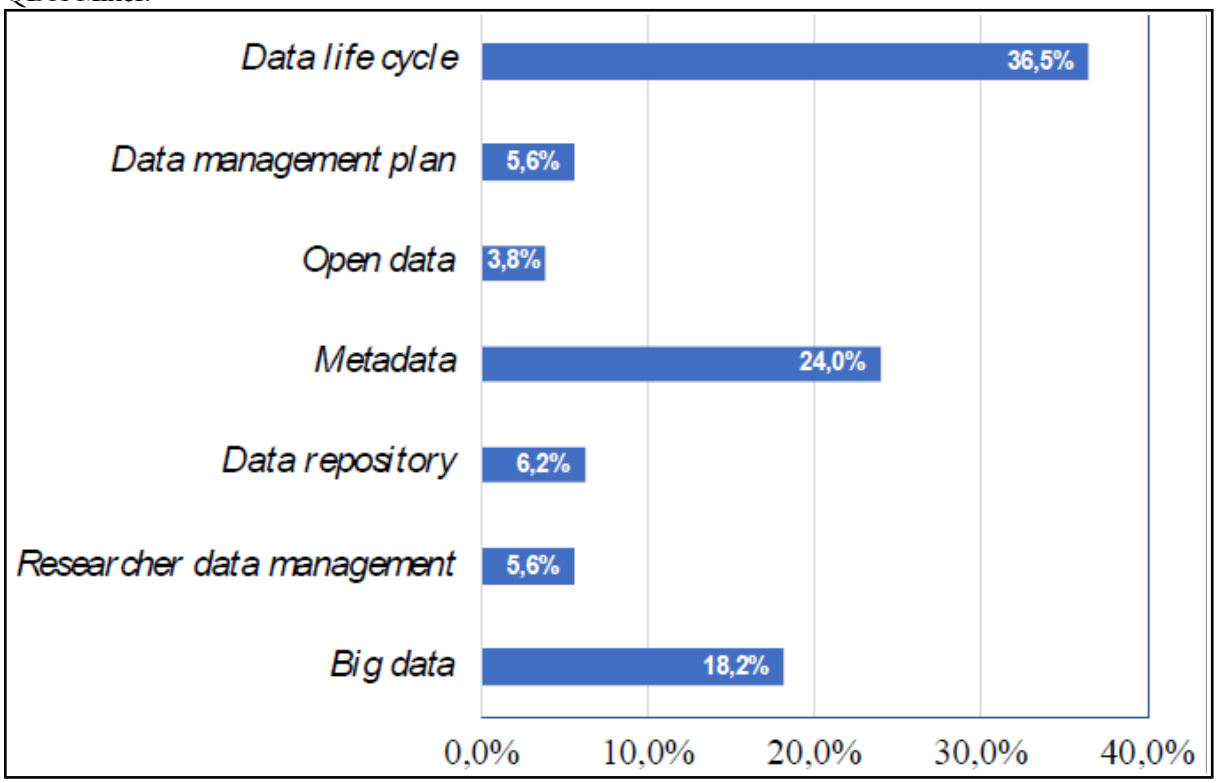

Fonte: Dados da pesquisa, 2018.

O Gráfico 1 confirma que o termo mais frequente nos textos avaliados foi o data life cycle, haja vista que os arquivos recuperados nas bases de dados se basearam no referido termo. Os demais termos estão envolvidos com a temática com destaque para metadata com 24% e big data com 18,2%. Por meio desse levantamento foi possível codificar os textos com as palavras supramencionadas, possibilitando a extração de segmentos relevantes contidos nos textos para o apoio teórico da pesquisa.

O Gráfico 2 a seguir, apresenta a coocorrência dos termos com relação ao data life cycle, ou seja, as vezes que as citações dos termos ocorreram simultaneamente, o que revela a proximidade dos mesmos.

Apesar do big data ter sido o termo mais citado nos textos recuperados pelo Gráfico 1, ele juntamente com o open data são os mais distantes do termo data life cycle na análise de proximidade (Gráfico 2) e o Researcher data management não apresentou coocorrência. O termo metadata foi recuperado como o mais próximo, seguido do data repository. Essa análise se

mostra importante quando na recuperação dos termos coocorrentes, o que ajuda na identificação de termos simultâneos.

Gráfico 2: Proximidade dos termos encontrados nos artigos sobre data life cycle utilizando a ferramenta QDA Miner.

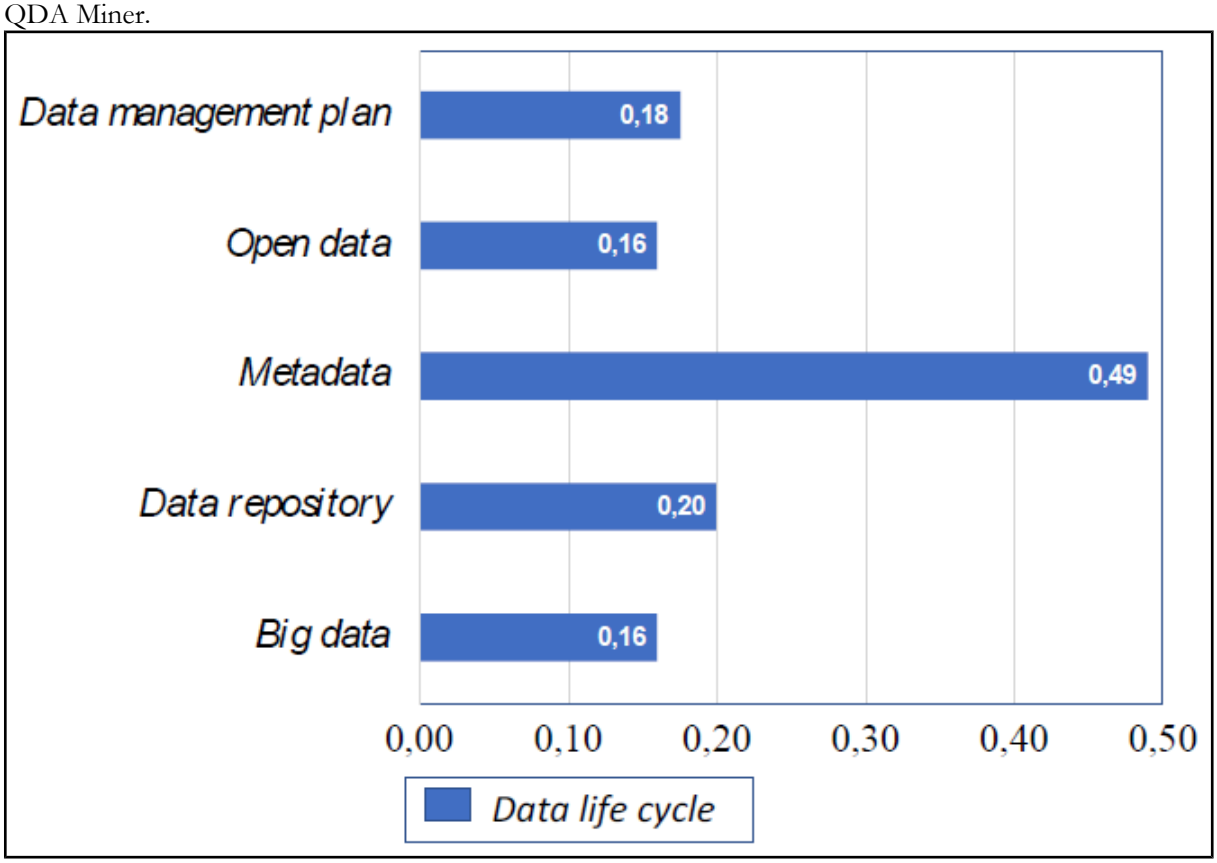

Fonte: Dados da pesquisa, 2018.

5 Considerações Finais

Através da pesquisa realizada foi possível fazer uma revisão da literatura sobre o termo data life cycle, nas bases de dados Emerald, LISA e LISTA. Evidenciou-se que a temática ainda é emergente na área da Ciência da Informação, uma vez que, a quantidade de produções não foi expressiva no período analisado. No entanto, a IASSIST QUARTERLY se destacou pela quantidade de publicações na área da CI, denotando alinhamento com os interesses dos profissionais da área sobre a temática, mesmo que ainda seja pouco explorada.

O termo é discutido no cenário internacional, com destaque para o Reino Unido, visto o maior de número de produções. Mary Vardigan, que mais produziu no período estudado, trabalha em projetos relacionados à administração de dados, tendo atuado como diretora do DDI, que como dito anteriormente, representa um ciclo de vida dos dados, podendo ser considerada uma referência no assunto.

As ferramentas Zotero e QDA Miner ofereceram um apoio na condução da pesquisa. Através da segunda foi possível extrair dos textos citações relevantes para o trabalho, facilitando o processo de pesquisa, em que a partir dos segmentos selecionados ficou claro que o processo de gerenciamento de dados científicos está diretamente ligado com o ciclo de vida dos dados,

sendo tal conexão algo fundamental para possibilitar o compartilhamento dos dados, uma vez que, boas práticas de gerenciamento são necessárias em cada fase do ciclo de vida dos dados.

Recomendamos como sugestão de trabalhos futuros, o desenvolvimento de pesquisas que, além de fazer um levantamento dos autores que mais publicaram na área, mostrem a quantidade de citações que têm recebido. Sugerimos ainda que estudos sejam realizados para identificar os ciclos de vida de dados existentes no âmbito científico, empresarial e governamental.

Referências

AYDINOGLU, A. U.; DOGAN, G.; TASKIN, Z. Research data management in Turkey: perceptions and practices. **Library Hi Tech**, v. 35, n. 2, p. 271–289, 27 abr. 2017. Disponível em< https://www.emeraldinsight.com/doi/abs/10.1108/LHT-11-2016-0134> Acesso em 17 de jul. 2018.

BARNES, A. Imperial Colegge London Library RDM Workflow. Zenodo. 2016. Disponível em:< https://zenodo.org/record/54000#.W6FzFmhKjIU>. Acesso em 18 set. 2018.

DALE, K. L. RIM's Role in Harnessing the Power of Big Data. **Information Management Journal**, v. 49, n. 4, p. 29–32, 7 ago. 2015.

DATAONE. **Primer on Data Management**: what you always wanted know. Disponível em: <https://www.dataone.org/sites/all/documents/DataONE_BP_Primer_020212.pdf>. Acesso em: 20 jun.2018.

DCC Digital Curation Centre. **Curation Lifecycle Model**. Disponível em: <http://www.dcc.ac.uk/resources/curation-lifecycle-model> Acesso em: 20 jun. 2018.

GOBEN, A.; RASZEWSKI, R. The data life cycle applied to our own data. **Journal of the Medical Library Association**, v. 103, n. 1, p. 40–44, jan. 2015. DOI: http://dx.doi.org/10.3163/1536-5050.103.1.008. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4279933/ > Acesso em 17 de jul. 2018.

H2020. Guidelines to the Rules on Open Access to Scientific Publications and Open Access to Research Data in Horizon 2020. Disponível em:<http://ec.europa.eu/research/participants/data/ref/h2020/grants_manual/hi/oa_pilot/h2020-hi-oa-pilot-guide_en.pdf>. Acesso em 8 ago. 2018.

HUA, X. et al. Investigation and analysis of research data services in university libraries. **The Electronic Library**, v. 33, n. 3, p. 417–449, 27 maio 2015. Joint Information Systems Committee, 2016. Disponível em<https://www.jisc.ac.uk/guides/how-and-why-you-should-manage-your-research-data> Acesso em: 28 set. 2018.

PATEL, D. Research data management: a conceptual framework. **Library Review**, v. 65, n. 4/5, p. 226–241, maio 2016.

QDA MINER. Disponível em< https://provalisresearch.com/products/qualitative-data-analysis-software/> Acesso em: 25 jul. 2018.

RICE, R.; SOUTHALL, J. **The Data Librarian´s handbook.** Publisher by Facet Publishing. London, 2016.

SANT'ANA, R. C. G. Ciclo de vida dos dados: uma perspectiva a partir da ciência da informação. **Informação & Informação**, v. 21, n. 2, p. 116, 20 dez. 2016.

SCHÖPFEL, J. et al. Dissertations and Data. **Grey Journal (TGJ)**, v. 12, n. 3, p. 126–148, set. 2016.

VARDIGAN, M. The DDI Matures: 1997 to the Present. **IASSIST Quarterly**, v. 37, n. 1– 4, p. 45–50, mar. 2013.

ZOTERO. Disponível em< https://www.zotero.org/> Acesso em 27 jul. 2018.

Vídeo da apresentação

Título: Práticas de gestão de dados: Uma revisão da literatura sobre o termo Data Life Cycle.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=40

Transcrição da apresentação

Olá pessoal, meu nome é Débora, autora do artigo intitulado "Práticas de gestão de dados: Uma revisão da literatura sobre o termo Data Life Cycle".

A gestão de dados é um dos temas que vem sendo discutido em nosso cenário atual, especialmente nessa perspectiva de dados científicos. Uma vez que temos a necessidade de uso e reúso desses dados diante dessa realidade, é importante dizer que os dados são o centro da investigação científica, uma vez que as conclusões que tiramos de nossas pesquisas devem seguir esses dados.

Desta forma novas formas de tratamento de dados vem surgindo para os pesquisadores possam lidar com seus dados, uma questão é o ciclo de vida dos dados como a nossa colega aqui já abordou. O ciclo de vida de dados fornece habilidade para que pesquisadores possam tratar corretamente seus dados, saber lidar com seus dados de pesquisa.

Na literatura temos alguns exemplos, como o Digital Curation Center, a iniciativa do DataONE já proposto pelo colega, e o ciclo de vida dos dados voltado para nossa área que é a Ciência da Informação que foi desenvolvido por Sant'Ana.

O objetivo diante dessas considerações foi realizar uma revisão bibliográfica sobre o termo Data Life Cycle na literatura concentrada na área da Ciência da Informação nas bases de dados Emerald eJournals Premier(Emerald), Library and Information Science Abstracts(LISA) e Library, Information Science and Technology Abstracts(LISTA).

Quanto aos procedimentos metodológicos desta investigação, o estudo é caracterizado enquanto quantitativo, exploratório e bibliográfico, utilizando como fonte de dados os metadados dos arquivos de artigos abertos localizados nessas bases de dados que eu acabei de citar.

Foi pesquisa o termo Data Life Cycle entre aspas, e o período de 2013 a 2018 nessas bases de dados. Utilizamos para a construção da pesquisa, ferramentas como o Zotero e QDA Miner.

Diante dos dados encontrados 22 artigos na base Emerald, 14 na LISA e 35 na LISTA. Cabe ressaltar que a LISTA foi a base que mais indexou nesse período entre 2013 e 2018.

Dentre essas bases encontrados 12 artigos que se repetiram. Essa identificação foi possível através do Zotero, que através dessa ferramenta conseguimos identificar a princípio os artigos duplicados e eles foram retirados, assim nosso estudo se concentrou em 59 artigos.

Foi verificado que apenas 13% dos autores publicaram mais de uma vez sobre a temática e 87% deles apenas uma vez. Isso significa que uma parcela maior de pesquisadores publicam pouco sobre o tema, enquanto uma parcela menor pública em maiores quantidades. Esses autores que publicaram mais de uma vez trabalharam em parceria com outros autores que também se encontravam no mesmo patamar.

Fizemos um levantamento sobre os periódicos, e identificamos que um periódico americano teve 8 publicações sendo o destaque entre os demais. A partir dos periódicos conseguimos identificar os países que publicaram sobre a temática, com destaque para o Reino Unido com 39% e os EUA com 34%. Tivemos também uma publicação no Brasil que foi de Sant'ana.

Esses dados revelam que a temática ela é discutida tanto no âmbito nacional quanto internacional. Utilizamos a ferramenta QDA Miner para identificar nos artigos recuperados nas bases de dados os termos que apareciam nos artigos, e conseguimos identificar como o próprio nome diz na pesquisa "ciclo de vida de dados", "plano de gestão de dados", "dados abertos", "repositório de dados", "gestão de dados", e "Big Data". Conseguimos resgatar que o termo que mais se destacou foi "Data Life Cycle" seguido de "Metadados".

Só um detalhe que essa ferramenta permitiu extrair as situações para fazer a ponto ao referencial teórico. Organizamos também por meio da ferramenta os termos que correlacionados, ou seja, a citação que teria o termo "Data Life Cycle", e encontramos que o termo que mais se repetiu na ferramenta foi "Metadado", e o menos foi "Metadata" e "Open Data".

Concluímos que essa temática ainda é incipiente na área da Ciência da Informação, uma vez que não encontramos um número significado de artigos. O termo é discutido no cenário internacional com destaque para o Reino Unido. Lembrando que apesar de o Reino Unido ter sido o local que mais publicou, o periódico com maior status foi americano.

As ferramentas Zotero e QDA Miner ofereceram um apoio na construção da pesquisa, e entendemos que a Ciência da Informação pode ser uma referência para outras áreas a buscar ferramentas que explorem sobre o ciclo de vida dos dados. Obrigado.

Slides da apresentação

Título: Práticas de gestão de dados: Uma revisão da literatura sobre o termo Data Life Cycle.

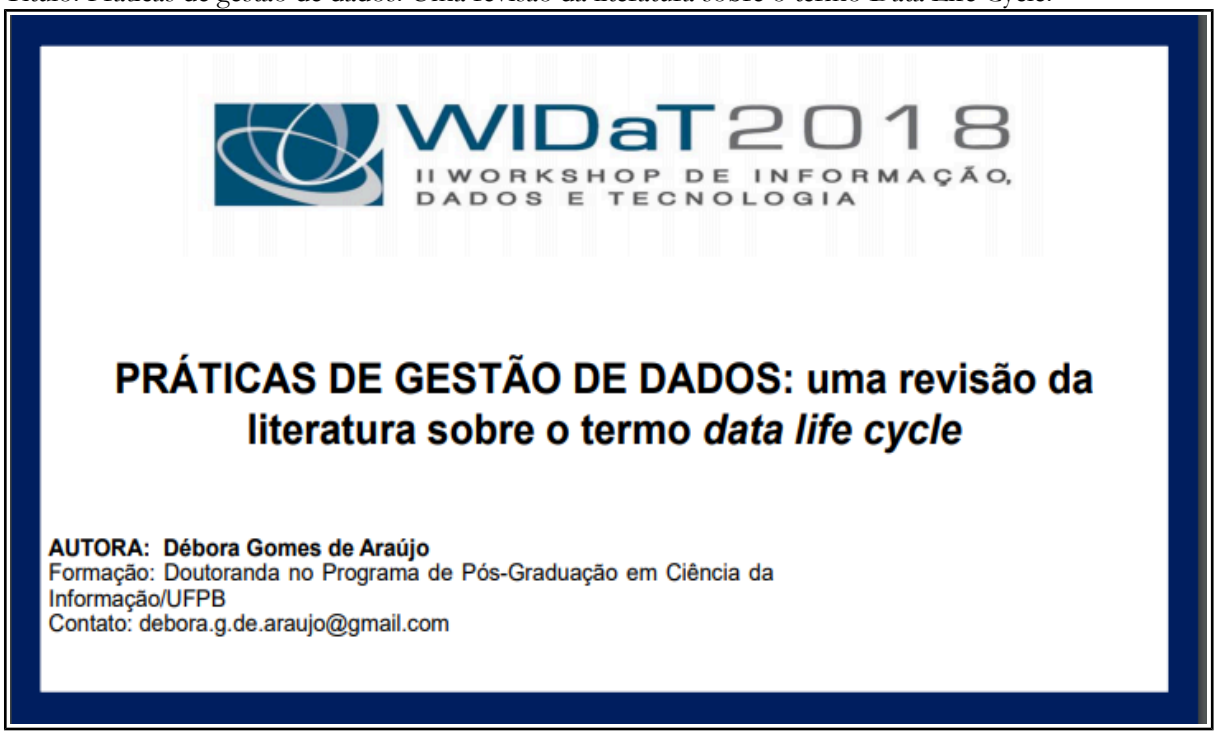

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=40

Metas, ações e indicadores como subsídios para análise da qualidade de dados: uma inversão necessária entre consequentes e antecedentes

Pedro Jácome de Moura Jr[a] *e Maicon Henrique Ferreira Aragão*[b]

Resumo: Assume-se que dados compõem os insumos fundamentais para a compreensão e transformação da realidade organizacional e, por conseguinte, a qualidade dos dados deve ser considerada para determinar em que medida esses dados podem ser usados para suporte a decisões. O objetivo deste estudo (em andamento) é identificar os níveis de qualidade dos dados contidos nos repositórios institucionais da Universidade Federal da Paraíba (UFPB) para suporte à mensuração dos indicadores de desempenho institucionais, realizando, para tanto, uma análise sobre o Plano de Desenvolvimento Institucional (PDI) da UFPB. Os achados demonstram que apenas 11% das metas possuem definição de indicadores para seu monitoramento, o que enseja considerações acerca da compreensão e aplicação dos conceitos de gestão e de governança por parte da instituição analisada e sugerem uma mudança na estratégia de coleta de dados para as etapas seguintes.

Palavras-chave: Governança corporativa; Governança de TI; Qualidade de dados; Planejamento estratégico.

Goals, actions and indicators as inputs for data quality analysis: A necessary reversal between consequents and antecedents

Abstract: This study assumes that data composes the fundamental inputs for the understanding and transformation of organizational reality and, therefore, the quality of the data should be considered to determine to what extent such data can be used to support decisions. The study (in progress) aims to identify the data quality levels exposed by the institutional repositories of the Universidade Federal da Paraíba (UFPB) to support the measurement of institutional indicators, performing an analysis of the UFPB's Institutional Development Plan (PDI). The findings show that only 11% of the defined targets have indicators for their monitoring, which leads to considerations about the understanding and application of management and governance concepts by the analyzed institution, and suggest a change in the data collection strategy for the next steps.

Keyword: Corporate governance; IT governance; Data quality; Strategic planning.

a Universidade Federal da Paraíba (UFPB). E-mail: pjacome@sti.ufpb.br. Currículo: http://lattes.cnpq.br/5392174861908041. ORCID: https://orcid.org/0000-0001-6548-4614

b Universidade Federal da Paraíba (UFPB). E-mail: maiconhenriq_ilhadg@hotmail.com. Currículo: http://lattes.cnpq.br/3154990148316655

1 Introdução

As organizações podem ser vistas como um contínuo processo de desenvolvimento, fluxo e troca de informações entre as diversas partes que as compõem (Simon, 1950; Winter, 2003).

Se houve um período em que havia limitação de dados disponíveis para análise, hoje o volume, velocidade e variedade com que os dados são produzidos é tão maior que a dificuldade se concentra na transformação desses dados em indicadores que subsidiem a tomada de decisão e aplicação. Para alguns autores, pode-se afirmar que as organizações estão inundadas de dados (Davenport, 2006; Hazen et al., 2014) e, paradoxalmente, não conseguem lidar adequadamente com isso.

Sendo o dado o insumo fundamental para a compreensão e transformação da realidade organizacional, a qualidade desse dado determina se – e em que medida – o mesmo poderá ser usado para suporte a decisões (O'Reilly, 1982), considerando também as características de veracidade (precisão) e valor (potencial de produção de benefícios) do dado (Bedeley et al., 2018).

A qualidade do dado pode ser objetivamente analisada por meio de quatro dimensões intrínsecas (independem de contexto):

(1) precisão (accuracy), ou o grau em que o dado (registrado em um sistema de informações) corresponde à realidade de que foi obtido; (2) atualização (timeliness), ou frequência de obtenção de valores atuais para o dado; (3) consistência (consistency), ou o grau de correspondência de formato e estrutura entre dados de mesma natureza (e.g. datas); e (4) completude (completeness), ou a disponibilidade compreensiva de atributos em um modelo de dados para representação da realidade (Ballou et al., 1998; Hazen et al., 2014; Redman, 1998).

No entanto, pressupõe-se que analisar a qualidade de todos os dados disponíveis em uma organização é uma tarefa onerosa e que tal intento pode ser mal sucedido, perdendo- se entre prioridades. Considerando-se que prioridades são definidas em planejamentos estratégicos organizacionais, um início adequado para análise de qualidade de dados pode ser definido pelos dados que subsidiam a elaboração de indicadores de monitoramento da estratégia (Kaplan & Norton, 2001).

2 Objetivos

O objetivo central deste estudo é identificar os níveis de qualidade dos dados contidos nos repositórios institucionais da Universidade Federal da Paraíba (UFPB) para suporte à mensuração dos indicadores de desempenho institucionais. Para isso, faz-se necessário (a) identificar os indicadores de desempenho contidos no Plano de Desenvolvimento Institucional (PDI) da UFPB, em vigência; (b) identificar os dados necessários ao monitoramento de cada indicador de desempenho; e (c) verificar a qualidade dos dados necessários à obtenção de cada indicador de desempenho.

3 Procedimentos Metodológicos

O PDI UFPB (disponível em: http://www.proplan.ufpb.br/proplan/contents/documentos/pdi/pdi_ufpb_2014-2018.pdf), acesso em 25/08/2018), contendo 131 páginas de texto corrido, foi utilizado como fonte de dados secundários para esta pesquisa. Definiram-se como unidades de análise as pró-reitorias

(PRG, PRPG, PRAC, Proplan, Progep, PRAPE e PRA) e os setores Agência de Inovação (INOVA), Superintendência de Tecnologia da Informação (STI) e Biblioteca Central (BC) por representarem setores de gestão, diferentemente de unidades acadêmicas (como seria o caso dos centros de ensino).

As palavras-chave "meta" e "indicador" foram aplicadas sobre o corpus que compõe o PDI. Os excertos contendo menção às palavras-chave foram tabulados em planilha eletrônica composta pelas colunas: localização (página/linha), setor, eixos/objetivos, metas, indicadores e ações. A análise do termo "ação" ou "ações" se mostrou necessária, embora não prevista inicialmente, em função de aparentes sobreposições conceituais com o termo "meta".

Cada excerto foi analisado e codificado como (categorias definidas a priori) "meta" ou "indicador"; e como (categoria emergente) "meta definida como ação".

Para fins metodológicos, adota-se como definição de meta o estabelecimento de objetivo específico (sem ambiguidades), mensurável (medida de alcance da meta), apropriado (relevante para a estratégia), realista (contextualizada em relação a restrições e desempenho conhecido) e com prazo determinado (conceito de metas "SMART"; Rietbergen & Block, 2010).

Assume-se como definição de indicador de desempenho "um número, percentagem ou razão que mede um aspecto do desempenho, com o objetivo de comparar esta medida com metas preestabelecidas" (da União, 2010). Ou seja, um indicador de desempenho compara o desempenho real com algum parâmetro (dado previamente conhecido ou organização da mesma natureza).

4 Resultados e discussão

O Apêndice "A" sintetiza quantitativamente os achados. Observa-se que dentre os dez setores analisados foram identificados 132 metas e apenas 15 indicadores a estas relacionados.

As metas identificadas demandaram distinção em relação ao uso do termo "ação" (ou "ações"), pois durante a análise verificou-se que houve sobreposição quanto às definições (por exemplo, nas págs. 36 e 37 as ações da Proplan são descritas como metas).

A exposição das metas no PDI também encontra formato distinto dentre os setores, já que alguns optaram por destacá-las em tópicos, o que possibilitou melhor clareza para sua identificação, enquanto outros optaram por mantê-las sem destaque, junto ao texto corrido (por exemplo, metas descritas pela PRPG na forma "A expansão quantitativa se dará a partir de estudos prospectivos e de diagnóstico da demanda", pág. 20). Provavelmente essa multiplicidade de forma se deve à estratégia de desenvolvimento do PDI, em que cada setor elaborou individualmente a sua parte, resultando, por fim, uma "compilação" vagamente integrada.

Verifica-se que o número de indicadores identificados (15) não corresponde ao número de metas identificadas (132). Uma tal discrepância sugere múltiplas interpretações, dentre as quais pode-se destacar, principalmente, sobreposição (intencional ou não, pois não há meios, nesta pesquisa, para afirmação inequívoca) dos conceitos de gestão e de governança. Ora, se uma meta é estabelecida por uma gestão e não há meios de verificação de sua execução, por suposto não há meios de exercício da governança, de modo que qualquer evidência de alcance da meta passa a ser questão de fé.

Por governança entende-se o conjunto de políticas e práticas que explicitem a atuação da gestão, sendo a transparência de ações um dos principais mecanismos de governança. No entanto, ao sobrepor os conceitos de gestão e governança, este último perde sua conotação (torna-se abstrato e inefetivo), "fazendo com que organizações pratiquem governança por imposição ou imitação, [apenas] como uma forma de 'dar satisfação' aos órgãos de controle" (De Moura Jr., 2017, p. 3).

Não obstante, destaca-se que os setores Proplan, PRPG e STI estabeleceram como meta a criação ou melhoria dos indicadores de desempenho, como se pode observar em excertos do tipo "ampliar e modernizar laboratórios de pesquisa, equipamentos de informática, aquisição de softwares, material de consumo, oferecendo condições para melhoria dos indicadores de desempenho dos programas" (PRG; PDI, 2014; p. 21), "Definição de indicadores de desempenho da atividade de TI na instituição" (STI; PDI, 2014; p.41) ou "Construir e acompanhar os indicadores de desempenho acadêmico" (Proplan; PDI, 2014; p. 37).

Observou-se que muitas definições de metas são falhas por não conter a ação específica que se deve empreender, vide "Estabelecimento da Formação continuada de docentes" (Progep; PDI, 2014; p. 37) ou "implantação dos módulos do Sistema Integrado de Gestão de Recursos Humanos – SIGRH" (STI/Progep; PDI, 2014; p. 39).

Ações definidas como verbos no infinitivo (realizar, implementar, elaborar, por exemplo), por outro lado, fornecem uma indicação direta do que deve ser feito, sem ambiguidades, conforme Rietbergen & Block (2010).

Em relação ao alcance do objetivo central deste estudo, qual seja, identificar os níveis de qualidade dos dados contidos nos repositórios institucionais da UFPB para suporte à mensuração dos indicadores de desempenho institucionais, tem-se que as dificuldades enfrentadas com o primeiro desdobramento específico (identificar os indicadores de desempenho contidos no PDI da UFPB, em vigência) ainda não permitem avançar consistentemente sobre os passos seguintes.

Identificar os dados necessários ao monitoramento de apenas 15 indicadores de desempenho não parece justificável. Assim, estima-se que a investigação sobre os indicadores deva avançar em consulta aos gestores que definiram as metas, ou seja, aqueles gestores que participaram da elaboração do PDI ou aqueles que vêm conduzindo seus setores seguindo a orientação contida no PDI.

Pretende-se com essas consultas, entrevistar os gestores apresentando-lhes os resultados parciais aqui descritos e obter deles definições pormenorizadas da relação entre metas e indicadores e de indicadores e dados.

Somente a partir de uma definição mínima de indicadores, poder-se-á avançar para as análises de qualidade dos dados que os subsidiam.

5 Considerações Finais

Este estudo em andamento investigou, até o momento, o Plano de Desenvolvimento Institucional (PDI) da UFPB (que aqui serve como uma ilustração de documento estratégico) em busca de definições de metas e indicadores de desempenho associados.

Os achados demonstram que apenas 11% (15/132) das metas possuem definição de indicadores para seu monitoramento. Este baixo índice enseja considerações acerca da

compreensão e aplicação dos conceitos de gestão e de governança por parte dos elaboradores do PDI da instituição analisada, além de provocar curiosidade quanto à capacidade de demonstração de cumprimento de metas por parte da gestão que adota um tal documento estratégico.

Ainda quanto aos achados, embora esta pesquisa enderece uma perspectiva específica de qualidade dos dados, os documentos que servem de fonte demandam atenção sobre aspectos que antecedem essa perspectiva específica, a saber: compreensão, definição e uso adequado dos termos "meta", "ação" e "indicador".

Os próximos passos envolvem entrevistas com gestores que participaram da elaboração do PDI e com aqueles que vêm conduzindo seus setores seguindo as orientações contidas no PDI. Em seguida, compreendendo melhor os indicadores em uso (já que aqueles formalmente declarados são insuficientes em seu estado atual), poder-se-á identificar os dados necessários à elaboração de cada indicador e, por fim, analisar a qualidade desses dados.

É nesse sentido que este artigo pratica uma inversão na ordem tradicional de investigação da temática. Enquanto tradicionalmente tem-se dados (com suposta qualidade) que dão suporte a indicadores de desempenho que, por sua vez, permitem o monitoramento do alcance de metas, aqui, de acordo com as circunstâncias, observam-se metas que devem (ou deveriam) ter indicadores associados, formados por dados cuja qualidade demanda análise.

Referências

Ballou, D., Wang, R., Pazer, H., & Tayi, G. K. (1998). Modeling information manufacturing systems to determine information product quality. **Management Science**, 44(4), 462-484.

Bedeley, R. T., Ghoshal, T., Iyer, L. S., & Bhadury, J. (2018). Business analytics and organizational value chains: a relational mapping. **Journal of Computer Information Systems**, 58(2), 151-161.

Brasil. UFPB. **Plano de Desenvolvimento Institucional** (PDI) 2014-2018. Disponível em: <http://www.proplan.ufpb.br/proplan/contents/documentos/pdi/pdi_ufpb_2014-2018.pdf>. Acesso em: 28/08/2018.

Tribunal de Contas da União, T. D. C. (2010). **Técnica de indicadores de desempenho para auditorias**. Portaria TCU. Disponível em: http://portal3.tcu.gov.br/portal/page/portal/TCU/comunidades/programas_governo/técnicas anop/BT-CU_indicadores_de_desempenho.pdf . Acesso em 28/08/2018.

Davenport, T. H., & Patil, D. J. (2012). **Data scientist. Harvard Business Review**, 90(5), 70-76.

De Moura Jr., P. J. (2017). Governança de Tecnologia da Informação: A meio caminho entre o isomorfismo e a comoditização. **Revista Eletrônica de Sistemas de Informação**, 16(3), no prelo.

Hazen, B. T., Boone, C. A., Ezell, J. D., & Jones-Farmer, L. A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. **International Journal of Production Economics**, 154, 72-80.

Kaplan, R. S., & Norton, D. P. (2001). **Transforming the balanced scorecard from performance measurement to strategic management**: Part I. Accounting horizons, 15(1), 87-104.

Vídeo da apresentação

Título: Metas, ações e indicadores como subsídios para análise da qualidade de dados: uma inversão necessária entre consequentes e antecedentes.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=41

Transcrição da apresentação

Uma boa tarde a todos, meu nome é Maicon, sou do sétimo período de Administração, e junto com o professor Pedro Jácome da Universidade Federal da Paraíba, nós tivemos esse artigo que ainda está em andamento o nosso projeto de PIBIC, e esse é o nosso título "Metas, ações e indicadores como subsídios para análise da qualidade de dados: Uma inversão necessária entre consequentes e antecedentes". Vocês vão entender melhor durante a apresentação essa análise que nós fizemos.

Às organizações tem um uso imenso de dados e nós sabemos que todas as horas existem fluxos de dados em organizações, informações, e esses dados geram conhecimento para as empresas, então é uma vantagem competitiva para as empresas. Por isso a importância de analisarmos a qualidade desses dados, a sua veracidade, sua precisão, além disso é interessante chegarmos a um valor que esses dados traz, valor em termos de benefício que ele traz para a organização.

Considerando esse contexto, levantamos a questão de que não seria possível, até seria possível mas seria muito oneroso, analisarmos todos os dados de organização, seria oneroso, demandaria tempo. Com isso nós utilizamos uma estratégia, da qual seriam as áreas prioritárias da organização, que são na verdade de a área de planejamento estratégico. Então nós fomos no Planejamento Estratégico de lá e tiramos os dados que dão suporte aos indicadores de desempenho e monitoramento da estratégia.

O objetivo desse projeto foi identificar os níveis de qualidade dos dados contidos nos repositórios institucionais da Universidade Federal da Paraíba (UFPB) para suporte à mensuração dos indicadores de desempenho. Com esse objetivo nós tínhamos alguns objetivos específicos, alguns passos como identificar os indicadores de desempenho contidos no Plano de Desenvolvimento Institucional (PDI) da UFPB em vigência, identificar os dados necessários ao monitoramento de cada indicador de desempenho, e o último foi verificar a qualidade dos dados necessários à obtenção de cada indicador de desempenho.

Bem o PDI da Universidade, que é o Plano de Desenvolvimento Institucional da Universidade, ele contém 31 páginas de texto corrido, então a estratégia que nós utilizamos foi de palavras-chave, além disso elencamos 10 setores de análise, como as pró-reitorias (PRG,PRPG, PRAC, Proplan, Progep, PRAPE e PRA), além disso a agência INOVA, o STI e a biblioteca central. Nós estamos analisando esses setores da Universidade. No INOVA, STI e biblioteca central foi verificado o plano de gestão.

As palavras-chaves que nós utilizamos nesse corpo extenso do planejamento de desenvolvimento institucional foram basicamente "metas", "indicador", entre outros. Essas duas palavras foram colocadas em uma planilha e classificadas conforme eu mostro a seguir.

Está um pouco pequeno, mas realmente eu não consegui alongar mais, mas ali cortou um pouco mas é uma parte pequena do PRPG, aqui está assim "ampliação do número de vagas dos cursos", esse aqui é a meta. Aqui ele compõe um eixo e um objeto, no STI colocamos assim os objetivos, depois metas, aqui nós observamos uma falha, por exemplo, ampliação do número de vagas em cursos existentes.

Uma meta bem definida ela não usa, por exemplo, ampliação, ela usa ampliar. Aqui a gente encontrou essa meta, aqui a gente tem um indicador para essa meta que está no Quadro 5 da avaliação institucional onde está localizado a descrição desse indicador, que é o número de vagas ofertadas para ingresso de alunos em cursos presenciais e a distância, e aqui a gente tem a somo do exemplo "meta" e "indicador". Essa meta está escrita, aqui nós chegamos que ela está escrita, essa meta possui indicador específico? Possui indicador específico.

Aqui nós analisamos a meta em relação à ação, porque nós observamos que houve divergência quanto a sobreposição do termo meta ou ação, teve vezes que usaram termo meta e outras vezes usaram termo ação. Aqui ela foi descrita como meta, e está certo. Aqui seria o caso que nós encontramos, no caso dessa meta de cima não houve indicador.

Quanto aos procedimentos metodológicos a gente utilizou a classificação de metas SMART, que seriam metas mensuráveis, metas específicas, apropriadas, realistas e com prazo determinado. Para indicador de desempenho nós utilizamos a classificação da união que é uma medida que compara com metas preestabelecidas.

Os achados. O número de indicadores não corresponde ao número de metas identificadas, são 132 metas para apenas 15 identificadores, muito insuficiente. Isso gera múltiplas interpretações, como a questão de sobreposição de conceitos de gestão de TI e governança.

É interessante nós percebermos que se uma meta não tem como ser identificada, ela é tida como uma questão de fé. Se nós não temos indicadores para provar que ela foi cumprida não temos governança de TI, não há governança se não possuirmos verificação.

Bem os achados então demonstram que apenas 11% das metas possuem indicadores, é muito pouco. Esse dado nos fez demorar um pouco mais nessa jornada, porque agora nós estamos entrevistando os gestores, sejam às pró-reitorias, seja o STI, seja a biblioteca central, para identificar quais são os indicadores. Porque 15 indicadores apenas são muito insuficiente para prosseguir com o trabalho.

Então os próximos passos que nós elencamos no andamento são as entrevistas com os que participarão da elaboração do PDI, e daqueles que vem conduzindo seus setores seguindo as indicações contidas no PDI. Segundo passo, identificar os dados necessários para a elaboração de cada indicador. E o terceiro passo é analisar a qualidade desses dados.

É um trabalho em andamento mas que já tem alguns achados interessantes como essa questão dos 11% apenas das metas possuindo indicadores relacionados. É esse nosso trabalhou até aqui, muito obrigado.

Slides da apresentação

Título: Metas, ações e indicadores como subsídios para análise da qualidade de dados: Uma inversão necessária entre consequentes e antecedentes.

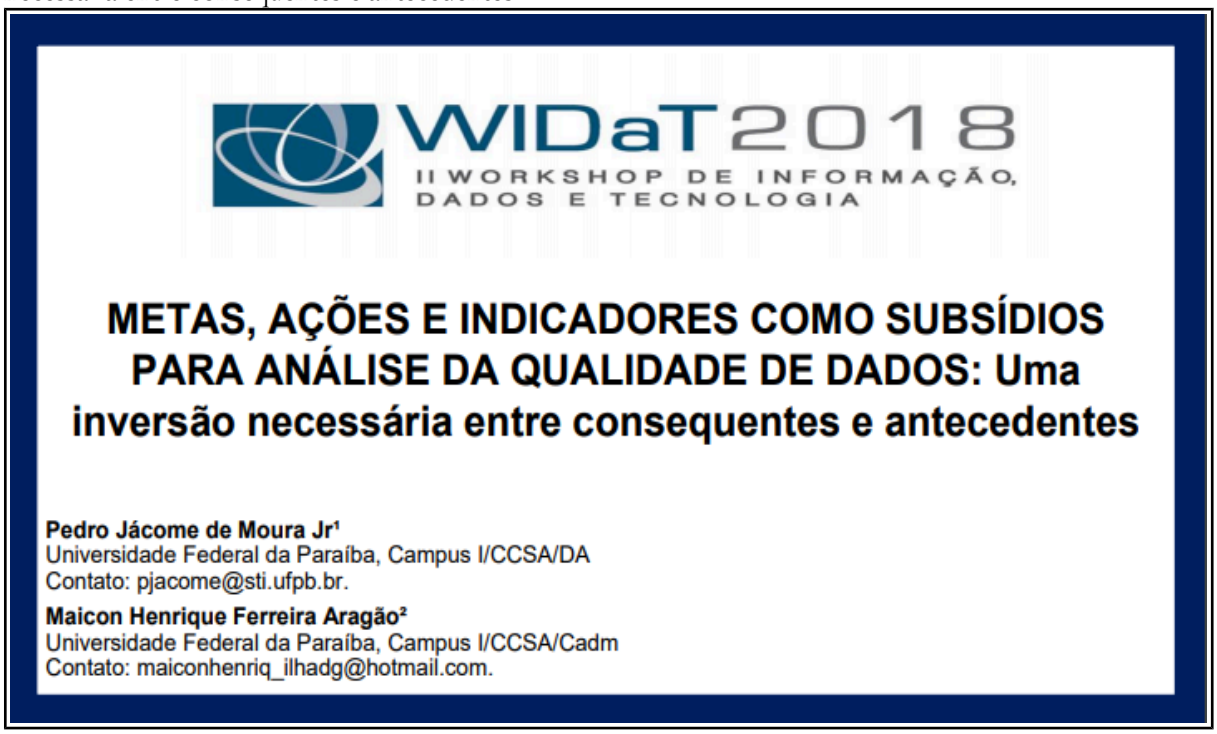

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=41

Previsões de ausência em cuidados especializados em Unidades de Saúde Pública de Florianópolis

Milena Maredmi Correa Teixeira[a], Leandro Pereira Garcia[b], Ingo Ramos[c], Douglas Dyllon Jeronimo de Macedo[d] e Gustavo Medeiros de Araujo[e]

Resumo: O absenteísmo em serviços de atendimento de saúde de média e alta complexidade do Sistema Único de Saúde está associado ao desperdício e ineficiência, uma vez que estes procedimentos envolvem grande densidade tecnológica. Nesse sentido, esse estudo busca desenvolver um modelo que possa identificar pacientes com grande probabilidade de falta em consultas especializadas, como base em aprendizagem de máquina. Para realização dessa pesquisa foram usados, como estudo-piloto, dados de atendimentos nos Centros de Especialidades Odontológicas da Secretaria Municipal de Saúde de Florianópolis entre os anos de 2016 a junho de 2018.

Palavras-chave: Absenteísmo; Consultas médicas especializadas; Faltas preditivas; Unidades de Saúde Pública de Florianópolis.

Absence forecast in specialized care in Public Health Units of Florianópolis

Abstract: Absenteeism in health care services of medium and high complexity of the Unified Health System is associated with waste and inefficiency, since this procedure involves a high technological density. In this sense, this study seeks to develop a model that can identify patients with a high probability of lack in specialized consultations, as a basis in machine learning. In order to carry out this research, we used as a pilot study data, between 2016 and june 2018, from the Dental Specialties Centers of the Municipal Health Department of Florianópolis.

Keyword: Absenteeism; Specialized medical consultations; Predictive errors; Public Health Units of Florianópolis.

a Universidade Federal de Santa Catarina (UFSC). E-mail: milena.correira@grad.ufsc.br. ORCID: https://orcid.org/0000-0002-4469-5006. Currículo: http://lattes.cnpq.br/4117308933497698

b Universidade do Sul de Santa Catarina (USSC). E-mail: lpgarcia18@gmail.com. ORCID: https://orcid.org/0000-0002-8601-7166. Currículo: http://lattes.cnpq.br/0573692306138917

c Universidade Federal de Santa Catarina (UFSC). E-mail: ingoramos12@gmail.com. Currículo: http://lattes.cnpq.br/5051204071216974

d Universidade Federal de Santa Catarina (UFSC). E-mail: douglas.macedo@ufsc.br. ORCID: https://orcid.org/0000-0002-3237-4168. Currículo: http://lattes.cnpq.br/0149028226656519

e Universidade Federal de Santa Catarina (UFSC). E-mail: gustavo.araujo@ufsc.br. ORCID: https://orcid.org/0000-0003-0572-6997. Currículo: http://lattes.cnpq.br/2609254559240670

1 Introdução

O sistema único de saúde (SUS) tem convivido com problemas de financiamento desde que foi criado. Iniciativas foram tomadas para minorar, pelo menos em parte, o problema. A aprovação da CPMF[2], em 1996, e da Emenda Constitucional 29[3], em 2000, foram as mais importantes(Piola et al., 2013) regulamentando e potencializando a atenção ao sistema único de saúde no País.

Contudo, é preciso ressaltar que os recursos destinados à saúde no Brasil, embora não ideais, não diferem de alguns países em desenvolvimento que lograram obter melhor assistência à população do que aquela que hoje, em média, é fornecida aos brasileiros (Piola et al., 2013).

Em épocas de escassez de recursos, duas ações são fundamentais para que o SUS consiga ofertar melhores serviços: 1) forçar um maior repasse para a saúde pública; e 2) melhorar os gastos em saúde, aumentando a eficiência do sistema como um todo.

Ações de advocacy para o aumento do repasse têm surgido de entidades como a ABRASCO. O aumento da eficiência, por sua vez, pode ser alcançada com o fortalecimento da atenção primária e com a redução de desperdícios na média e na alta complexidade. A atenção primária à saúde é o atendimento inicial, cujo principal objetivo é a prevenção de doenças, tratamento de agravos mais prevalentes e o direcionamento de casos menos prevalentes e mais graves para outros níveis de complexidade (SALDIVA; VERAS, 2018). Dessa forma, consegue racionalizar a utilização dos recursos em saúde, fazendo com que a entrada dos indivíduos no sistema de saúde ocorra em seu ponto mais seguro e menos dispendioso, as Unidades Básicas de Saúde (UBS). Uma boa atenção primária, deve oferecer acesso amplo e oportuno a população, fazendo com que as pessoas consigam rapidamente sanar suas principais necessidades em saúde.

Porém, a atenção primária, isoladamente, não é capaz de oferecer um cuidado integral ao cidadão, sendo, muitas vezes necessária sua articulação com serviços de saúde de média e alta complexidade. Esta articulação deve ser feita por meio de regulação, fazendo com que casos mais graves sejam atendidos de forma prioritária.

Nesse sentido, um grande problema em termos de eficiência são os desperdícios ocasionados por faltas em consultas médicas e odontológicas nos níveis mais altos de complexidade. Diferente do que ocorre na atenção primária, onde o paciente deve, preferencialmente, ser escutado no dia em que procura a UBS, reduzindo muito o número de faltas, o acesso à média e alta complexidade dá-se por encaminhamento, com marcação antecipada, fazendo com que os pacientes precisem aguardar em fila para a consulta. Desta forma, o número de faltas nestes níveis de complexidade tendem a ser maior que na atenção primária.

Em Florianópolis, por exemplo, o percentual de faltas é de 3% para consultas médicas e 12% para consultas odontológicas na atenção primária (FLORIANÓPOLIS, 2018a). Na média complexidade municipal, a mediana de faltas é de 26% (FLORIANÓPLIS, 2018b).

O absenteísmo em serviços de atendimento de média e alta complexidade vinculam-se a um alto custo, uma vez que estes são procedimento geralmente demorados e com o envolvimento de uma maior densidade tecnológica. (CONASS, 2007).

2 CPMF. Disponível em:<https://www12.senado.leg.br/noticias/entenda-o-assunto/cpmf>. Acesso em: 19 set. 2018.

3 Regulamentação da Emenda Constitucional Nº 29, De 2000. Disponível em:<http://www2.camara.leg.br/orcamento-da-uniao/estudos/2012/nt14.pdf>. Acesso em: 19 set. 2018.

Neste sentido, o presente trabalho visa a contribuir com a redução do desperdício no SUS, buscando produzir um modelo que possa identificar pacientes com grande probabilidade de falta às consultas especializadas, baseado em algoritmos de aprendizagem de máquina.

2 Objetivo

Construir um modelo de predição de possíveis faltantes às consultas especializadas no Sistema Único de Saúde.

3 Procedimentos Metodológicos

O desenvolvimento do modelo, partiu de estudo-piloto com dados secundários fornecidos pela Gerência de Inteligência e Informação da Secretaria Municipal de Saúde de Florianópolis.

Os dados correspondem a consultas agendadas no período de 1 de janeiro de 2016 a 30 de junho de 2018, realizadas nos dois Centros de Especialidades Odontológicas - CEOs do município: CEO Centro e CEO Continente. Estes serviços atendem nove especialidades odontológicas, com agendamento a partir de encaminhamentos de dentistas da atenção primária do município.

Para cada uma das especialidades, foram extraídos dos bancos: a data e o período do dia do atendimento, a Unidade de Referência (Centro de Saúde que realizou o encaminhamento), escolaridade, idade e sexo do paciente, além da indicação de primeira consulta ou retorno e de falta ou comparecimento.

Baseando-se nas especialidades com maior porcentagem de faltas neste período, foram selecionadas apenas três delas para o estudo: endodontia, periodontia e radiológica.

Gráfico 1: Percentual de faltas por especialidade nos anos 2016 /2017.

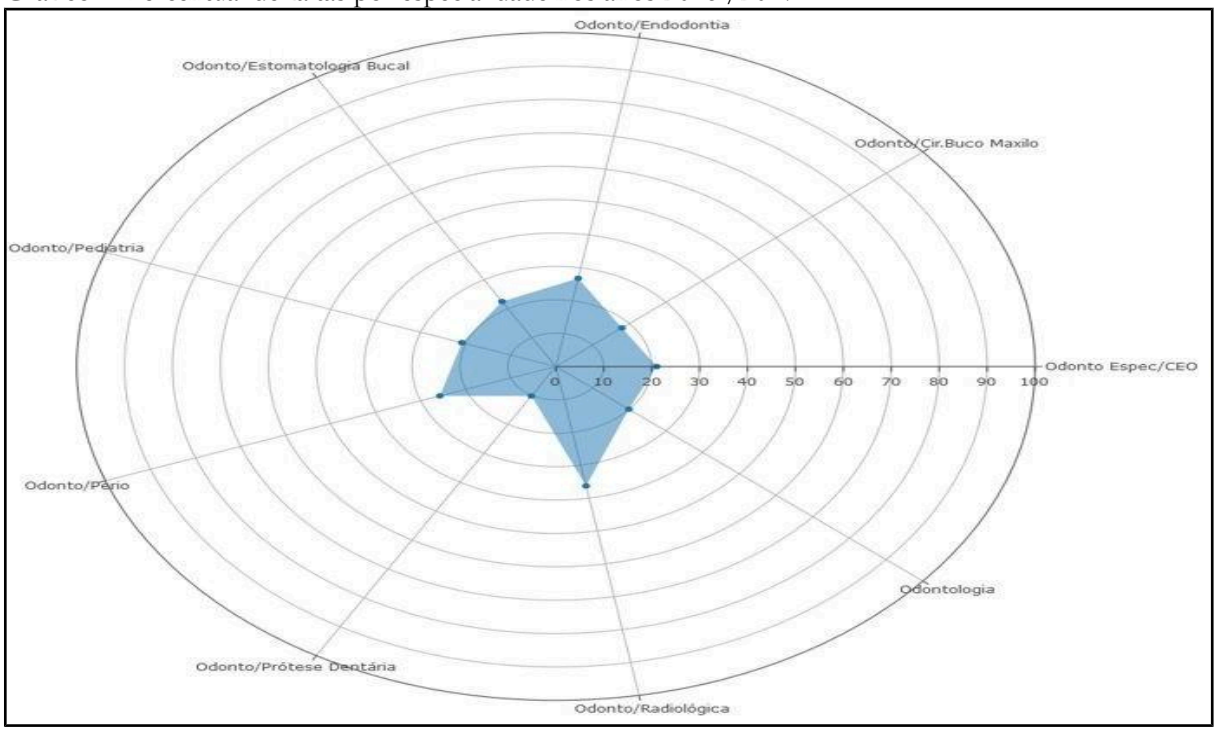

Fonte: Autores.

Para a etapa de predição de faltas nos atendimentos, foram aplicados os modelos de aprendizagem de máquina nos bancos de dados das especialidades. Por se tratar de um problema de classificação binária, que neste caso, será classificar se o usuário irá faltar ou não, utilizamos a matriz de confusão para aferir o preditor. Para o problema em questão, utilizamos como métrica de avaliação do preditor, a divisão do número de verdadeiros positivos pela soma dos falsos positivos e falsos negativos (VP / FP + FN).

O propósito em usar essa métrica foi selecionar o algoritmo que maximiza a relação entre acertos e erros nas classificações dos faltantes.

É importante salientar, que segundo a Resolução Nº 510, de 7 de abril de 2016 (CNS, 2016), do Conselho Nacional de Saúde do Brasil, pesquisas com bancos de dados, cujas informações são agregadas, sem possibilidade de identificação individual não precisam ser submetidas a Comitês de Ética. Desta forma, não houve submissão deste projeto a um Comitê de Ética em pesquisa.

3.1 Tratamento de Dados

Os dados entre os anos de 2016 e 2017 foram usados para o treinamento dos modelos. Os modelos treinados e validados utilizando o método K-fold, com número de folds igual a 10. Além disso, os conjuntos de dados foram balanceados para aumentar a classe minoritária.

Para os testes dos algoritmos, utilizou-se dados do ano de 2018 para verificar a capacidade de predição do melhor modelo escolhido.

3.2 Algoritmos de Aprendizado de Máquina

Utilizamos os seguintes algoritmos de aprendizagem de máquina para realização da classificação dos pacientes como faltantes ou não faltantes: Generalized Linear Model, Random Forest, k-Nearest Neighbors, Neural Network, Stacked AutoEncoder Deep Neural Network, eXtreme Gradient Boosting, Stochastic Gradient Boosting, AdaBoost Classification Trees.

A implementação destes algoritmos deu-se por meio do pacote Caret do software R (R, 2018).

Algoritmos foram parametrizados da seguinte forma:

Figura 1: Parâmetros para a função de controle dos modelos.

Função "trainControl": controle que deve ser utilizado em todos os modelos para que sejam comparáveis. No código é atribuída a uma variável de nome "myControl", para poder ser utilizada da função de treino.		
Parâmetro	Valor	Descrição
method	"repeatedcv"	Dividir o banco em treinamento e teste diversas vezes. Reamostragem.
number	10	Define o número de folds (dobras) para o método de reamostragem.
summaryFunction	twoClassSummary	Calcular métricas de desempenho.
classProbs	TRUE	Computa as probabilidades dos modelos.
verboseIter	FALSE	Não imprime o log de treinamento.
savePredictions	TRUE	Quanto das predições deve ser salvo. (Tudo)
returnResamp	"all"	Quantidade das métricas que devem ser salvas. (Tudo)
sampling	"up"	Aumenta aleatoriamente a classe minoritária. Balanceamento dos dados.
allowParallel	TRUE	Permite a computação paralela

Fonte: Autores.

Todas as análises foram executadas com o uso dos softwares estatísticos R (R, 2018) com a IDE R-Studio (RSTUDIO, 2018).

Figura 2: Parâmetros para a função de treino dos modelos.

Função "train": configuração de parâmetros para os modelos de classificação e regressão e calculo de desempenho.		
Parâmetro	Valor	Descrição
y	FALTA	Variável preditora
data	train_data	Banco no qual serão aplicados os modelos.
preProcess	c("center", "scale")	Centraliza e escala os dados de predição.
metric	ROC	Métrica para comparação dos modelos.
method	modelos[index]	Lista com índice, retorna um string com o nome do modelo.
trControl	myControl	Aplica o controle (trainControl).

Fonte: Autores.

3.3 Aplicação de Ciência de Dados à previsão de Faltas

Na tentativa de encontrar padrões nos dados referentes aos anos de 2016 a junho de 2018 de atendimentos nos Centros de Especialidade Odontológicas para predizer usuários que faltam em consultas, foram feitas análises e descrições de algumas das variáveis disponíveis, sendo elas, dia da semana e período dos atendimentos, e também escolaridade e sexo dos pacientes.

4 Resultados

Primeiramente, realizamos um trabalho de análise descritiva para verificar a relevância das características em cada especialidade. Posteriormente, realizamos a avaliação dos diversos modelos de aprendizado automático para verificar a eficiência na predição das faltas.

4.1 Análise Estatística Descritiva

Com as especialidades já escolhidas, obtiveram-se dados de 18.503 consultas, tendo registradas 5.944 faltas para o conjunto.

Sendo que ao separar os dados por especialidade, periodontia 2.531 atendimentos e 652 faltas, endodontia com 5.360 registros e 1.438 faltantes e por fim, radiológica com a maior quantidade de atendimentos, 10.612, assim como a maior quantidade de faltas, com 3.854.

Quanto às variáveis usadas, odontologia radiológica e odontologia periodontia apresentaram sexta e sábado respectivamente como dias da semana com maior percentual de faltas, enquanto segunda feira foi o dia com menos faltantes.

Na odontologia radiológica, 40% de todos os pacientes que marcaram na sexta-feira, faltaram. A endodontia foi a única das três que não apresentou sexta ou sábado como dia da semana com mais faltas, mas sim terça-feira.

A escolaridade segue um padrão, para as três especialidades. Foi possível perceber que o de faltantes diminui com relação a pacientes que tenham ensino superior, mestrado ou doutorado.

Da mesma forma, que ensino médio incompleto aparece como grau de escolaridade com o maior percentual, assim como, não alfabetizados, fundamental (completo e incompleto).

O percentual de faltas não teve muita variação na especialidade periodontia de acordo com o período de atendimento, sendo 25,8% dos pacientes que tinha consulta agendada para tarde faltará e 25,5% daqueles com consultas agendadas pela manhã.

Padrão semelhante ao encontrado na Endodontia, com 28% de faltas a tarde e 25% no período matutino. A especialidade com maior discrepância de faltas por período de atendimento foi radiológica, que variou mais de 10% entre os períodos, sendo que de tarde aconteceram mais faltas.

Gráfico 1: Maior percentual de faltas em um dia da semana. (Radiológica).

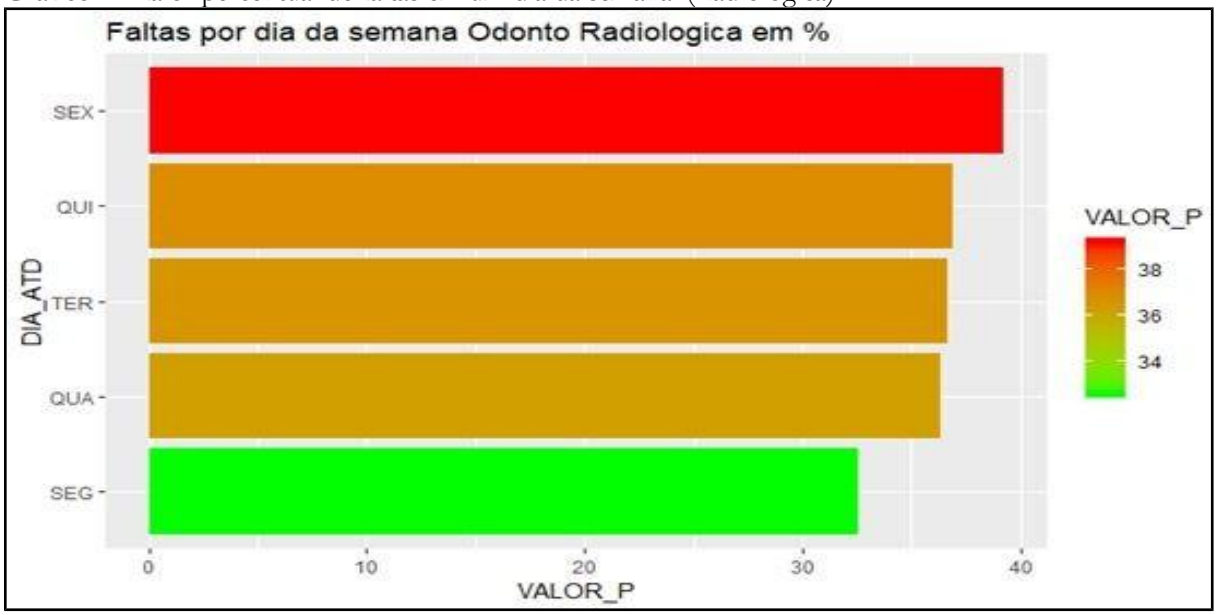

Fonte: Autores.

Gráfico 2: Percentual de faltas por escolaridade odontologia radiológica.

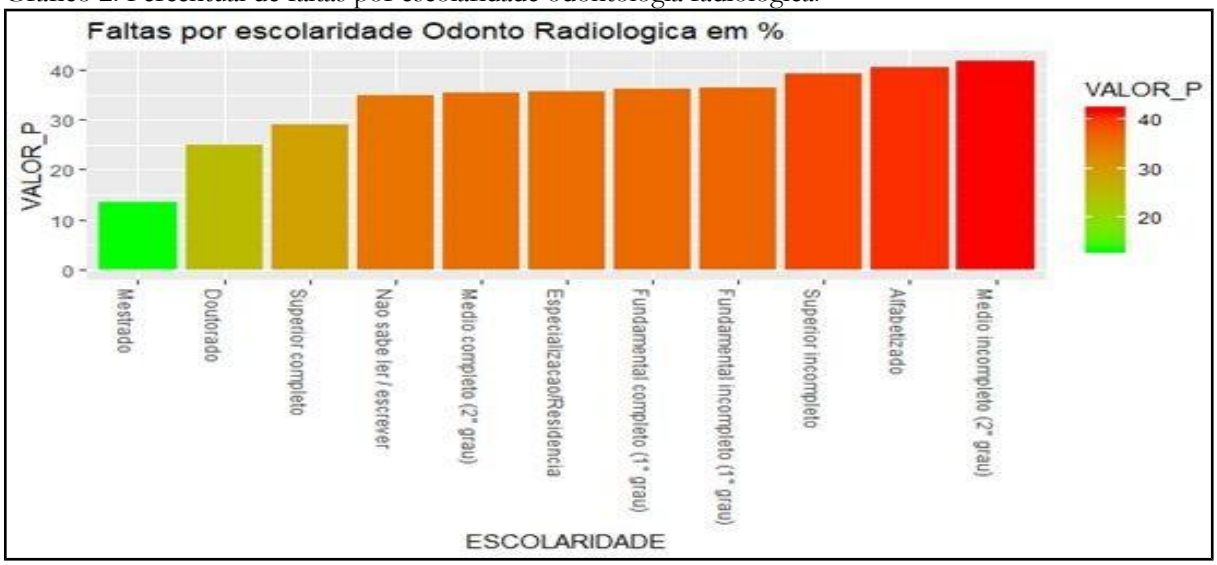

Fonte: Autores.

Não se observaram grandes variações entre o percentual de faltas entre homens e mulheres. Na Periodontia o percentual de faltas entre as mulheres tende a ser ligeiramente maior. Na Radiologia e na Endodontia homens tendem a faltar mais. Em todas as especialidades, porém, a diferença do percentual de faltas entre os sexos não passa de dois por cento.

Gráfico 3: Percentual de faltas por período em radiologia.

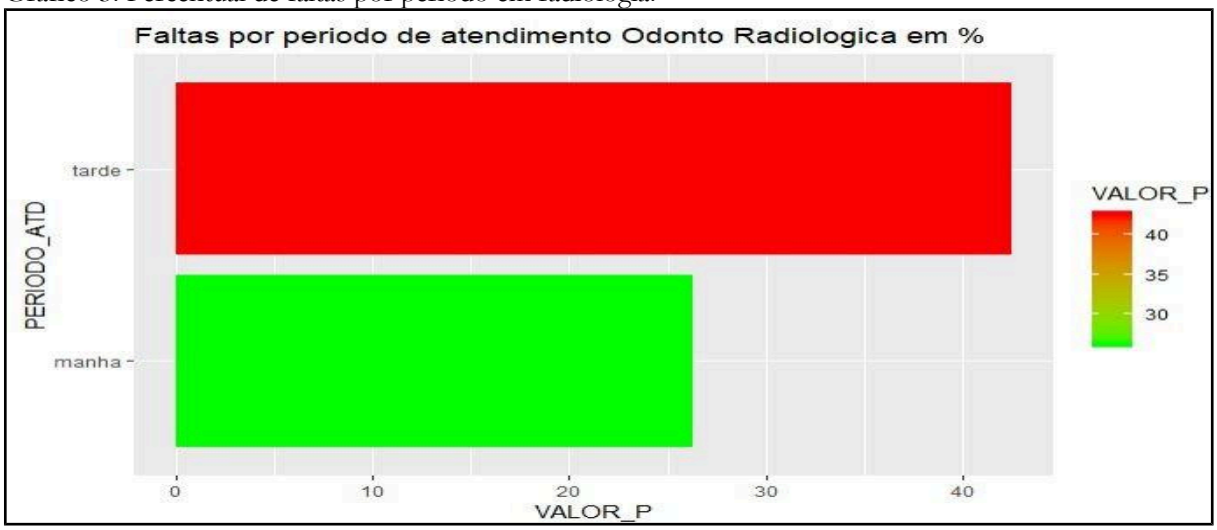

Fonte: Autores.

Gráfico 4: Percentual de faltas por sexo em Endodontia.

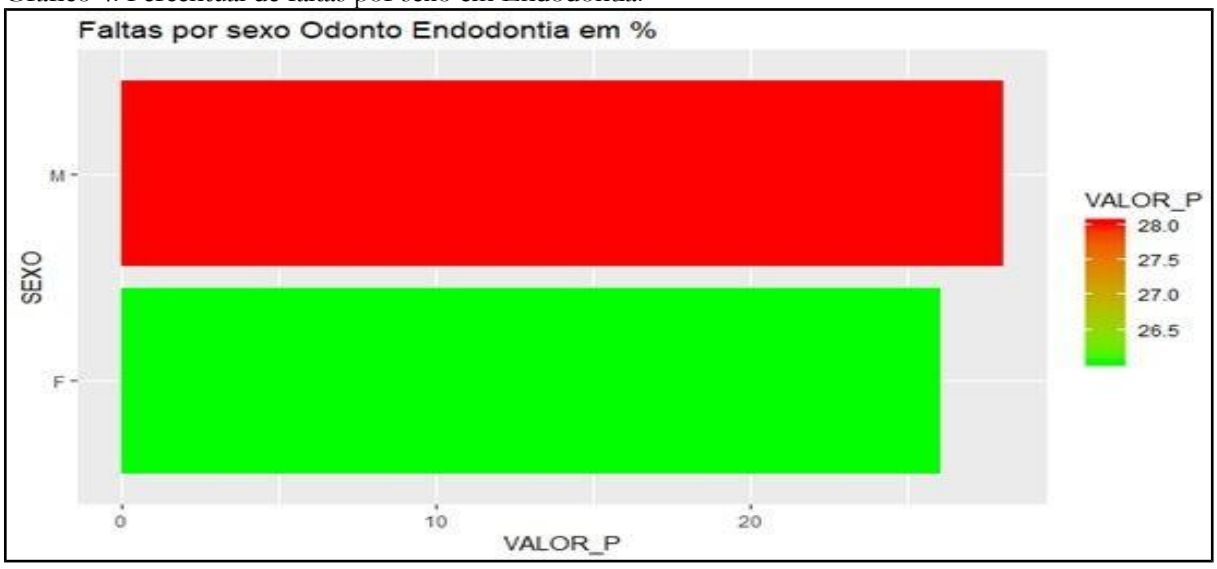

Fonte: Autores.

4.2 Aprendizado Automático

Em relação à seleção do modelo para predição dos faltantes, para cada uma das especialidades, usamos os dados entre 2016 a 2017 para treino e os dados de 2018 para teste. Quanto às matrizes de confusão do processo de treinamento, nenhum dos resultados apresentou especificidade boa, não passando de 0,4, o que também aconteceu para a sensibilidade, chegando à 0,739. A média entre os resultados dos três modelos com melhor desempenho de acurácia foi de aproximadamente 0,588. Entretanto, a acurácia não foi usada como método de avaliação dos algoritmos, uma vez que por se tratarem de bancos com dados não balanceados.

Os modelos aplicados ao banco de dados não balanceados predizem de forma discrepante apenas um valor da variável preditora – neste caso, que o usuário não faltará, enquanto prediz pouco que irá faltar, tornando essa métrica inválida para a avaliação. Mesmo com o

balanceamento dos dados no treinamento, os resultados não melhoram na predição, a especificidade se mantém baixa e a taxa de não informação foi maior do que a acurácia para todos os resultados. Para todos os bancos, o modelo de aprendizado automático que teve o melhor desempenho foi o adaboost, alcançando sensibilidade de 0,761 e especificidade de 0,273 no banco Odonto_Endodontia (Apêndice A). Para o banco Odonto_Radiologica (Apêndice B) a sensibilidade foi a menor, chegando apenas em 0,636, mas a especificidade foi a melhor com 0,423. Já para o banco da especialidade Odonto_Perio (Apêndice C), a sensibilidade foi a maior, 0,802, mas a especificidade foi também baixa, 0,244.

5 Conclusão

Em cada cinco consultas médicas agendadas, um paciente falta e gera prejuízo de 13,4 milhões em SC em 2016 (WEISS, 2017). Apesar de implantadas medidas mais rigorosas, e exigências nas marcações de consultas ainda não impedem o absenteísmo, trazendo prejuízo à população. Nesse sentido, um modelo de previsão de faltas é imprescindível devendo diminuir os custos, pois o algoritmo pode prever se um paciente irá faltar ou não.

Este estudo-piloto indica um possível caminho para a utilização de técnicas de aprendizagem de máquina no aumento da eficiência do Sistema Único de Saúde. Os resultados preliminares dos algoritmos, podem estar relacionados à baixa capacidade preditora das features selecionadas. Desta forma, se faz necessário realizar mais estudos nas seleções de características com maior significância no modelo de dados. Com um subconjunto de características mais significantes, é possível melhorar os preditores e por consequência, auxiliar as Secretarias de Saúde do Brasil a reduzirem o absenteísmo em consultas especializadas.

Referências

ARAÚJO, Edson C.; LOBO, Maria Stella. Desafios para Sustentabilidade do Sistema Único de Saúde: **Draft for Review**. p.13, 2018.

BRASIL. **Florianópolis atinge 100% de cobertura da Atenção Básica com a Estratégia de Saúde da Família.** Departamento de Atenção Primária. Ministério da Saúde. Disponível em: http://dab.saude.gov.br/portaldab/noticias.php?conteudo=_&cod=1998. Acessado em: 01/10/2018.

CNS. Resolução No 510, de 07 de Abril de 2016. 2016.Disponível em: http://conselho.saude.gov.br/resolucoes/2016/Reso510.pdf. Acessado em: 01/10/2018.

BRASIL.(CONASS)CONSELHO NACIONAL DE SECRETÁRIOS DE SAÚDE. **Assistência de média e alta complexidade no SUS**. 2007; 248p.

FLORIANÓPOLIS. Sala de Situação da Atenção Primária. Secretaria Municipal de Saúde de Florianópolis. 2018ª.

_____. Sala de Situação da Regulação. Secretaria Municipal de Saúde de Florianópolis. 2018b.

GONÇALVES, Cláudia Ângela et al. Estratégias para o enfrentamento do absenteísmo em consultas odontológicas nas Unidades de Saúde da Família de um município de grande porte: uma pesquisa-ação. **Ciência & Saúde Coletiva**, v. 20, p. 449-460, 2015.

PIOLA, Sérgio Francisco et al. Estruturas de financiamento e gasto do sistema público de saúde: **A saúde no Brasil em 2030-prospecção estratégica do sistema de saúde brasileiro: estrutura do financiamento e do gasto setorial** [online]. Rio de Janeiro: Fundação Oswaldo Cruz, v. 4, p. 19-70, 2013.

R – **A language and environment for statistical computing R Foundation Statistical Computing**, 2018. Disponível em: https://www.r-project.org. Acessado em: 01/10/2018.

RStudio: **integrated development for R RStudio,** Inc, 2018. Disponível em: http://www.rstudio.com/. Acessado em: 01/10/2018.

SALDIVA, Paulo Hilário Nascimento; VERAS, Mariana. Gastos públicos com saúde: breve histórico, situação atual e perspectivas futuras. **Estudos Avançados**, v. 32, n. 92, p. 47-61, 2018.

Apêndice A – Resultados banco OdontoEndodontia.

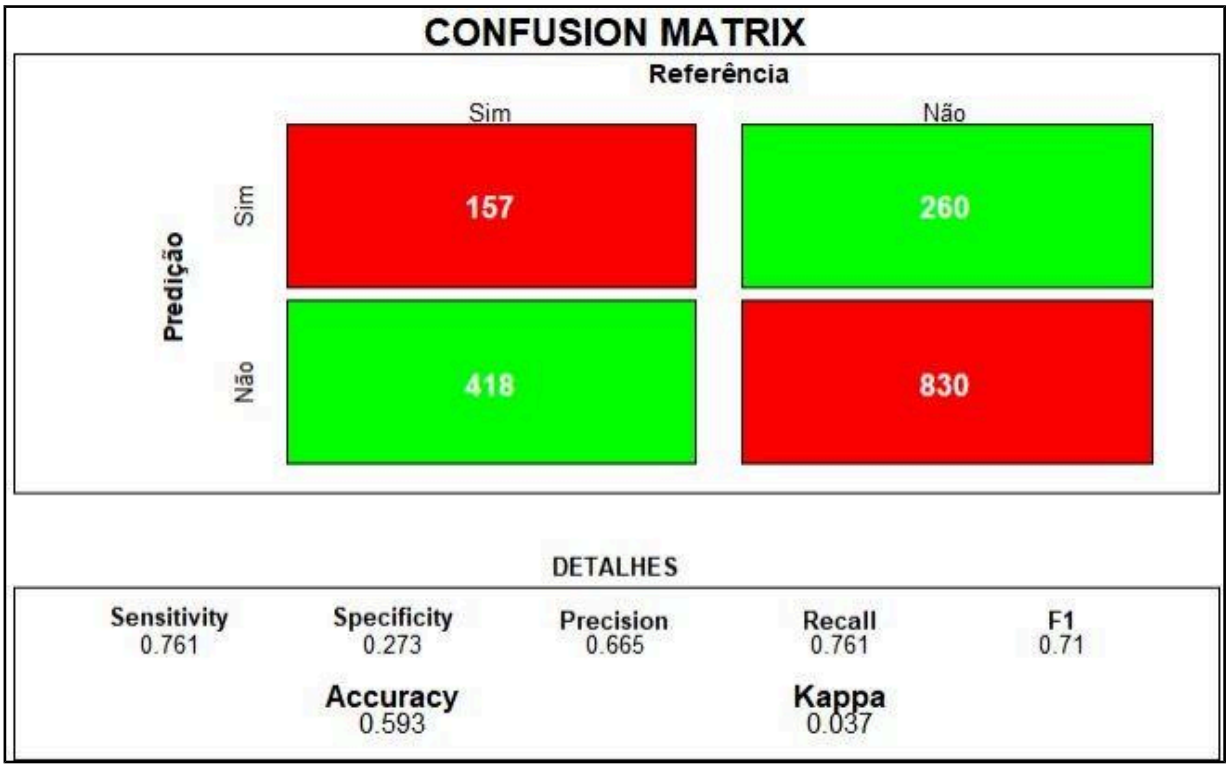

Fonte: Autores.

Apêndice B – Resultados banco OdontoRadiologica.

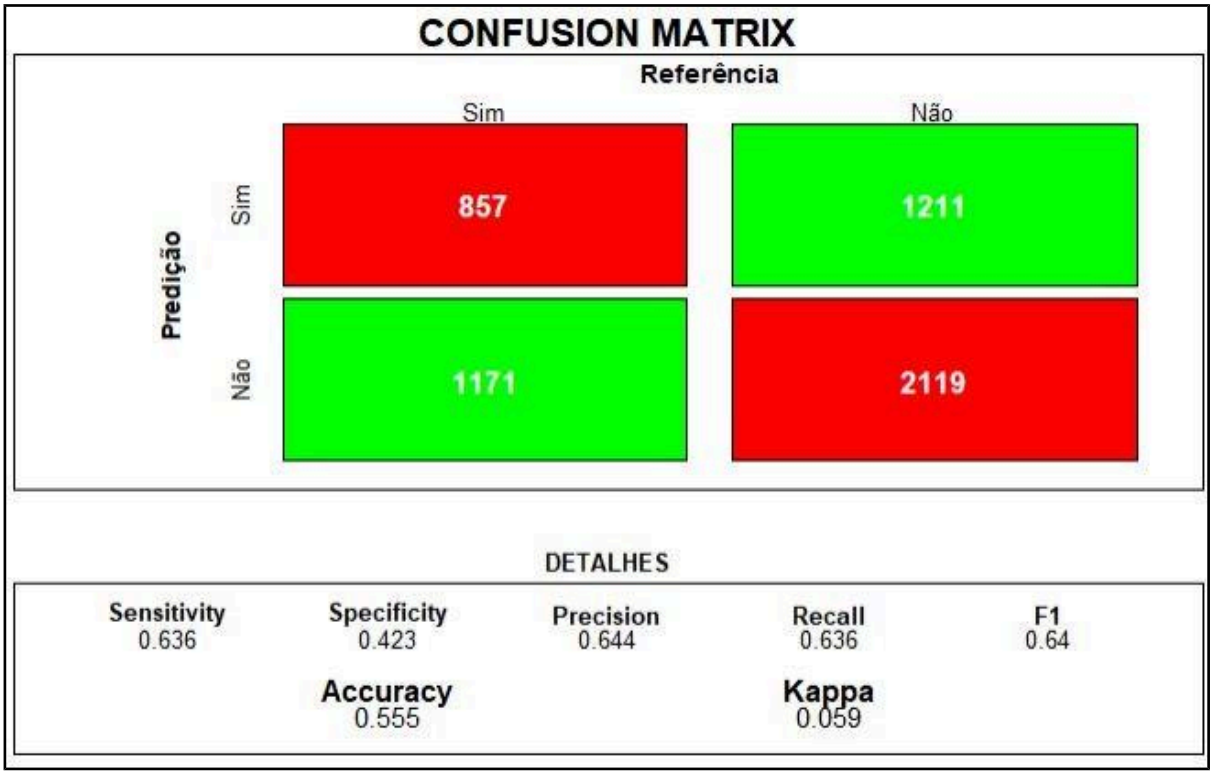

Fonte: Autores.

Apêndice C – Resultados banco OdontoPerio.

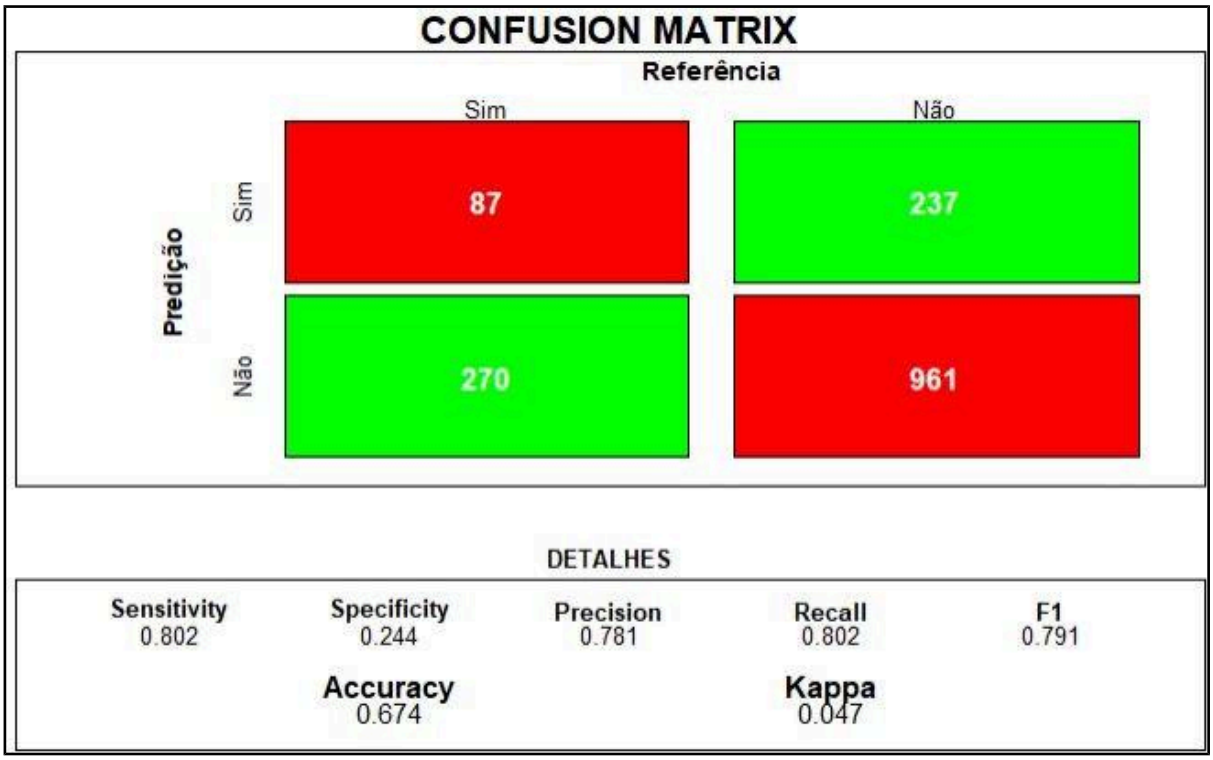

Fonte: Autores.

Vídeo da apresentação

Título: Previsões de Ausência em Atendimento Especializado em Unidades de Saúde Pública de Florianópolis.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=42

Transcrição da apresentação

Olá pessoal, sou aluno da UFSC, e esse trabalho aqui é um trabalho de comunicação do nosso grupo de engenharia e ciência de dados em Florianópolis.

Aqui é mais um overview o que eu vou passar para vocês porque o trabalho está em andamento, então são os nossos preliminary results e eu vou mostrar aqui o que a gente construiu um modelo de previsão de faltas em atendimentos especializados em Unidades de Saúde de Florianópolis, que é um problema lá real.

O Sistema Único de Saúde (SUS) tem convivido com bastante problema de financiamento e gerenciamento, além dos problemas de gerenciar os recursos, isso vem dando uma dor de cabeça bastante grande tanto para a gestão quanto para o estado, e isso traz prejuízos de recursos financeiros mal administrados.

Apesar do impasse do recurso financeiro ideal nós estamos no caminho do desenvolvimento. O Brasil está um pouco pior comparado com alguns países em questão de repasse do PIB para saúde mas está melhor do que alguns outros em desenvolvimento como Chile e México.

Nessa época que a gente tem escassez de recursos e a gente não sabe se vai piorar ou não, a gente tem duas frentes para se trabalhar: ou pega mais dinheiro ou trabalha bem com o que tem. A ideia do trabalho surgiu dessa cooperação para tentar mitigar alguns dos problemas de gerenciamento de recursos que é justamente essa questão de faltas.

No caso o grande problema em termos de eficiência lá no SUS e em Florianópolis, é o desperdício causado por faltas em consultas médicas e odontológicas, ou seja, a pessoa marca a consulta e não vai. Existem diversos fatores, esses fatores a gente vem analisando diretamente com a agência de inteligência do SUS, a gente tem os dados e a gente verifica o que está acontecendo.

Em Florianópolis por exemplo tem um índice médio de faltas de 3% em consultas médicas e 12% em consultas odontológicas, então é um percentual bastante grande principalmente com relação às consultas odontológicas e isso gera perda de recurso financeiro, além de atrasar a fila.

Como objetivo que a gente identificou, analisar características que levam a ausência nas consultas de atendimento de complexidade mais alta no SUS em Florianópolis e construir um modelo que possa identificar os pacientes com grande probabilidade de faltas em consultas especializadas. A gente mapeou isso como um problema de classificação binária, se o cara vai faltar ou não vai faltar.

A gente pegou os dados de consultas agendadas, 18.503 consultas, no tempo de 1º de janeiro de 2016 até 30 de junho de 2018, para dois centros de especialização odontológico, com várias especialidades, então a gente pegou um pequeno recorte para poder trazer aqui no WIDAT. Então a gente analisou especialidades odontológicas para esse trabalho, a radiologia com 10.612 consultas, periodontia com 2.531, e endodontia com 5.360 consultas, no período de mais ou menos 1 ano e meio.

Algumas características que a gente analisou, que são as nossas features para começar a trabalhar, algumas delas a qualidade no cadastro, porque o SUS de Florianópolis tem um protocolo de atendimento que é todo digital, de uns 2 anos para cá nós temos uma base que a

gente consegue trabalhar com todos os dados daquelas consultas, e um desses dados a escolaridade, dias da semana que acontecem as faltas quando são agendadas as consultas, o período que na verdade esse período foi um trabalho de data cleaning porque a gente transformou um horário em período porque senão ficaria muito a quantidade de variáveis a ser analisada então a gente acabou binarizando ali e fazendo manha e tarde, sexo, dentro outras variáveis.

Vou apresentar algumas que a gente analisou que é bem interessante de mostrar. A gente fez a aplicação de alguns algoritmos de machine learning, a gente pegou um set de algoritmo para poder verificar essa previsão, e a gente analisou a acurácia e a sensibilidade, que é bastante importante nesse caso para prever as faltas.

A sensibilidade que é a proporção de verdadeiros positivos, que é a capacidade do sistema predizer corretamente a condição para casos que realmente tem a condição de verdadeiro, ou seja, são os acertos positivos sobre o total de positivos, os verdadeiros positivos e os falsos negativos. Falsos negativos é que seriam faltas mas foram classificados como não.

Primeiro a gente faz segundo aquele rito de data science, faz um data cleaning, faz um data analytics, e a gente fez uma análise de dados com relação às especialidades de consultas em odontologia e viu ainda que a radiologia tem uma quantidade bastante de faltas, a periodontia também e a endodontia, entre outras especialidades.

Um exemplo simples aqui, a gente tem faltas por dia na semana em radiologia, a gente tem que de segunda a sexta essa distribuição de faltas, a gente percebeu que de sexta-feira é quando tem mais faltas, quando o pessoal mais falta em consultas especializadas. Lembrando que essas consultas especializadas muitas vezes são pagas pelo estado, são consultas que o SUS para ali 300 reais dependendo do tipo da consulta, e o cidadão falta na sexta-feira por exemplo, na segunda é quando menos falta.

Um outro dado interessante de odontologia e radiologia no caso é o nível de escolaridade. A gente vê aqui que o pessoal com mais escolaridade possível como mestrado e doutorado faltam menos mas a gente vê que isso vai crescendo, o superior incompleto falta mais, e o pessoal que tem o fundamental completo ou incompleto.

A gente tem uma distribuição aqui dos tipos de escolaridade com relação às faltas em consultas, então tem uma relação, quanto maior a escolaridade mas só que aqui fura um pouco no superior completo, mas quanto mais alta a escolaridade menor a probabilidade de faltar. Teria que cruzar com outros tipos de dados do IBGE para poder encontrar uma razão para isso daí.

Um outro tipo de variável foi o sexo, então há uma diferença pequena mas nessa análise os homens faltam um pouco mais que às mulheres nas consultas.

Mais uma análise, por período, então o período da tarde a gente verificou que há uma quantidade de faltas maior para a odontologia do que na manhã. Teria que verificar e cruzar com outros dados para verificar a razão disso daí. Inicialmente é uma análise mais crua daquele dado que está disponibilizado pelo SUS.

A partir dessas análises de dados, temos outras variáveis e outras análises que a gente fez, a gente parte para poder fazer aquele procedimento para escolher as características que mais são importantes e representam aquele modelo de predição de faltas. A gente pegou alguns algoritmos

de machine learning, os mais usados e os principais, como: o modelo linear para tentar ver se os dados seguem uma linearidade; o Random Forest que é bastante importante em diversas análises de machine learning para grandes quantidade de dados; Rede Neural, pegamos uma rede simples; e os Boosts com três configurações (Gradiente Boosting, Stochastic Gradient Boosting e o AdaBoost).

Desses resultados que nós tivemos iniciais, nós tivemos ali na nossa matriz de confusão que nos dá ali a sensibilidade como um dado importante e como a acurácia. A gente não teve uma acurácia muito boa dessas features, mas a gente teve uma sensibilidade até aceitável.

Para a radiologia nós tivemos uma acurácia não muito boa mas a sensibilidade até um pouco melhor do que a acurácia. A precisão, uma boa precisão. E para a periodontia nós tivemos ali resultados chegando até 70% de acurácia e precisão quase 80%, e sensibilidade 80%.

A gente percebeu que melhora a acurácia a precisão também aumenta, nós fizemos diversos, porque quando nós começamos ter um underfit modelo a gente tem três coisas que agente pode fazer: uma ou a gente mexe nos parâmetros, a gente fez; usamos um boot search para poder varrer aquela quantidade de parâmetros possíveis que o modelo precisava e fizemos isso, então cumprimos o rito. Outra coisa que a gente pode fazer é justamente melhorar a engineers, escolher novas features que representam melhor o modelo, só que a gente tinha todas as features naquele momento.

Nesse caso a gente percebeu que varremos todos os parâmetros possíveis e máximo de resultado que a gente teve foi esse que eu apresentei para vocês, quanto mais de 70% acurácia e 80% de sensibilidade em relação ao modelo.

A gente agora, inclusive essa semana, o pessoal está conseguindo coletar mais duas variáveis, uma de chuva, se teve chuva naquele momento, e ver se o cara faltasse, essa variável a gente consegue no instituto de meteorologia, é bem simples o acesso ao site, você cadastra e eles te dão um dataset que você quiser e você escolhe o tema, eles te dão os MLs de chuva, umidade, várias características que precisa.

E uma variável que a gente acho bastante importante é o tempo de espera, que é um pouco óbvio, porque tem consulta que demoram 7 meses ou 1 ano, a gente não sabe nem se o cara vai estar vivo até lá por exemplo. Então essa é uma variável bastante importante que estamos trabalhando e incluindo no modelo para ver se a gente melhora esse modelo de predição para chegar até no entorno de 90% ou 95%, já seria ideal para que o SUS possa utilizar esse modelo. Ou seja, a ideia é, o cara vai fazer o cadastro da consulta, o sistema vai alertar uma probabilidade muito alta do cara faltar, então para o SUS isso é muito interessante para que o SUS possa ligar algum tempo antes, para saber e alertar que tem consulta, de repente o cara não vai também porque morreu por exemplo, ou a pessoa conseguiu juntar dinheiro no tempo e fez a consulta no particular.

Isso para o SUS ele vai gastar 1 real de ligação e vai economizar 299 reais da consulta, além de reescalonar a fila, então esse é um trabalho bastante importante para a saúde. É nessa parceria que a gente está tentando melhorar o uso desses recursos, aqui às referências do trabalho e é isso.

Slides da apresentação

Título: Previsões de Ausência em Atendimento Especializado em Unidades de Saúde Pública de Florianópolis.

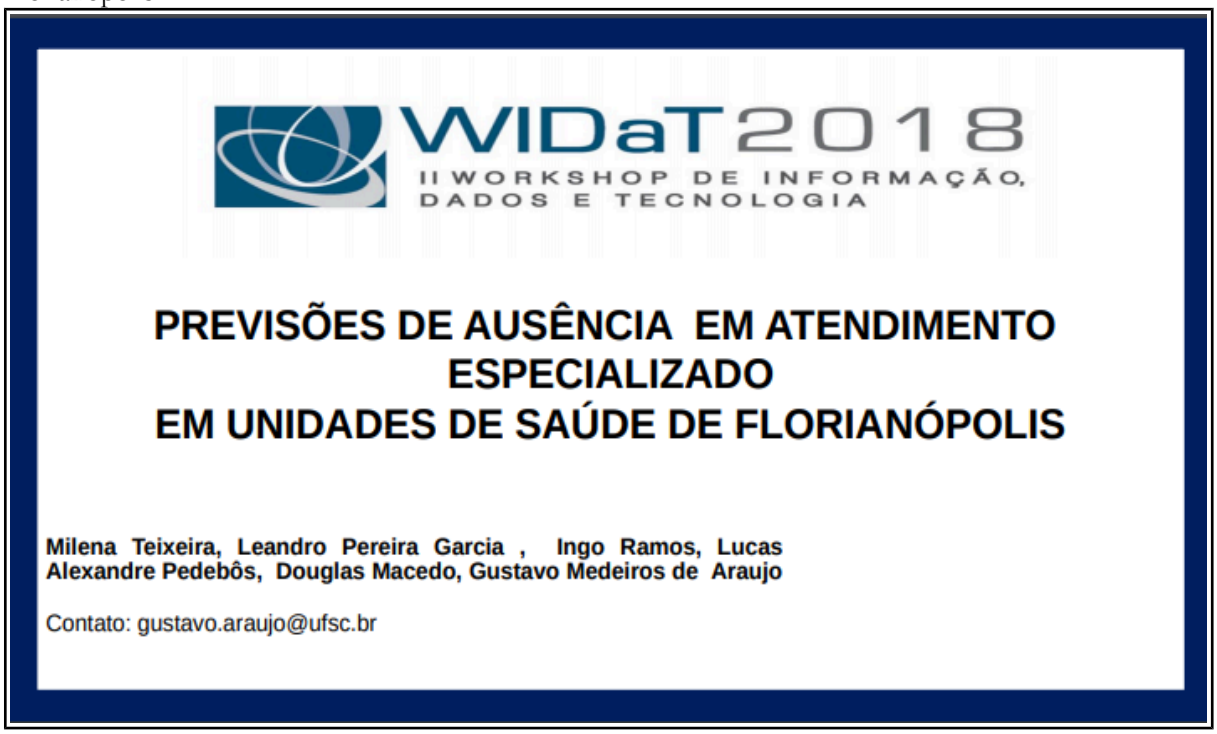

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=42

A construção do repositório de dados da UFPB: a experiência com o dataset de Arboviroses

Pollianna Marys de Souza e Silva[a] *e Sandra de Albuquerque Siebra*[b]

Resumo: Repositório de Dados (RD) são sistemas digitais de informação que armazenam dados provenientes de pesquisas científicas, a fim de colaborar com o seu acesso, uso, reúso e preservação. Nesse contexto, este artigo objetiva relatar a experiência de construção do RD da UFPB. Esta foi uma pesquisa-ação, qualitativa e descritiva. Como resultados iniciais se obteve a instalação da plataforma Dataverse e criação do RD da UFPB, no ano de 2018, tendo como conjunto de dados inicial um dataset construído a partir da extração de mais de um milhão de posts da rede social Twitter, de outubro de 2017 a março de 2018, sobre as arboviroses, que é um conjunto de patologias formado principalmente pela Zica, Dengue e Chikungunya. Com esse dataset espera-se disponibilizar dados brutos que possam servir para pesquisadores de várias áreas estudarem a disseminação das doenças, do que se fala sobre elas, mapear seus agravos e surtos, entre outros.

Palavras-chave: Repositório de Dados; Dataverse; Dataset Arboviroses; Curadoria de Dados; Ciência Aberta.

The construction of the data repository of the UFPB: the experience with the dataset of Arboviroses

Abstract: Data Repository (RD) are digital information systems that store data from scientific research in order to collaborate with its access, use, reuse and preservation. In this context, this article aims to report on the experience of building the UFPB's data repository. This was an action research, qualitative and descriptive. As initial results we obtained the installation of the Dataverse platform and creation of the RD of the UFPB, in the year of 2018, having as dataset a dataset constructed from the extraction of more than one million posts of the social network Twitter, of October of 2017 to March 2018, on arboviruses, which is a set of pathologies formed mainly by Zika, Dengue and Chikungunya. With this dataset, it is expected to provide raw data that can be used for researchers from various areas to study the spread of diseases, what is being said about them, map diseases and their outbreaks, among others.

Keyword: Data Repository; Dataverse; Arboviruses Dataset; Data Curation; Open Science.

a Universidade Federal da Paraíba (UFPB). E-mail: pollianna_marys@hotmail.com. ORCID: https://orcid.org/0000-0002-1134-6264. Currículo: http://lattes.cnpq.br/1404355220123084

b Universidade Federal de Pernambuco (UFPE). E-mail: sandra.siebra@gmail.com. ORCID: https://orcid.org/0000-0002-0078-6918. Currículo: http://lattes.cnpq.br/4923627544089379

1 Introdução

O movimento em favor do acesso aberto, conhecido como Open Access, surgiu a partir da crise dos periódicos e permitiu a democratização do acesso à informação, sendo os repositórios digitais uma das primeiras plataformas digitais de acesso aberto (SILVA JÚNIOR; BORGES, 2014).

Estes são ambientes digitais que possibilitam reunir dados e informações de cunho científico, administrativo, técnico, artístico, cultural, entre outros, cuja função principal é promover a visibilidade de seus objetos digitais, preservando-os por meio do gerenciamento de informação (ABREU; VIDOTTI, 2016). Eles podem ser de vários tipos (SILVA JÚNIOR; BORGES, 2014):

a) Temáticos – armazenam conteúdos de assuntos especializados;

b) Nacional – agrega a produção acadêmica e/ou científica de um país;

c) Institucional – foca na produção intelectual de uma instituição; e

d) De pesquisa ou de dados – armazenam dados de pesquisa, sendo esses últimos o foco da pesquisa que originou esse artigo.

De acordo com Sayão e Sales (2016), os repositórios de dados (RD) garantem os princípios de transparência e oferecem um sistema de armazenamento seguro, além da possibilidade de se ter os dados de pesquisa disponíveis on-line,indexados, documentados, para serem acessados, baixados, visualizados e processados por pessoas ou por sistemas, estendendo-os a uma comunidade mais ampla e conectada em rede. De fato, os RD têm sua importância como recurso informacional e se tornam um dispositivo de troca de experiências e compartilhamento de dados científicos[4], além de parte essencial das infraestruturas mundiais de pesquisa em escala global, tornando visível e aberta para toda a sociedade uma parcela importante da atividade de pesquisa, caracterizando a chamada Open Science ou Ciência Aberta[5] (FORMENTON, 2015).

Sayão e Sales (2016) consideram que os RD, de forma diferente das publicações acadêmicas que falam por si próprias, precisam ter explícitos os seus conteúdos, para poder revelar e transmitir conhecimento no tempo e no espaço, de forma que os dados possam ser interpretados, sintetizados e reanalisados em contextos diversos, com finalidades diferentes das quais foram gerados e coletados originalmente. Assim como é preciso garantir a gestão e preservação a longo prazo, o que faz com que seja necessário o desenvolvimento de metodologias (gerenciais e tecnológicas) que guiem desde a criação dos dados, passando por seu gerenciamento, armazenamento, análise, uso e reúso, em uma diversidade de contextos. O que vem sendo proporcionado pela curadoria de dados, que "engloba atividades de gestão requeridas para manter e gerir dados de pesquisa a longo prazo, de modo que estejam disponíveis para o reúso, favorecendo a colaboração entre pesquisadores e o avanço da ciência" (SIEBRA; BORBA; MIRANDA, 2016, p. 12-13).

Entre as plataformas disponíveis para criação de um RD encontra-se o Dataverse. Ele é um RD de código aberto para compartilhar, preservar, citar, explorar e analisar dados de pesquisa.

4 Dados científicos são os materiais comumente registrados e aceitos na comunidade científica como necessários para validar os resultados de pesquisa. Ex: fatos e estatísticas recolhidas para posterior referência ou análise, documentos, questionários, transcrições, algoritmos, scripts, etc. (DUDZIAK, 2016).

5 Movimento para tornar a pesquisa científica, os dados e a divulgação destes acessíveis a todos os níveis da sociedade (WIKIPÉDIA, 2018).

Pesquisadores, autores de dados, editores, distribuidores de dados e instituições afiliadas recebem o crédito apropriado por meio de uma citação de dados com um identificador persistente (por exemplo, DOI ou Handle) (RICE; SOUTHAL, 2016). Cada conjunto de dados contém metadados descritivos e arquivos de dados (incluindo documentação e código que acompanham os dados) (DATAVERSE PROJECT, 2018). Essa foi a plataforma utilizada nessa pesquisa.

2 Objetivos

Esse artigo teve por objetivo relatar a experiência de criação do 1º RD da UFPB, fazendo uso da plataforma Dataverse, com foco no dataset de arboviroses. Esse RD surgiu após a realização do projeto de pesquisa – Chamada Universal – MCTI/CNPq (Número 01/2016) – intitulado "A Ciência da Informação e a Disseminação de Informações Associadas à Epidemia de Zika Vírus: uma investigação baseada na Análise de Redes Sociais". E a motivação para o dataset surgiu após o Brasil vivenciar, em 2016, um surto de microcefalia em bebês recém-nascidos, causada pela contaminação de mulheres grávidas com o vírus zica. Sendo que para a criação decidiu-se expandir para um conjunto de patologias formado principalmente pela Zica, Dengue e Chikungunya, denominadas arboviroses. Isso porque essas são doenças com graves repercussões para a saúde da população conforme indicadores operacionais e epidemiológicos.

3 Procedimentos Metodológicos

A pesquisa que originou esse artigo trata-se de uma pesquisa-ação, qualitativa e descritiva (MICHEL, 2009). Na pesquisa-ação os pesquisadores-participantes estão envolvidos de modo cooperativo e participativo na pesquisa, que é concebida e realizada em estreita associação com uma ação ou resolução de um problema coletivo (BALDISSERA, 2001). Na pesquisa qualitativa, segundo Michel (2009), existe a ligação e correlação de dados interpessoais, coparticipação das situações dos informantes e estes são analisados a partir da significação que eles dão aos seus atos. E é descritiva na medida que colhe, interpreta e discute fatos e situações. Além disso, essa é uma pesquisa bibliográfica que fez uso de artigos, livros, teses e dissertações, assim como documental pois fez-se necessário estudar o site e o manual da plataforma Dataverse.

O dataset foco desse relato é um conjunto de dados composto por posts da rede social Twitter sobre as arboviroses, que engloba a Zica, Dengue e Chikungunya. Assim, a colega de dados para compor o dataset foi realizada no período de outubro de 2017 a março de 2018. Os dados foram coletados por um script feito na linguagem de programação Ruby, fazendo uso de API (Application Programming Interface) disponibilizada pelo próprio Twitter. Os posts coletados foram os que apresentaram uma ou mais das seguintes palavras, desconsiderando maiúsculas e minúsculas: zica, zika, zyca, zkv, zikav, dengue, dengue hemorrágica, chikungunya, chicungunya, arbovirose, arboviroses, microcefalia.

Os posts identificados, mais de um milhão, foram baixados no formato JasonB e categorizados considerando 3 grupos: Zica, Dengue e Chicungunya. Em seguida, foi criado um banco de dados modelado para as normas do Dataverse, onde os dados extraídos foram efetivamente armazenados. Ressalta-se que, para poder contextualizar e adicionar valor aos dados, foi criado um conjunto de metadados descritivos para sintetizar os diferentes contextos em que as mensagens foram utilizadas e compreender como os usuários da rede social

discutiram/escreveram sobre a temática. O Dataverse foi escolhido como plataforma por ser uma das mais popularmente utilizadas para criação de RDs.

Para realização do trabalho, a equipe foi composta por 6 pessoas: 1 coordenador e 5 bolsistas das áreas de Ciência da Informação e Ciência da Computação.

4 Resultados

O RD da UFPB foi disponibilizado em 2018, no endereço https://dataverse.ufpb.br/dataverse/root. A equipe inicial de pesquisadores em uma primeira etapa precisou se familiarizar com o que é e como funciona um repositório de dados, o que foi sanado com a pesquisa bibliográfica. Posteriormente, sobre a plataforma Dataverse. Como toda documentação da plataforma estava em inglês, a equipe se dedicou a traduzir e destacar as principais partes da documentação, antes de começar a implantação da plataforma na instituição. Uma vez a plataforma instalada, ela foi populada com o dataset de arboviroses extraído do Twitter.

Para Gomes (2013, p. 29): "[…] a otimização e atualização de dispositivos e ações de informação têm de responder às demandas intensivas de informação e comunicação que satisfaçam, em quantidade e qualidade, às metas e finalidades da promoção da saúde e do atendimento clínico". O que ressalta as possibilidades de colaboração entre a Ciência da Informação e a área de Saúde. O que pode ser concretizado por exemplo, com a exploração, coleta e organização de bases de dados que possam colaborar com pesquisas na área de saúde, como é o caso do dataset de arboviroses.

Para um melhor gerenciamento de acesso e segurança, buscou-se restringir o acesso aos dados a pesquisadores previamente cadastrados, cujas credenciais de acesso podem ser feitas a partir do cadastro individual do pesquisador no Dataverse, utilizando uma conta do Gmail. Assim, optou-se por permitir acessar o arquivo restrito do dataset apenas após login e senha com as credenciais de acesso adequadas ao sistema e, durante download do arquivo do dataset, o sistema deve solicitar a aceitação de um termo de acesso e uso. O objetivo é manter um controle de acesso aos dados disponibilizados. Adicionalmente, para aqueles que navegarem nos datasets sem baixar nenhum arquivo há a solicitação de registro no Guestbooks (livro de visitas) de cada dataset. Ressalta-se que o acesso aos dados no RD Dataverse ocorre de quatro formas: aberto, fechado, gerenciado e moderado, o que pode trazer flexibilidade para os casos de dados de pesquisa que necessitem ficarem em sigilo por algum motivo (pesquisa em andamento, patenteamento de solução, etc). O repositório criado a partir da plataforma Dataverse possui a identificação especificada no Quadro 1.

Quadro 1 – Identificação do Dataverse UFPB.

Dataverse	**Departamento de CI**
Identifier	https://dataverse.ufpb.br/datavers e/dci
Category	Department
Affiliation	CCSA – UFPB
Description	Este repositório concentra dados de pesquisas do Departamento de Ciências da Informação (DCI) do Centro de Ciências Sociais Aplicadas (CCSA) da Universidade Federal da Paraíba (UFPB).

Fonte: Autores.

O campo "Dataverse" descreve o título do banco de dados, o departamento, a universidade ou a revista que conterá os dados. O "Identifier" refere-se a um nome curto a ser utilizado como URL (Uniform Resource Locator – Localizador Padrão de Recursos que é um formato de atribuição universal para designar um recurso na Internet). A "category" identifica o tipo de grupo ao qual a base de dados pertence, no caso, departamento. O campo "Affiliation" deve compor algum nome ou sigla associado à instituição proprietária do repositório, no caso CCSA (Centro de Ciências Sociais Aplicadas) da Universidade Federal da Paraíba (UFPB) e, por fim, "Description" que deve ser a descrição resumida da base de dados, especificando o que é armazenado nela, para exibição na página do repositório.

No Dataverse, os campos de metadados são escolhidos para uso em cada conjunto de dados (dataset) a serem adicionados (THE DATAVERSE PROJECT, 2018).

Considerando a natureza multidisciplinar das pesquisas do Departamento de CI, os pesquisadores optaram pelo uso de campos de metadados gerais, em um padrão que pudesse ser aplicado em dados das diversas áreas do conhecimento. Assim, os principais campos a serem preenchidos no Dataverse para o dataset são: título, autor(es), informações para contato, descrição resumida da pesquisa, data da coleta dos dados no RD, tópicos da pesquisa, palavras-chave, entre outros. Esses metadados tanto contextualizam e descrevem os dados armazenados, como facilitam a sua recuperação.

A preservação e acesso a longo prazo são garantidos no Dataverse pela identificação persistente, que protege os documentos digitais com mecanismos que preveem a obsolescência dos dados – migração dos dados para um software mais recente e a prescrição que consiste em guardar o conjunto de bytes para serem consultados quando for necessário. (DATAVERSE PROJECT, 2018).

5 Conclusão ou Considerações Finais

Nesse cenário, as arboviroses são enfermidades tropicais endêmicas, que merecem receber atenção especial dos profissionais de saúde que atuam na atenção básica e na vigilância em saúde e dos gestores das esferas federal, estadual e municipal (FIOCRUZ, 2017). Elas incapacitam ou matam milhões de pessoas e representam uma necessidade médica importante que permanece não atendida. Assim, o estudo sobre a disseminação de informações sobre essas enfermidades, tanto nos círculos acadêmicos e científicos formais, como nos informais, na mídia de massa através das redes sociais, apresenta inúmeras oportunidades de investigação para pesquisadores. É nesta vertente que a proposta do Dataset arboviroses da UFPB está direcionada, contribuindo com dados brutos para o campo científico e para a sociedade diante da urgência da temática. Podendo-se investigar: o que a população sabe sobre as arboviroses? Que tipo de dúvidas possuem? Como a informação tem chegado até a sociedade? Que tipo de queixas são realizadas sobre as doenças em questão? Que localidades mais discutem sobre arboviroses? Além de ser possível mapear casos de relatos de morte, surtos e agravamento das doenças por meio dos posts coletados.

Ressalta-se que essa pesquisa ainda está no início, porém, a implantação e configuração do dataverse e a coleta dos dados do twitter com a criação do dataset de arboviroses já se mostram como primeiros resultados, que podem trazer diversos desdobramentos no futuro.

Espera-se, como trabalhos futuros, poder relatar os usos feitos do dataset de arboviroses tanto pelos administradores do Dataverse, como por pesquisadores cadastrados na plataforma.

Referências

ABREU, J. P.; VIDOTTI, S. A. B. G. Curadoria Digital nos Contexto dos Repositórios Digitais. In: Encontro Internacional de Dados, Tecnologia e Informação, 2., 2016. Marília. **Anais…** Marília: UNESP, 2016.

FIOCRUZ. **Agência Fiocruz de Notícias**. Disponível em: <https://agencia.fiocruz.br/doen%C3%A7as-negligenciadas>. Acesso em: 08 jun. 2018.

BALDISSERA, A. Pesquisa-Ação: uma metodologia do conhecer e do "agir" coletivo. **Sociedade em Debate**, Pelotas, v. 7, n. 2, p. 5-25, agosto, 2001. Disponível em: <http://revistas.ucpel.edu.br/index.php/rsd/article/viewFile/570/510>. Acesso em: 02 ago. 2018.

DATAVERSE PROJECT. **About Dataverse**. Disponível em: <https://dataverse.org/>.Acesso em: 08 jun. 2018.

FORMENTON, D. **Identificação de Padrões de Metadados para Preservação Digital**. São Carlos: UFSCar, 2015. 102 f. Dissertação de Mestrado – Universidade Federal de São Carlos. Disponível em: <https://repositorio.ufscar.br/bitstream/handle/ufscar/7221/DissDF.pdf?sequence=1 . Acesso em: 02 jun. 2018.

GOMEZ, M. N. G. O Domínio das Informações em Saúde. In: PINTO, V. B.; CAMPOS, H. H. (Org). **Diálogos Paradigmáticos Sobre Informação para a Área da Saúde.** Fortaleza: Edições UFC, 2013.

MICHEL, M. H. **Metodologia e Pesquisa Científica em Ciências Sociais**. 2 ed. São Paulo: Atlas, 2009.

RICE, R; SOUTHALL, J. **The Data Librarian's Handbook.** London: Facet, 2016. 169p.

SAYÃO, L. F.; SALES, L. F. Algumas Considerações Sobre os Repositórios de Dados de Pesquisa. **Informação & Informação**, Londrina, v. 21, n. 2, p. 90 – 115, maio/agosto, 2016. Disponível em: <http:www.uel.br/revistas/informacao/90>. Acesso em: 12 jul. 2018.

SIEBRA, S. A.; BORBA, V. R.; MIRANDA, M. J. K. F. O. Curadoria digital: um termo interdisciplinar. In: XVII Encontro Nacional de Pesquisa Em Ciência da Informação (ENANCIB), 17., 2016, Salvador. **Anais…** Salvador, BA: UFBA, 2016. Disponível em: <http://www.ufpb.br/evento/lti/ocs/index.php/enancib2016/enancib2016/paper/view/4107/2559>. Acesso em: 2 jul. 2018.

SILVA JUNIOR, L. P.; BORGES, M. M. Preservação digital no Repositório Científico de Acesso Aberto de Portugal. **Rev Eletrônica de Comun. Inf. Inov. Saúde**, v. 8, n. 4, p. 567-574, out./dez. 2014. Disponível em:<http://www.reciis.icict.fiocruz.br/index.php/reciis/article/view/911>. Acesso em: 04 ago. 2018.

WIKIPÉDIA. **Open Science.** Disponível em: <https://en.wikipedia.org/wiki/Open_science>. Acesso em: 12 ago. 2018.

Vídeo da apresentação

Título: A construção do repositório de dados da UFPB: A experiência com o dataset de Arboviroses.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=43

Transcrição da apresentação

Boa a tarde a todos, eu me chamo Adriana, estou matriculada no Programa de Pós-Graduação em Ciência da Informação, esse trabalho foi feito com a coautoria da professora Sandra Siebra da Universidade Federal de Pernambuco, o título é a "A construção do repositório de dados da UFPB: A experiência com o dataset de Arboviroses".

Apesar de que estamos a três dias quase discutindo o acesso aberto inserido nesse contexto, os repositórios institucionais de pesquisa ainda carece de alguns conceitos e definições de autores da área.

O movimento em favor do acesso aberto surgiu a partir da crise dos periódicos e permitiu a democratização do acesso à informação, sendo repositórios digitais uma das primeiras plataformas digitais de acesso aberto.

Esses repositórios estão em ambientes digitais que possibilitam reunir dados e informações de cunho científico, administrativo, técnico, artístico, cultural, entre outros, cuja função principal é promover a visibilidade de seus objetos digitais, preservando-os por meio do gerenciamento de informação como discutida inicialmente.

Os repositórios de dados garantem os princípios de transparência e oferecem um sistema de armazenamento seguro prevendo o ciclo de vida dos dados, além da possibilidade de se ter os dados de pesquisa disponíveis on-line, indexados, documentados, para serem acessados, baixados, e inseridos como contribuição em outras pesquisas.

O objetivo desse trabalho é relatar a experiência de criação do primeiro repositório de dados da UFPB, fazendo uso da plataforma Dataverse, com foco no Dataset de Arboviroses.

Esse repositório de dados surgiu após a realização do projeto de pesquisa da Chama Universal do MCTI/CNPq, número 1 de 2016, intitulado "A Ciência da Informação e a disseminação de informações associadas à epidemia de Zika Vírus: uma investigação baseada na Análise de Redes Sociais".

Então a motivação para o projeto de pesquisa surgiu após o Brasil vivenciar em 2016 um surto de microcefalia de mães que foram acometidas pela Arbovirose Zika. Porém eu decidi criar o Dataset, a metodologia foi ampliada para Zika e Chikungunya que podem ser chamadas de Arboviroses ou Arbovirus. Isso porque são doenças com graves repercussões para saúde da população e de casos operacionais e epidemiológicos do Ministério da Saúde.

Eu trago essa linha do tempo só para justificar o porquê da gente sair de uma pesquisa que abrangia apenas a Zika e hoje abrange três arboviroses. Inicialmente em 1981 houve o primeiro caso de Dengue confirmado, com diagnóstico laboratorial onde a doença se devia à Região Norte, em 1986 houve uma expansão da doença e o Rio de Janeiro e as faculdades do Nordeste foram atingidas pela Dengue, e o Ministério da Saúde em 2017 com os dados deste ano está prevendo que em 2018 todos os estados brasileiros serão atingidos pelas três doenças.

Os procedimentos metodológicos. A pesquisa que originou este artigo trata-se de uma pesquisa-ação, qualitativa e descritiva, por isso os resultados vão ser bem descritivos, ela é descritiva.

O dataset foco desse relato é um conjunto de dados composto por post da Rede Social Twitter sobre as Arboviroses, que engloba a Zyca, Dengue e Chikungunya. A coleta de dados

para compor o dataset foi realizada no período de outubro de 2017 a março de 2018. Os dados foram coletados por um script feito na linguagem de programação Ruby, fazendo uso do API que é disponibilizado pelo próprio Twitter. Os posts coletados foram os que apresentavam uma ou mais das seguintes palavras, tudo em minúscula: zica, zika, zyca, zkv, zikav, dengue, dengue hemorrágica, chikungunya, chicungunya, arbovirose, arbovirose ou microcefalia.

Os posts identificados que foram mais de 1 milhão, foram baixados no formato JasonB e categorizados considerando 3 grupos: Zyka, Dengue e Chikungunya. Por que esses descritores? Através de uma pesquisa informal realizada no Google Acadêmico percebemos que esses descritores continham a maiores referências nessa base de dados.

Em seguida foi criado um banco de dados modelado para as normas do Dataverse onde os dados extraídos foram armazenados. Ressalta-se que, para poder contextualizar e adicionar valor os dados, foi criado um conjunto de metadados descritivos para sintetizar os diferentes contextos em que as mensagens foram utilizadas durante os posts, nas discussões e conversas no Twitter. O Dataverse foi escolhido como plataforma por ser uma das mais popularmente utilizadas para a criação de Repositório de Dados de pesquisa.

Como resultados, o repositório de dados da UFPB foi disponibilizado em 2018, no endereço "dataverse.ufpb.br/dataverse/root. A equipe inicial de pesquisadores em uma primeira etapa precisou se familiarizar como o que é e como funciona repositório de dados, e o que foi sanado com a pesquisa bibliográfica. Posteriormente, sobre a plataforma Dataverse.

Como toda a documentação estava em Inglês, os pesquisadores tiveram o trabalho de traduzir para o português para que houvesse melhor compreensão. Uma vez a plataforma instalada, ela foi populada com o dataset de arboviroses extraído do Twitter.

Para um melhor gerenciamento de acesso e segurança, buscou-se restringir o acesso aos dados a pesquisadores que tivessem feito seu cadastro na plataforma e que possuísse login e senha cadastrados pela plataforma do Gmail. Assim, optou-se por permitir acessar o arquivo restrito após o login e senha, e o credenciamento, durante o download do arquivo do dataset, o sistema deve solicitar a aceitação de um termo de acesso e uso.

O repositório está assim descrito atualmente. No campo dataverse que corresponde ao departamento da revista ou instituição que é proprietária dos dados, no caso em questão o Departamento de CI. No campo de identificação deve conter o parâmetro universal de recursos. No campo categoria deve estar relacionado o levantamento que trabalha com o banco de dados. No campo de afiliação deve ter o nome ou sigla da instituição ou empresa possuidora dos dados, no caso CSA/UFPA. E no caso do campo descrição, um resumo descritivo do que é essa base de dados.

No Dataverse, os campos de metadados são escolhidos para uso em cada conjunto de dados a serem adicionados, então cada dataset possui um conjunto de dados. Considerando a natureza multidisciplinar das pesquisas do Departamento de CI, os pesquisadores optaram pelo uso de campos de metadados gerais, em um padrão que pudesse ser aplicado em dados de diversas áreas do conhecimento. Assim, os principais campos a serem preenchidos no Dataverse são: título, autor, palavras-chave, tópicos da pesquisa, tempo e data da coleta dos dados, e descrição resumida da pesquisa.

A preservação e acesso a longo prazo são garantidos no Dataverse pela identificação persistente, que protege documentos digitais. Os mecanismos que preveem a obsolescência dos dados em relação a migração dos dados para um software mais atualizado e o conjunto de dados pode ser consultado quando for acessado.

Após a descrição dos resultados, as autoras chegaram às seguintes considerações. As arboviroses são enfermidades tropicais endêmicas, que merecem receber atenção em especial os que trabalham na atenção básica e na vigilância epidemiológica, em nível de gestores das esferas federal, estadual e municipal. Essas três doenças em especial, elas incapacitam e matam milhões de brasileiros, então um estudo sobre a disseminação de informações sobre estas enfermidades tanto nos círculos acadêmicos e científicos formais, como nos informais como as Redes Sociais, apresenta inúmeras oportunidades de investigação para os pesquisadores. E nesta vertente é que surge a proposta do Dataset de Arboviroses, contribuindo com dados brutos para o campo científico e para sociedade diante da urgência da temática.

Pode-se investigar, com essa base de dados, o que a população sabe sobre as arboviroses? Que tipo de dúvidas as pessoas possuem? Como a informação tem chegado até a sociedade? Que tipo de queixas são realizadas sobre as doenças em questão? Que localidade mais discutem sobre arboviroses? Além de se poder mapear casos de surtos, mortes e agravantes das doenças por meio dos posts coletados.

Espera-se como trabalhos futuros que os pesquisadores que construíram o dataset possam desenvolver trabalhos usando o banco de dados, e outros pesquisadores que estejam cadastrados na plataforma também contribuam com a pesquisa. Essas foram algumas referências utilizadas, obrigado.

Slides da apresentação

Título: A construção do repositório de dados da UFPB: A experiência com o dataset de Arboviroses.

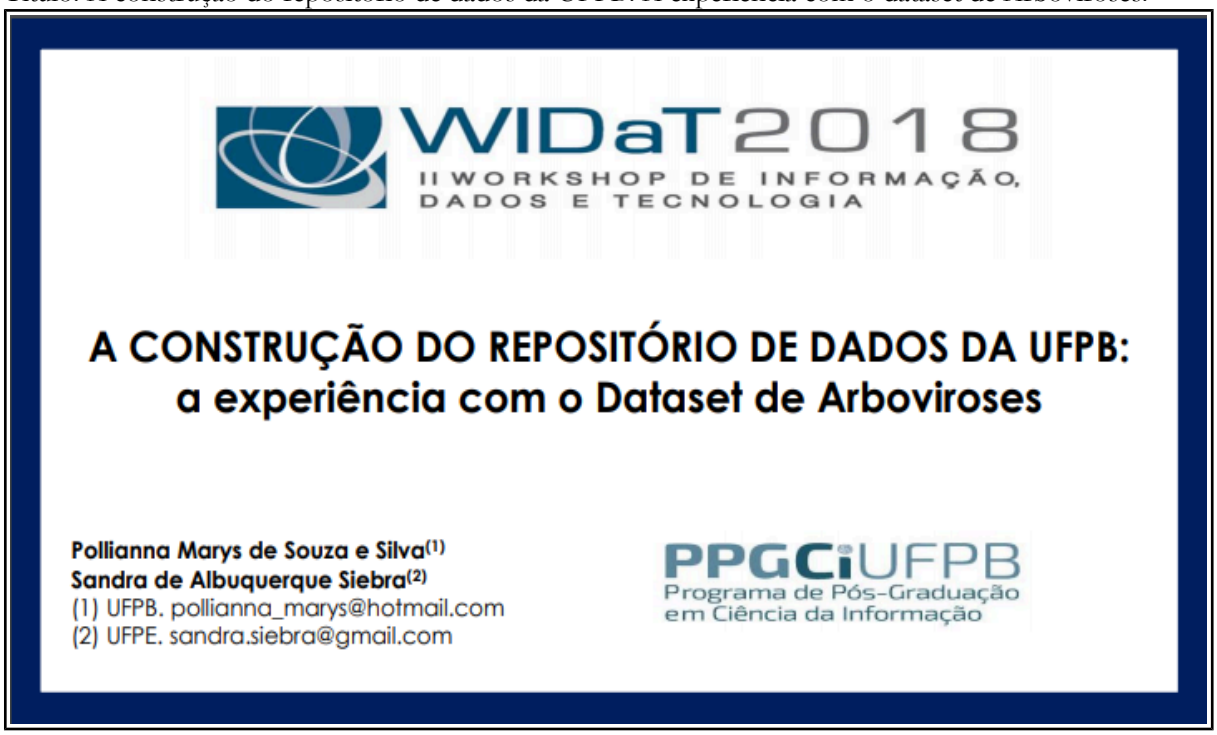

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=43

Pornografia infantil: análise de manuais de pedofilia

Marcelo da Silva Moreira[a] *e Enrique Muriel-Torrado*[b]

Resumo: A transformação da sociedade, associada ao desenvolvimento tecnológico e da comunicação, provocou grandes mudanças nas inter-relações sociais. Novos paradigmas, como a Sociedade da Informação, surgiram com a universalização do acesso à informação e da propagação crescente do fluxo de dados, contudo a criminalidade não está alheia ao fenômeno das transformações da sociedade. O surgimento da Internet facilitou que criminosos pudessem propagar práticas ilícitas mais facilmente. Crimes relacionados à violência sexual de crianças e adolescentes ganharam um potencial lesivo muito maior com o advento da rede mundial de computadores, pois pedófilos passaram a compartilhar na Deep Web manuais e guias para ensinar práticas e técnicas de violência sexual infantil. Nesse contexto, a presente pesquisa tenta produzir um conjunto de diretrizes e princípios de prevenção do crime de Pornografia Infantil, através da análise de manuais de pedofilia disponibilizados na Deep Web. Esta pesquisa caracteriza-se como exploratória e qualitativa, sendo explorada através da análise e categorização de manuais de pedofilia; das percepções de policiais no enfrentamento ao problema; e, das percepções de profissionais da área psicossocial no acolhimento das vítimas. Dessa forma, busca-se fornecer um rol de diretrizes de prevenção que possam subsidiar ações de Estado na promoção de políticas públicas de combate à Pornografia Infantil.

Palavras-chave: Pornografia Infantil; Sociedade da Informação; Prevenção.

Child Pornography: Pedophilia Manuals Analysis

Abstract: The transformation of society, associated with technological development and communication, has brought about great changes in social interrelationships. New paradigms, such as the Information Society, have emerged with the universalization of access to information and the growing spread of data flow, yet crime is not alien to the phenomenon of the transformations of society. The emergence of the Internet has made it easier for criminals to propagate illicit practices more easily. Crimes related to sexual violence against children and adolescents have gained much greater potential with the advent of the global computer network, as pedophiles began sharing Deep Web manuals and guides to teach practices and techniques of child sexual violence. In this context, the present research tries to produce a set of guidelines and principles of prevention of the crime of Child Pornography, through the analysis of pedophilia manuals available in the Deep Web. This research is characterized as exploratory and qualitative, being explored through the analysis and categorization of pedophilia manuals; perceptions of cops in coping with the problem; and of the perceptions of psychosocial professionals in the reception of the victims. In this way, we seek to provide a set of prevention guidelines that can support State actions in the promotion of public policies to combat Child Pornography.

Keyword: Child Pornography; Information Society; Prevention.

a Universidade Federal de Santa Catarina (UFSC). E-mail: marcelomoreira3000@gmail.com. Currículo: http://lattes.cnpq.br/9638745749402660

b Universidade Federal de Santa Catarina (UFSC). E-mail: enrique.muriel@ufsc.br. ORCID: https://orcid.org/0000-0003-0969-9500. Currículo: http://lattes.cnpq.br/6493679032893430

1 Introdução

O paradigma da Sociedade da Informação ou Sociedade em Rede demonstra que as atuais transformações sociais são permeadas pelo uso da Tecnologia da Informação e Comunicação – TIC. O advento da Internet afetou as relações sociais, as técnicas de produção, a cultura e o próprio conceito de poder, promovendo transformações nas experiências humanas e na própria estrutura social. Todavia, o uso a rede mundial de computadores também possibilitou a propagação de ações criminosas.

Especialmente, os crimes que envolvem violência sexual contra menores de idade passaram a ter um potencial lesivo ainda maior como o uso crescente do "ambiente virtual". O grande desafio da sociedade em geral, por meio dos órgãos de segurança pública e de entidades de apoio, é buscar medidas efetivas de proteção de suas crianças e adolescentes a fim de combater tais crimes, os quais causam consequências nefastas às vítimas desses abusos.

1.1 Referencial teórico

Dados da Pesquisa Nacional por Amostra de Domicílios Contínua – PNAD Contínua, realizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE), no quarto trimestre de 2016, revelaram que: i) 69,3% dos brasileiros têm acesso à rede mundial de computadores; em 97,2% dos domicílios em que havia acesso à Internet, (ii) o equipamento mais usado era o telefone celular; e, iii) 94,2% das pessoas de 10 anos ou mais de idade, usam a Internet com a finalidade de enviar ou receber mensagens de texto, voz ou imagens por aplicativos diferentes de e-mail. (BRASIL, 2016).

Outra informação relevante, apurada na PNAD – Contínua, é o percentual de menores de idade que tem acesso à Internet. No grupo de 10 a 13 anos de idade, as meninas apresentam percentual 67,5%, superior aos meninos (65,2%); e, no grupo de 14 a 17 anos de idade, o percentual das meninas sobe para 85,1% e os meninos para 80,1%. Conforme mostrado no gráfico 1.

De fato, com a evolução da sociedade e o desenvolvimento das tecnologias e das comunicações, a rede mundial de computadores passou a ser recorrida como meio de sociabilidade e de entretenimento, entre crianças e jovens que buscam as redes sociais para passar o tempo e fazer amizades (FERREIRA; SOBRINHO, 2012).

Por outro lado, criminosos usam a Internet com o objetivo de realizar tentativas de aliciamento de possíveis vítimas (crianças e adolescentes) de violência sexual, justamente pelas facilidades tecnológicas oferecidas (CAPPELLARI, 2018) e pela dificuldade de serem identificados.

Em 2018, apenas no período de janeiro a junho, o Ministério dos Direitos Humanos da Presidência da República, por meio do Disk 100, recebeu 9.297 denúncias de violações sexuais contra menores de idade.

Nesse levantamento, a violência sexual é a quarta violação mais denunciada, atrás apenas da negligência (26.242 casos), da violência psicológica (17.031 casos) e da violência física (14.355) (BRASIL, 2018).

O gráfico 2 retrata esta realidade.

Gráfico 1: Percentual de pessoas que utilizam a Internet – Brasil – 4º trimestre de 2016.

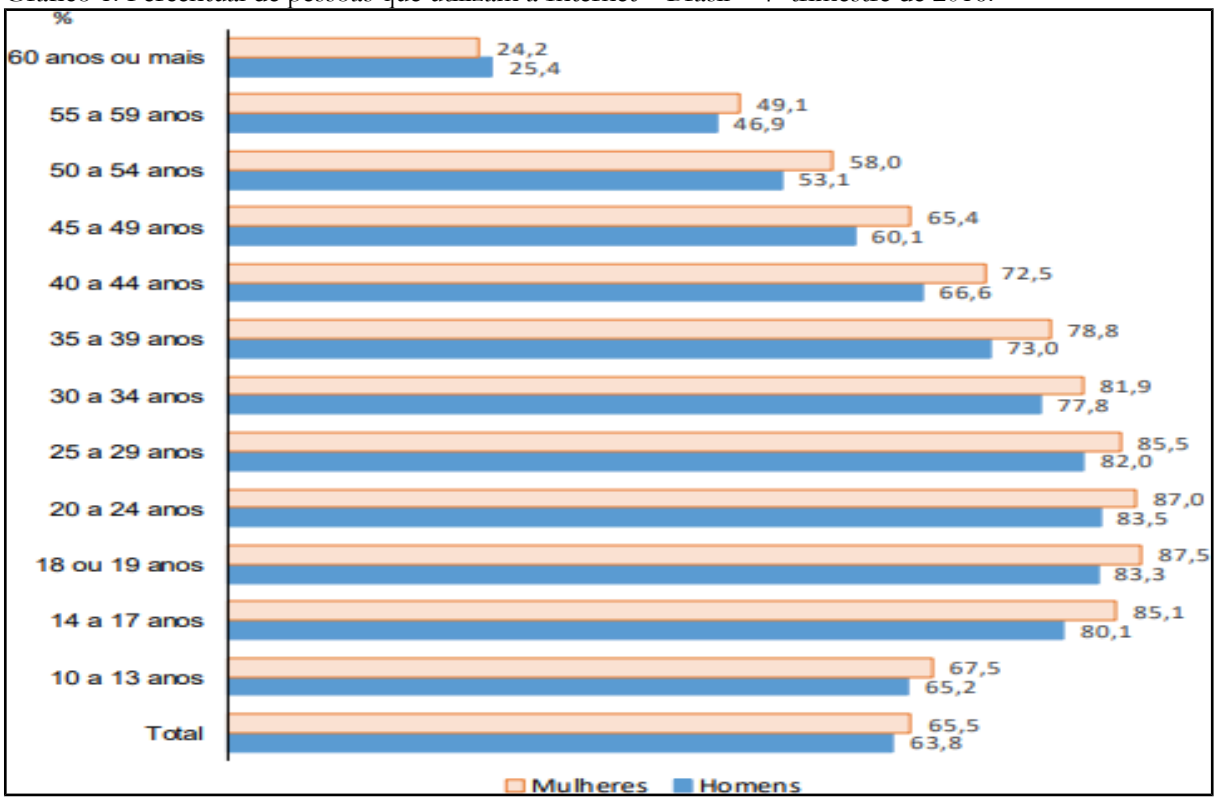

Fonte: IBGE, Diretoria de Pesquisas, Coordenação de Trabalho e Rendimento, Pesquisa Nacional por Amostra de Domicílios Contínua 2016.

Gráfico 2: Principais Violações Sexuais contra menores de idade (janeiro a junho de 2018).

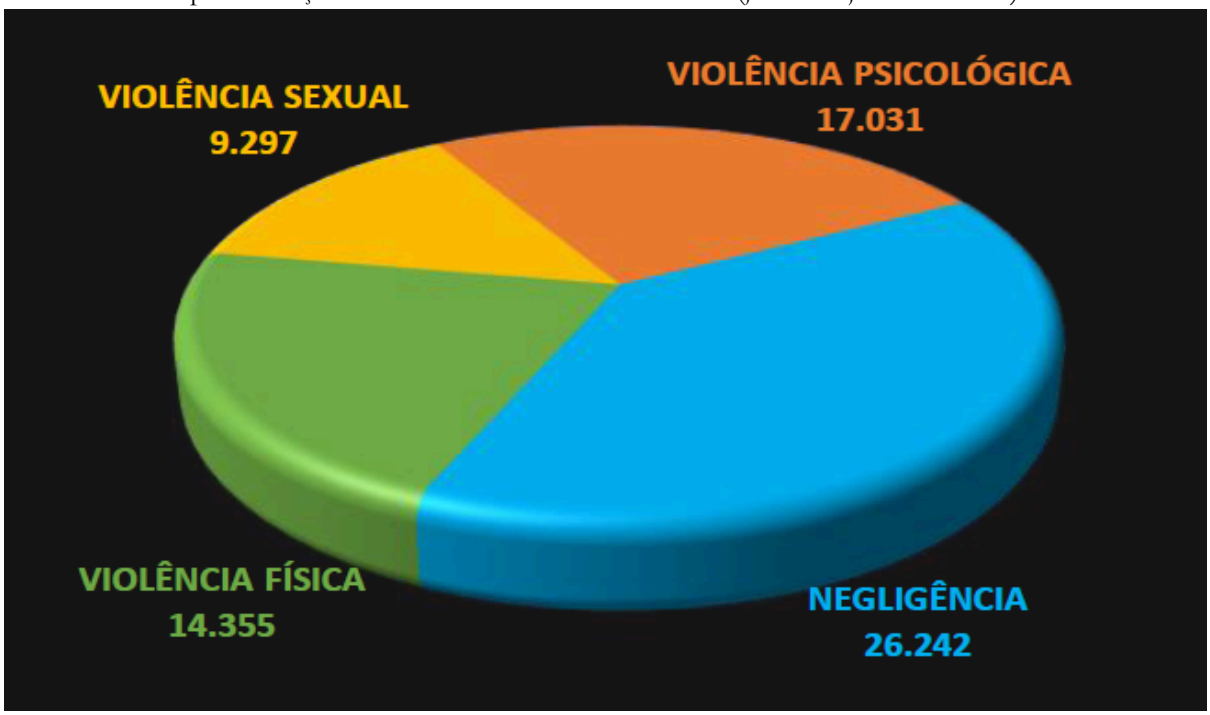

Fonte: Elaborado pelo autor (Dados Disk 100, 2018).

Dessas denúncias de violações sexuais contra crianças e adolescentes:

- 68% estão relacionadas a situações de abuso sexual;
- 15% a exploração sexual; e,
- 14% a pornografia infantil.

Para aprofundar neste grave problema, o Atlas de Violência 2018, produzido pelo Instituto de Pesquisa Econômica Aplicada (Ipea) e pelo Fórum Brasileiro de Segurança Pública (FBSP) revelou que, no ano de 2016, as polícias brasileiras registraram 49.497 casos de estupro e o Sistema Único de Saúde (SUS) notificou 22.918 incidentes desta mesma natureza; sendo que, em quase 68% do total de casos de estupro ocorridos no Brasil, as vítimas eram crianças ou adolescentes; revelando ainda que 63,8% dos casos de estupros coletivos envolviam menores de idade. No gráfico 3, o destaque fica nos casos da participação de crianças e adolescentes nos casos de estupros coletivos.

Gráfico 3: Brasil: distribuição percentual das vítimas de estupro no total de casos e nos estupros coletivos, 2016.

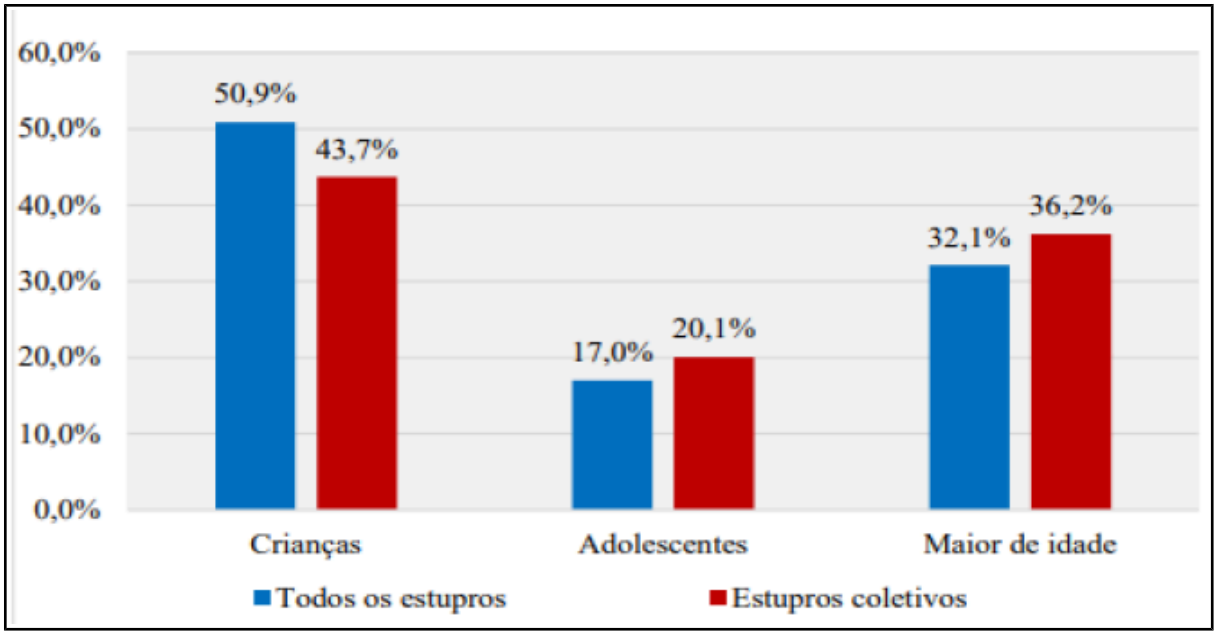

Fonte: Microdados do Sinan/Dasis/SVS/Ministério da Saúde. Elaborado Diest/Ipea e FBSP, 2016.

As formas violência sexual infantojuvenil envolvem um cenário complexo de segurança pública, associado aos graves danos físicos e psicológicos acometidos às vítimas, à relação de proximidade dos agressores, e ao local dos fatos que, devido aos avanços tecnológicos, teve, ainda, seu espaço expandido para o ciberespaço (CASTELLS, 1999) por meio da Internet. "[…] diante das novas possibilidades de inter-relação propiciadas pela Internet, poucas vezes a pedofilia esteve tão visível e, ao mesmo tempo, tão difícil de ser controlada" (CAPPELLARI, 2018, p. 1).

Nesse contexto de expansão da criminalidade, pedófilos, na rede mundial de computadores, passaram a disponibilizar on-line fotos e vídeos contendo cenas de sexo infatojuvenil, tanto com o intuito de perpetrar sua satisfação pessoal, bem como para utilizar como "moeda de troca" na aquisição de novos vídeos e imagens em comunidades de pedofilia. Por estes motivos, a Internet

se tornou o meio mais usado para a distribuição e compartilhamento deste material ilícito (CAPPELLARI, 2018), através de redes sociais, de redes peer-to-peer (P2P), de grupos de Whatsapp e da rede profunda, conhecida como Deep Web.

Cabe ressaltar que pedófilos têm compartilhado na Deep Web manuais de pedofilia a fim de divulgar práticas e técnicas de abuso sexual de menores de idade. Tais guias têm como objetivo ensinar:

- Sobre a sexualidade infantil;
- Sobre os riscos envolvidos;
- Quando começar, idade ideal;
- Onde encontrar uma criança, filhos próprios, família, mães com filhos, creches, escolas, na rua;
- Como escolher bem das possíveis vítimas;
- Como abordar ou se aproximar de crianças ou adolescentes;
- Como conquistar a mãe para ter acesso à vítima, menor de idade;
- Como conquistar a confiança da vítima;
- Como concretizar o abuso sem deixar marcas;
- Como fazer a criança te dar prazer; e,
- Como se prevenir da ação policial.

Na "Era da Informação", referida por Burke (2003), a informação tem valor para a sociedade e promove o seu desenvolvimento. Entretanto, a divulgação de manuais para ensinar a praticar o mal vai de encontro ao conceito de Sociedade da Informação (CASTELLS, 1999) e se contrapõe a todos os valores sociais.

O presente estudo busca, através da análise de manuais de pedofilia, de entrevistas com policiais que atuam no enfrentamento do problema e de entrevistas de profissionais da área psicossocial que atual no acolhimento e tratamento das vítimas, propor uma estrutura de diretrizes e princípios de prevenção que ajudem a sociedade no combate à pornografia infantil, servindo de matéria-prima para a elaboração de campanhas publicitárias, palestras educacionais e ações de conscientização.

A questão central a ser respondida é: Como podemos combater e previr a pornografia infantil no contexto da Sociedade de Informação? Com o intuito de responder esta indagação, os seguintes objetivos específicos foram elaborados:

a) Analisar as relações da Sociedade da Informação com o contexto do crime de pornografia infantil;
b) Identificar e caracterizar os manuais e guias de pedofilia disponibilizados na Deep Web;
c) c) Coletar as percepções de policiais que trabalham no combate aos crimes de violência sexual infantojuvenil;
d) Verificar e analisar as percepções de profissionais da área de assistência psicossocial que atuam no acolhimento e tratamento de menores vítimas de abusos sexuais, e;
e) Identificar os fluxos institucionais dos órgãos públicos que atuam na área de segurança pública e de assistência psicossocial.

2 Objetivos

Objetivo Geral: Produzir um conjunto de diretrizes e princípios de prevenção do crime de Pornografia Infantil através da análise de guias e manuais de pedofilia disponibilizados na Deep Web.

2.1 Objetivos Específicos

A tabela 1 lista os objetivos específicos do presente estudo:

Tabela 1: Objetivos Específicos.

Objetivos Específicos
a) Analisar as relações da Sociedade da Informação com o contexto do crime de pornografia infantil.
b) Identificar e caracterizar os manuais e guias de pedofilia disponibilizados na Deep Web.
c) Coletar as percepções de policiais que trabalham no combate aos crimes de violência sexual infantojuvenil.
d) Verificar e analisar as percepções de profissionais da área de assistência psicossocial que atuam no acolhimento e tratamento de menores vítimas de abusos sexuais.
e) Identificar os fluxos institucionais dos órgãos públicos que atuam na área de segurança pública e de assistência psicossocial.

Fonte: Elaborado pelo autor, 2018.

3 Procedimentos Metodológicos

Neste estudo serão analisados 04 manuais de pedofilia e serão entrevistados profissionais da área de segurança e assistência psicossocial envolvidos no contexto do crime de Pornografia Infantil no intuito de propor uma estrutura de diretrizes e princípios que possam dar apoio à prevenção deste tipo de ilícito.

3.1 Caracterização da Pesquisa

A abordagem do problema é qualitativa, em virtude da busca da compreensão dos elementos associados ao contexto da prevenção da Pornografia Infantil. É um estudo de caráter exploratória-descritivo uma vez que "pressupõem (sic) que o investigador tenha um conhecimento aprofundado a respeito dos fenômenos e problemas que está estudando" (KÖCHE, 2010, p.126). Dessa forma, a meta é analisar a questão da prevenção a partir de diferentes perspectivas, por meio do emprego de entrevistas com questionamentos semiestruturados (ROSA; ARNOLDI, 2006).

Tabela 2: Procedimentos Metodológicos.

Procedimentos Metodológicos
a1) Levantamento da legislação pátria vigente relacionada ao crime de pornografia infantil.
a2) Levantamento bibliográfico de artigos e publicações científicas relacionadas a interseção da Ciência da Informação, pornografia infantil e prevenção.
b) Análise de conteúdo das principais dicas recomendações compartilhadas por pedófilos.
c) Realizar de entrevistas semiestruturadas com policiais que atuam no combate ao crime de pornografia infantil.
d) Realizar de entrevistas semiestruturadas com psicólogos e assistentes sociais que atuam com menores vítimas de violência sexual.
e) Levantamento de protocolos, fluxos e rotinas de trabalho dos órgãos envolvidos no enfrentamento do problema.

Fonte: Elaborado pelo autor, 2018.

A pesquisa é caracterizada quanto aos procedimentos metodológicos como documental, pois "vale-se de materiais que não receberam ainda um tratamento analítico." (GIL, 2008, p.51), como os guias de pedofilia disponibilizados na Deep Web. A tabela 2 detalha os procedimentos metodológicos.

Por fim, quanto ao referencial teórico, é importante salientar que neste estudo são apresentados dados, gráficos e análises no intuito de tentar demonstrar a dimensão do problema da violência sexual infantil no Brasil. Entretanto, a presente pesquisa tem como eixo central a extração de conteúdo de manuais de pedofilia disponibilizados na Deep Web com o intuito de fomentar a prevenção, dessa forma será produzida a partir de um levantamento bibliográfico (LAKATOS, MARCONI, 2010), através livros e artigos de periódicos que tenham relação com a Ciência da Informação, crimes de violência sexual infantil e prevenção.

A pesquisa da fundamentação bibliográfica será realizada nas bases de dados: Library and Information Science Abstracts (LISA), SUCUPIRA, SCOPUS e Web of Science (WoS), tendo em vista a grande quantidade de períodicos nestas bases e o seu reconhecimento internacional.

4 Resultados

A iminente pesquisa encontra-se numa etapa inicial, tendo sido realizado o levantamento da legislação pátria relacionada à questão da proteção da criança e do adolescente, bem como da legislação associada aos crimes de violência sexual de menores de idade.

Foi realizada a também a Revisão Sistemática da Literatura relacionada à relação da Ciência da Informação, Pornografia Infantil e prevenção.

Ao longo da pesquisa, serão analisados quatro manuais de pedofilia intitulados:

- "How to practice child love";
- "The Pedophile's Handbook";
- "Pedo playground";
- "DDLG Guide".

A fase atual é a análise e categorização dos manuais de pedofilia disponíveis na Deep Web. Tendo sido iniciado a tradução e categorização do primeiro dos quatro manuais de pedofilia disponibilizados na Deep Web.

A tabela 3 apresenta os resultados realizados e esperados relacionando-os aos objetivos específicos e procedimentos metodológicos.

Tabela 3: Resultados.

Resultados
a1) Resultado Esperado: Fundamentação legal sobre o crime de Pornografia Infantil. **a1) Resultado Realizado:** 1. Arts. 109, 144, 227 da Constituição da República Federativa do Brasil 2. Convenção sobre os Direitos da Criança adotada pela Assembleia Geral das Nações Unidas 3. Lei nº 8069/90 (Estatuto da Criança e do Adolescente – ECA) 4. Lei nº 11829/2008 (alterou o ECA) 5. Decreto 99.710/90 – Convenção sobre os Direitos da Criança 6. STJ, RECURSO ESPECIAL Nº 1.543.267 – SC (03/12/2015) 7. STF, RECURSO EXTRAORDINÁRIO 628.624 (Minas Gerais);

a2) Resultado Esperado: Fundamentação teórica sobre as interseções da Sociedade da Informação com o crime de Pornografia **a2) Resultado Realizado:** I. Revisão Sistemática da Literatura.
b) Resultado Esperado: Categorização das dicas e recomendações compartilhadas em manuais de pedofilia na *Deep Web*. b) Resultado Realizado: Em andamento.
c) Resultado Esperado: Identificação das boas práticas de combate ao crime de Pornografia Infantil no contexto policial; coleta de experiências e captação de dicas de prevenção.
d) Resultado Esperado: Identificação dos aspectos relacionados às vítimas de violência sexual infanto-juvenil, observadas por profissionais na área de atendimento e de acolhimento.
e) Resultado Esperado: Identificação de protocolos, fluxos e rotinas no encaminhamento de denúncias de Pornografia Infantil. Levantamento das etapas de acolhimento e tratamento de vítimas pelos órgãos públicos.

Fonte: Elaborado pelo autor, 2018.

4 Considerações Finais

Ao final, busca-se que, à luz da Ciência da Informação, o resultado desta pesquisa possa efetivamente contribuir para a redução dos casos de violação sexual de crianças e adolescentes, enumerando um conjunto de diretrizes e princípios de prevenção que ajudem a sociedade no combate à pornografia infantil, servindo de matéria-prima para a elaboração de campanhas publicitárias, palestras educacionais e ações de conscientização.

Espera-se que o conjunto de diretrizes e princípios de prevenção produzidos por este estudo possam compor manuais de orientação a pais, professores, policiais e sociedade em geral no intuito de permitir maior proteção de crianças e adolescentes em relação aos crimes de violência sexual infantil.

Referências

BRASIL. Instituto Brasileiro de Geografia e Estatística. **Pesquisa Nacional por Amostra de Domicílios Contínua – PNAD Contínua.** 2016. Disponível em: <ftp://ftp.ibge.gov.br/Trabalho_e_Rendimento/Pesquisa_Nacional_por_Amostra_de_Domicilios_continua/Anual/Acesso_Internet_Televisao_e_Posse_Telefone_Movel_2016/Analise_dos_Resultados.pdf>. Acesso em: 10 set. 2018.

BRASIL. Instituto de Pesquisa Econômica Aplicada. **Atlas da Violência.** 2018. Disponível em:<http://www.ipea.gov.br/portal/images/stories/PDFs/relatorio_institucional/180604_atlas_da_violencia_2018.pdf>. Acesso em: 19 set. 2018.

BURKE, Peter. **Uma história social do conhecimento – I: de Gutenberg a Diderot.** Trad. por Plínio Dentzien. Rio de Janeiro: Zahar, 2003.

CAPPELLARI, M. R. S. V. A pedofilia na pós-modernidade: um problema que ultrapassa a cibercultura. **Em Questão**, v. 11, n. 1, p. 67-82, 2005. Disponível em:<http://www.brapci.inf.br/index.php/article/view/0000003734/fcd6ae2b54c19896ab4cce32c6662b37>. Acesso em: 14 set. 2018.

CASTELLS, Manuel. **A Sociedade em Rede:** A Era da Informação: Economia, Sociedade e Cultura. 8. ed. São Paulo: Paz e Terra, 1999. 44 p. 1 v. Tradução de: Roneide Venancio Majer.

FERREIRA, Rubens da Silva; SOBRINHO, Telma Socorro da Silva. Bibliotecas públicas e ciberviolência em tempos de uma sociedade em rede: Novos papéis diante de um novo fenômeno. **Revistas de La Fahce**: Facultad de Humanidades y Ciencias de la Educación/UNPL, Buenos Aires, Argentina, v. 2, n. 1, 2012. Disponível em: <https://www.palabraclave.fahce.unlp.edu.ar/article/view/PCv2n1a03>. Acesso em: 14 set. 2018.

GIL, A. C. **Métodos e técnicas de pesquisa social.** 6. ed. São Paulo: Atlas, 2008. 51 p.

KÖCHE, J. C. **Fundamentos da metodologia científica.** 27. ed. Petrópolis: Vozes, 2010. 126p.

LAKATOS, Eva Maria; MARCONI, Marina de Andrade. **Fundamentos de Metodologia Científica.** 7. ed. São Paulo: Atlas, 2010.

ROSA, M. V. F. P. C.; ARNOLDI, M. A. G. C. **A entrevista na pesquisa qualitativa:** mecanismos para a validação dos resultados. Belo Horizonte: Autêntica Editora, 2006. 112 p.

Vídeo da apresentação

Título: Pornografia infantil: análise de manuais de pedofilia.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=44

Transcrição da apresentação

Pessoal, boa tarde a todos, meu nome é Marcelo, sou aluno de mestrado da UFSC, e também sou policial federal. De antemão gostaria de dizer que fico muito feliz pela parceria entre a UFSC e a Polícia Federal no sentido de trazer a ciência da informação e a segurança pública para uma relação produtiva, muito dos artigos e materiais que eu vi sobre pornografia infantil estão associados normalmente a parte de psicologia, parte técnica, e com essa parceria a gente conseguiu trazer ou, pelo menos, tentar trazer luz a uma questão que é muito séria e muito importante para a gente.

O trabalho no estado é justamente pegar os manuais de pornografia infantil que foram disponibilizados na Deep Web com o intuito de promover e incentivar as pessoas a praticar este tipo de crime. Eu trabalho na parte de repressão a muitos anos e a gente percebe que existe uma movimentação, a gente tenta chegar nos pedófilos através da tecnologia e as tecnologias têm limitações, às vezes você chega em um IP, as vezes você tem uma rede WiFi no endereço que a gente busca, as vezes têm a alimentação de um provedor, então em muitos casos e investigações apesar de ter muitas investigações sobre isto a gente fica limitado na parte técnica, e nesse trabalho de investigações chegou a encontrar a última página de pedófilo ensinando passo a passo, do início ao fim como abusar de crianças de menores, é uma realidade triste de ter uma informação, um guia, que em vez de ser para o bem é utilizado para o mal.

Então a ideia do nosso projeto é pegar a perspectiva desses cidadãos, desses meliantes e junto com a perspectiva da segurança pública, através de entrevistas com policiais e da área social por meio de entrevistas com psicólogos e médicos, fazer um apanhado com o intuito de produzir um conjunto de princípios e diretrizes de prevenção. O objetivo na verdade é de salvar vidas, trazer isso à nossa realidade de uma forma muito clara.

Um outro trabalho que a gente fez, percebemos também no ENANCIB em Londrina, que é interessante trazer para este projeto a questão de prevenção que são feita de forma esporádica, existem alguns sites e projetos que já tem material de preleção que a gente pode nomear junto com o nosso projeto.

Só para contextualizar o nosso trabalho, ele é qualificativo, exploratório-descritivo, onde temos um manual que eu já comecei a analisar. Se a gente olhar o índice deste manual, eu não posso agir naturalmente porque é um manual que ensina alguns caminhos, e na atividade policial nós não teríamos como aprofundar e detalhar estas linhas, até porque a gente não está aqui para isso, mas a gente percebe claramente o caminho que o cidadão que criou este manual quer te ensinar.

Ele trabalha aspectos de sexualidade infantil, diz quando e como a criança passa a ter este interesse, ele traz a questão de tabu e vergonha, diz que a sociedade reprime os pedófilos, que não seria correto fazer esta repressão, que você teria o direito de praticar o que você quisesse. Além disso ele alerta claramente aos pedófilos sobre os riscos envolvidos, esse cara que fez esse manual, ele sabe perfeitamente que ele está cometendo um crime, ele sabe que socialmente isso é recriminado, mas ele continua incentivando porque ele acha que isto é correto, infelizmente essa é a realidade.

Ele se intitula um profissional do ramo infantil, e ele vai conduzindo a pessoa para que faça de qualquer maneira sexo seguro com crianças. Mas ele fala com segurança não é só com o pedófilo, com o abusador, ele tenta dizer para criança que aquilo também é para ela, que ela está sendo educada sexualmente para no futuro ela ser uma pessoa consciente com este tipo de ação.

O nosso foco principal no projeto é a prevenção, então aqui neste capítulo que ele coloca como e onde encontrar uma criança é o que a gente normalmente vai tentar porque o caminho que ele vai chegar, digamos assim no objeto, no alvo que ele quer seduzir, que ele quer alcançar.

Então ele ensina você a procurar seus próprios filhos, inacreditável mas é assim, além disso ele ensina a você através dos seus filhos encontrar amigos dos seus filhos, ensina a procurar mães solteiras que têm crianças e que naturalmente possam ter uma relação com ele, ele possa se aproximar das crianças, outro caminho que ele ensina também que é inverso seria você virar babá, trabalhar em creches e escolas, ser profissionais nesses ambientes onde tem muitas crianças e com isso você vai ter facilidade de acesso. Ensina outras formas criativas e ensina também algumas vantagens para você poder se aproximar dessas crianças e ter maior sucesso. Enfim existem outras etapas que eu não posso listar naturalmente porque é um conteúdo ilícito e não posso divulgar, mas são os valores que ele ensina por realizar estes atos.

O objetivo mais uma vez do nosso projeto é criar prevenção, mas para públicos alvos, a gente tentar criar um manual, um guia de contra medidas ou prevenção para professores, para educadores, para pessoas da sociedade em geral, para policiais ou até mesmo para assistente social, para que a gente possa no futuro trazer prevenções para nossas crianças.

Infelizmente, sendo muito sincero, a gente que trabalha na parte de repressão, a gente tem uma limitação, infelizmente na Polícia Federal principalmente a gente percebe que o estado precisa evoluir, mas nós trabalhamos com o compartilhamento de fotos e vídeos, isso é um problema grave, mas o abuso já aconteceu, e se a gente não se preocupar e se a sociedade não entender disso, tem que internalizar em todos nós, que cada um pode ser um vigilante de uma criança, a nossa realidade não vai mudar.

Para vocês terem ideia de como é essa situação de manuais, esse cara que usou, eu tenho quatro manuais que vou trabalhar no projeto, eles tem uma didática muito forte, eles ensinam realmente como se fosse um livro de leitura de alto explicação, ele fala que não precisa ter contato, ele naturalmente não quer ser identificado, que o próprio manual é autoexplicativo e por ele você vai conduzir ao seu caminho da felicidade, realizar seus desejos o máximo de vezes possíveis, e dessa forma ele vai instigando o leitor a ter este interesse, a caminhar e executar cada uma dessas etapas, ele deixa claro, se você não gosta, não continue, mas se você quiser você será muito feliz ao finalizar o curso.

Outra coisa que fica marcante e claro que a gente que trabalha como policial a gente fica alerta, a gente tem a impressão que a internet que é uma linha que deu um boom para criminalidade, primeira dica que ele dá é "não utilize a internet", "não use qualquer sinal de comunicação eletrônica" porque justamente a policia vai estar observando todas as suas ações, então a gente tem que se preocupar não é apenas com o meio digital, esse caminho que a gente normalmente acha que é o caminho maior, mas é no dia a dia, e isso é só conversando, eu

cuidando dos meus filhos, cada um de nós com um olhar atento com cada criança que nós temos neste mundo.

Obrigado.

A Ciência da Informação e a educação em gestão e curadoria de dados de pesquisa

Gracielle Mendonça Rodrigues Gomes[a] *e Marcello Mundim Rodrigues*[b]

Resumo: A pesquisa tem como objetivo geral identificar se existem estudos na literatura nacional da CI que contemplem a formação dos profissionais da informação para atuação na área dos dados de pesquisa bem como se existem estudos que tratem sobre desenvolvimento da competência de dados de pesquisa em estudantes e pesquisadores. A busca foi realizada em bases de dados nacionais e internacionais, e no Google Acadêmico. A interpretação dos documentos recuperados foi realizada através da técnica de análise de conteúdo. Não foi identificado nenhum artigo na literatura nacional de CI com as temáticas principais sobre a formação de profissionais da informação na área de dados de pesquisa e/ou o desenvolvimento de competência em dados de pesquisa pelas bibliotecas universitárias e serviços de informação científica. Foi observada a necessidade de discussões e pesquisas sobre essas temáticas na literatura científica nacional de modo a contribuir para a realização de mudanças nos atuais currículos das Escolas de Ciência da Informação no Brasil e o aperfeiçoamento dos serviços de informação prestados aos estudantes e pesquisadores com o intuito de acompanhar as últimas transformações ocorridas na pesquisa científica.

Palavras-chave: Ciência da Informação – Educação; Especialistas em dados de pesquisa; Competência em dados de pesquisa; Gestão de dados de pesquisa; Curadoria digital.

The Information Science and education in management and curation of research data

Abstract: The research has as main objective identifying the existence of studies in the Library and Information Science (LIS) national literature that discuss the education of information professionals to perform in the research data field as well as identifying studies that deal with the development of research data literacy by students and researchers. The search conducted used national and international databases, also Google Scholar. Data analysis and interpretation were performed using the content analysis technique. The research did not identify papers in the national literature of LIS that seek to discuss in their main objectives the education of information professionals in the research data field and/or the development of research data literacy by academic libraries and scientific information services. It observed the need for more discussions and research on these topics in the national scientific literature to contribute to changes in the current curricula of LIS Schools in Brazil and to improve the information services provided to students and researchers in order to follow the latest transformations on scientific research.

Keyword: Information Science – Education; Research data specialist; Research data literacy; Research data management; Digital curation.

a Universidade Federal de Minas Gerais (UFMG). E-mail: graciellemendonca@yahoo.com.br. ORCID: https://orcid.org/0000-0003-3614-771X. Currículo: http://lattes.cnpq.br/5638259728289538

b Universidade Federal de Minas Gerais (UFMG). E-mail: marcellomundim@ufu.br. ORCID: https://orcid.org/0000-0001-7945-6673. Currículo: http://lattes.cnpq.br/7319023790210705

1 Introdução

A Ciência da Informação (CI) está em condições de sustentar as mudanças necessárias para favorecer o movimento em direção à área de dados de pesquisa e atender as novas demandas que estão surgindo no contexto da ciência (e-Science). Os problemas enfrentados pelas instituições na gestão e curadoria de dados de pesquisa oferecem uma oportunidade relevante e atraente para a área e seus profissionais reformularem teorias, valores e currículos, redefinirem seus papéis e competências no apoio à pesquisa, além de avançarem na disponibilização de novos serviços, desde que percebam as várias oportunidades que surgirão a partir da integração dos dados em seus serviços e estejam convencidos do valor que podem trazer à pesquisa na medida em que investirem tempo na expansão de suas fronteiras habituais (CORRALL, 2012; KIM, 2016).

O desenvolvimento das habilidades e conhecimentos relacionados à área de dados pode ocorrer em dois níveis. O primeiro, através da formação dos profissionais da informação como especialistas capazes de realizar a gestão e a curadoria de dados de pesquisa mediante educação formal em instituições de ensino e eventos da área. O segundo, através do treinamento de pesquisadores e estudantes realizado por profissionais da informação com competências e conhecimentos sobre o contexto dos dados. Neste caso, sendo realizado como parte das funções vitais das bibliotecas e serviços de informação científica de promover capacidades que permitam aos indivíduos acessarem, interpretarem, avaliarem criticamente, gerenciarem, manipularem e usarem dados de pesquisa eticamente, no qual vem sendo definido na literatura como competência em dados (CALZADA PRADO; MARZAL, 2013; KOLTAY, 2015).

Os profissionais da informação para serem capazes de ensinar a competência em dados ou estarem envolvidos em qualquer atividade de pesquisa relacionada a dados devem ser capacitados, pois o sucesso na realização dessas atividades dependerá de uma formação de qualidade. As Escolas de Ciência da Informação e os professores têm um papel importante a desempenhar no planejamento e preparação de profissionais adequadamente habilitados para atender às demandas latentes da e-Science e exercer seu papel na gestão e na curadoria de dados de pesquisa. Contudo, torna-se necessário realizar uma mudança de paradigma, pois muitas Escolas de Ciência da Informação ainda estão mais preocupadas com a informação do que com os dados. Outra maneira de melhorar a consciência dos profissionais da informação que buscam atuar na área de dados é através do estímulo dos gestores para que sua equipe realize leituras de publicações e participe de eventos sobre o tema de modo a ajudá-los a atualizar seus conhecimentos e ganhar confiança sobre o assunto (SWAN; BROWN, 2008; CORRALL, 2012; KOLTAY, 2015).

O treinamento de estudantes e pesquisadores pode ser realizado por bibliotecas e serviços de informação através de diversas atividades como a disponibilidade de orientações sobre questões relacionadas à gestão de dados, acesso aberto, comunicação acadêmica, direitos autorais, propriedade intelectual, metadados, padrões técnicos, acesso, arquivamento, reúso e preservação de dados; o desenvolvimento de serviços de curadoria digital em conjunto com centros de TI fornecendo serviços de computação, armazenamento e segurança de dados; a conscientização e a defesa em torno da gestão de dados para as comunidades de pesquisa, cujo nível de compreensão provavelmente variará no campus devido as diferentes culturas disciplinares que muitas vezes tornam os desafios da gestão de dados específicos à disciplina. Porém, a maioria das bibliotecas

universitárias e científicas ainda oferecem apenas programas de competência informacional para seus usuários, sendo incomum ver estas participando de projetos de pesquisa para auxiliarem na gestão de dados (SWAN; BROWN, 2008; CORRALL, 2012).

Diante dessas mudanças, a CI está sendo desafiada a desenvolver uma nova vertente de especialidades e funções capazes de responder às crescentes necessidades de serviços relacionados aos dados de pesquisa, além de auxiliar seus usuários a serem capazes de gerenciar os seus próprios conjuntos de dados. Para isso, torna-se necessário fornecer formação e treinamento que ajustem às novas formas de manipulação, gestão e uso dos dados de pesquisa, preparando tanto os profissionais da informação quanto os pesquisadores e estudantes de graduação e pós-graduação para lidar com o que surgirá daqui em diante, pois estamos num ambiente informacional completamente novo do que tínhamos há 10 anos (KOLTAY, 2015; KIM, 2016; TANG; SAE-LIM, 2017).

2 Objetivos

O objetivo geral dessa pesquisa é identificar se existem na literatura nacional da CI estudos que contemplem a formação dos profissionais da informação em gestão e curadoria de dados de pesquisa, e estudos que tratem sobre o desenvolvimento da competência em dados para pesquisadores e estudantes de graduação e pós-graduação. Os objetivos específicos são: a) identificar trabalhos pertinentes ou relacionados às temáticas; b) avaliar como as temáticas estão sendo apresentadas nos artigos; c) caracterizar o estado atual da literatura da CI sobre as temáticas; d) promover a discussão sobre os temas na CI brasileira.

3 Procedimentos Metodológicos

O trabalho consiste numa pesquisa qualitativa e exploratória. A partir da revisão de literatura apresentaram-se algumas contribuições relevantes para a construção teórica e conceitual da pesquisa, e através da análise de conteúdo avaliaram-se os documentos selecionados. Na primeira etapa realizou-se a coleta de dados, através da busca na literatura brasileira da CI sobre as temáticas supracitadas, em bases nacionais, BRAPCI e SCIELO, bases internacionais, LISA, LISTA, Scopus e Web of Science, além do Google Acadêmico. Para isso, usaram-se as palavras-chave "Curriculum" OR "Currículo", "Information Science" OR "Ciência da Informação", "Curation" OR "Curadoria" e "Data" OR "Dados". Na estratégia de busca almejou-se aumentar a revocação e ampliar a possibilidade de recuperação de documentos úteis.

Na segunda etapa selecionaram-se os documentos recuperados através da leitura do título, resumo, palavras-chave e texto completo para reconhecer documentos que tratam das temáticas supracitadas e/ou identificar artigos que as mencionam de algum modo, pois estas ainda são incipientes na literatura brasileira da CI. Ao final dessa etapa, permanecem 10 documentos, nos quais 07 são artigos de periódico, 01 é livro, 01 é tese e 01 é monografia.

Na terceira etapa, usou-se como critério de exclusão, analisar somente os 07 artigos de periódicos devido à sua natureza de comunicação. Em seguida, elaboraram-se as categorias para avaliar os assuntos tratados nos artigos, indicando dessa forma a proximidade ou o distanciamento dos artigos com os objetivos almejados para a pesquisa (ver Tabela 1 – Apêndice A).

4 Resultados

Os artigos são analisados nos resultados por critério de ordem cronológica.

4.1 Boeres e Cunha (2012)

Os autores citam a escassez de trabalhos que tratam sobre as competências necessárias para formação dos profissionais da informação na área de preservação digital. Apresentam as demandas para bibliotecários com domínio sobre as tecnologias digitais, gestão da informação e promoção do acesso à informação em formato impresso ou digital. Discutem sobre o desenvolvimento das capacidades analíticas do profissional que lida com os dados para tomar decisões nos negócios. Alertam quanto à necessidade de profissionais com know-how para lidar com a segurança de dados digitais. Porém, apesar de refletirem sobre algumas problemáticas em relação aos dados, os autores dedicam à formação do profissional da informação com foco a aprendizagem de técnicas de digitalização de recursos informacionais e preservação digital, e não a atuação direcionada à área de dados de pesquisa.

4.2 Curty e Serafim (2016)

Os autores estudam currículos de cursos de ciência de dados dos EUA e a formação de profissionais com competências para lidar com volumes cada vez maiores de dados em diferentes contextos. Os termos "gerenciamento de dados" e "curadoria de dados" aparecem no trabalho e indicam que a formação dos cientistas de dados também passa por essas temáticas, práticas e teorias. Ainda que não trate diretamente os dados gerados pela ciência, aborda sobre a demanda existente para os profissionais de dados neste contexto devido ao avanço da e- Science. Também apontam para a possibilidade dos cientistas de dados trabalharem com pesquisadores ou grupos de cientistas em ambientes de pesquisa e serviços que tratem de dados digitais. Entretanto, não foi objetivo da pesquisa discutir o desenvolvimento de competências em dados de pesquisa e/ou a formação dos profissionais da informação orientada aos dados de pesquisa.

4.3 Boeres e Cunha (2016)

Os autores apresentam conceitos sobre preservação digital, biblioteca digital e curadoria digital e os relacionam com as etapas de gestão de dados de pesquisa. Tratam sobre questões de autenticidade, confiabilidade e integridade dos dados digitais. Destacam o reúso ético dos dados de pesquisa por pesquisadores como usuários de repositórios de dados e que têm por intuito retirar desses conjuntos de dados novas análises e percepções. Concluem que Escolas de Ciência da Informação são responsáveis pela capacitação dos profissionais da informação para preservação e curadoria digital, porém não foi o objetivo principal dos autores tratar sobre a formação dos profissionais da informação para o contexto dos dados de pesquisa.

4.4 Weber (2017)

O autor cita a curadoria digital como responsável pelo gerenciamento do objeto digital. Aborda sobre os repositórios de dados, o ciclo de vida dos dados, a e- Science e a importância de realizar a gestão dos dados de pesquisa. Discorre sobre a necessidade dos pesquisadores aplicarem as práticas de curadoria no seu dia-a-dia utilizando os metadados para garantir o reúso e o acesso aos dados. Discute os riscos dos repositórios digitais se tornarem cemitérios de dados,

caso a prática de curadoria recaia exclusivamente sobre o sistema em vez de envolver também a prática humana. Aponta que a curadoria digital surge principalmente como necessidade da pesquisa científica na era digital e, portanto, deve contar com profissionais capacitados. O objetivo principal da pesquisa foi discutir os conceitos de curadoria digital, e desse modo, não trata diretamente das temáticas aqui pesquisadas.

4.5 Araújo e Finamor (2017)

Os autores discutem as funções do arquivista na curadoria e na preservação digital sob a ótica da Arquivologia. Tratam da importância de se assegurar que os futuros usuários sejam adequadamente capacitados para garantir um efetivo gerenciamento e reúso dos dados, o que significa um alerta para o desenvolvimento de competência em dados por usuários desses serviços, ainda que esse não seja o foco principal do artigo. Apresentam as competências que devem ser desenvolvidas pelos profissionais interessados em atuar na curadoria e na preservação digital. Concluem sobre a necessidade de disponibilizar disciplinas de graduação nos cursos de Arquivologia do Brasil que formem profissionais aptos a trabalharem na área da curadoria e preservação digital, além de incitar profissionais pela formação continuada. Portanto, percebe-se que as temáticas aqui pesquisadas foram brevemente citadas, mesmo não sendo o objetivo do trabalho.

4.6 Rocha, Sales e Sayão (2017)

O artigo foca no uso das ferramentas de escrita e registro de procedimentos e resultados de pesquisa científica pelos pesquisadores, avaliando os seus impactos. Discute sobre essas ferramentas sendo anteriormente encontradas apenas em formato analógico, porém, atualmente existem também em formato digital, denominadas de cadernos eletrônicos de laboratório. Trata o seu uso e as práticas relacionadas à ciência aberta e a preservação de dados institucionais, além da importância da atuação do profissional da informação nos ambientes de pesquisa como mediadores do uso dessas novas e promissoras tecnologias. Há também uma acanhada menção ao bibliotecário de dados e a formação desses profissionais que ainda está muito distante da realidade dos cursos de graduação de Biblioteconomia no Brasil.

4.7 Vanz, Santin e Pavão (2018)

O artigo tem como objetivo principal a bibliometria como serviço de informação a ser ofertado por bibliotecas universitárias brasileiras a partir de novas demandas dos usuários. Indicam que a bibliometria ainda não faz parte dos conteúdos obrigatórios da maior parte dos cursos de Biblioteconomia no país, muito menos é comum enquanto serviço das bibliotecas universitárias. Apontam brevemente sobre a necessidade dos bibliotecários auxiliarem os pesquisadores a lidarem com seus dados de pesquisa e a atenderem a demanda das agências de financiamento. Expõem sobre a importância de promover a competência informacional nas bibliotecas. Porém, não foi discutida a formação da competência em dados para pesquisadores e estudantes como parte das novas atividades dos bibliotecários das universidades.

5 Considerações Finais

Observam-se, atualmente, dificuldades para encontrar artigos na CI no Brasil quanto à formação do profissional da informação em gestão e curadoria de dados de pesquisa e sobre o desenvolvimento da competência de dados em estudantes e pesquisadores pelos serviços de informação científica. Não foi constatado nenhum artigo. Destaca-se que os artigos selecionados para análise tratam de modo incipiente sobre esses assuntos, pois não eram os seus objetivos principais. Apenas um artigo discutiu brevemente sobre algumas atividades relacionadas ao desenvolvimento de competência em dados de pesquisa e quatro artigos indicam sobre necessidade de formação do profissional da informação para atividades relacionadas ao contexto de dados. Considera-se a necessidade de realizar discussões e pesquisas sobre essas temáticas na literatura nacional da área de modo a tentar estimular a mudança dos currículos atuais das Escolas de Ciência da Informação e dos serviços prestados aos estudantes e pesquisadores no Brasil, pois torna-se imprescindível para a CI acompanhar as transformações na ciência e evoluir conjuntamente com as práticas de produção e comunicação científica.

Referências

ARAÚJO, R. O.; FINAMOR, M. S. Curadoria digital: papéis e responsabilidades do arquivista. **Inf. Prof.,** Londrina, v. 6, n. 1, p. 44 – 68, jan./jun. 2017.

BOERES, S. A. A.; CUNHA, M. B. Competências básicas para os gestores de preservação digital. **Ci. Inf.**, Brasília, DF, v. 41 n. 1, p.103-113, jan./abr., 2012.

BOERES, S. A. A.; CUNHA, M. B. Competências para a preservação e curadoria digitais. **Rev. Digit. Bibliotecon. Cienc. Inf**. Campinas, SP v.14 n.3 p. 426-449, set/dez. 2016.

CALZADA PRADO, J.; MARZAL, M. A. Incorporating data literacy into information literacy programs: core competencies and contents. **Libri**; v. 63, n. 2, p. 123−134. 2013.

CORRALL, S. Roles and responsibilities: libraries, librarians and data. In: PRYOR, Graham (Ed.). **Managing research data**. London: Facet, 2012. p. 141-151.

CURTY, R. G.; SERAFIM, J. da S. A formação em ciência dos dados: uma análise preliminar do panorama estadunidense. **Informação&Informação**, Londrina, v. 21, n. 2, p. 307–328, maio/ago., 2016.

KIM, J. Who is teaching data: meeting the demand for data professionals. **Journal of Education for Library and Information Science Online**, v. 57, n. 2, p. 161-173, 2016.

KOLTAY, T. Data literacy: in search of a name and identity. **Journal of Documentation**, v. 71, n. 2, p. 401-415, 2015.

ROCHA, L. L.; SALES, L. F.; SAYÃO, L. F. Uso de cadernos eletrônicos de laboratório para as práticas de ciência aberta e preservação de dados de pesquisa. **PontodeAcesso**, Salvador, v.11, n.3, p. 2-16, dez. 2017.

SWAN, A.; BROWN, S. **The skills, role and career structure of data scientists and curators**: an assessment of current practice and future needs. Truro, UK: Key Perspectives, 2008.

TANG, R.; SAE-LIM, W. Data Science Programs in U.S. higher education: an interview with the authors, **Journal of eScience Librarianship**, v. 6, n. 1, p. 1-17, 2017.

VANZ, S. A. S.; SANTIN, D. M.; PAVÃO, C. M. G. A bibliometria e as novas atribuições profissionais em bibliotecas universitárias. **InCID: R. Ci. Inf. e Doc.**, Ribeirão Preto, v. 9, n. 1, p. 4-24, mar./ago. 2018.

WEBER, C. Curadoria digital de dados científicos: pelo viés de um periódico. **P2P & Inov**. Rio de Janeiro, RJ, v. 3 n. 1, set./mar. 2017.

Apêndice A

Quadro 1 – Avaliação dos artigos.

Categoria	Artigo 1 Boeres e Cunha (2012)	Artigo 2 Curty e Serafim (2016)	Artigo 3 Boeres e Cunha (2016)	Artigo 4 Weber (2017)	Artigo 5 Araújo e Finamor (2017)	Artigo 6 Rocha, Sales e Sayão (2017)	Artigo 7 Vanz, Santin e Pavão (2018)
Literatura da CI	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Temas principais	Preservação e biblioteca digital	Ciência de dados	Preservação curadoria digital	Curadoria de dados científicos	Curadoria e preservação de documentos digitais	Ciência aberta e preservação de dados de pesquisa	Bibliometria em biblioteca universitária
Objetivo geral	Identificar as competências dos profissionais de preservação digital	Compreender os aspectos formativos do cientista de dados	Identificar competências e atividades da preservação e curadoria digital	Estudar os conceitos de curadoria digital e os assuntos relacionados à temática	Investigar as funções do arquivista na curadoria e preservação digital	Relacionar o uso de cadernos eletrônicos com o reúso e a preservação de dados	Discutir o uso da bibliometria como atividades das bibliotecas acadêmicas
Menção a dados de pesquisa	Não	Sim	Sim	Sim	Sim	Sim	Sim
Competência em dados de pesquisa	Não	Não	Não	Não	Não	Não	Trata brevemente do assunto
Formação do PI em Gestão e Curadoria de Dados de Pesquisa	Não	Trata brevemente do assunto	Trata brevemente do assunto	Não	Trata brevemente do assunto	Trata brevemente do assunto	Não

Fonte: Dados de pesquisa, 2018.

Vídeo da apresentação

Título: A Ciência da Informação e a educação em gestão e curadoria de dados de pesquisa.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=45

Transcrição da apresentação

Boa tarde, bom meu nome é Marcello, eu sou mestrando em gestão e organização do conhecimento na Universidade Federal de Minas Gerais, eu fiz este trabalho com uma colega de doutorado que é a Gracielle Mendonça Rodrigues Gomes, ela é bibliotecária na UFMG e eu sou bibliotecário em Uberlândia. A gente trouxe este trabalho, ingressando na pesquisa em gestão de dados e a gente decidiu fazer essa abordagem dentro da educação.

Antes de começar queria agradecer a oportunidade pelo trabalho apresentado ter sido selecionado, é um prazer vir até aqui e estar participando do evento. Então o contexto que a gente fala sobre a ciência da informação e educação de profissionais de informação e dados, também falamos de competência em dados que é transmitido pelo pessoal da informação, que domina essa expertise de gestão e dados, conhece esses meios e consegue auxiliar esses pesquisadores, alunos de graduação, pós-graduação, que trabalham com pesquisa para gerirem seus datasets, conjuntos de dados.

Os problemas enfrentados pelas instituições na gestão e curadoria de dados de pesquisa oferecem uma oportunidade para ciência da informação e os profissionais da ciência da informação elaborarem teorias, valores e políticas, além de definir os papéis e competências no apoio a pesquisa e a importância de que esses profissionais percebam as oportunidades que surgem nessas percepções dos dados de pesquisa.

O desenvolvimento das habilidades e conhecimentos relacionados à área de dados pode ocorrer em dois níveis. O primeiro nível é o nível que vem obviamente na fase inicial que é a formação dos profissionais, então primeiro é necessário que a gente tenha a formação para que depois a gente faça essa capacitação dos nossos usuários de serviços no caso bibliotecas universitárias. Se a gente está falando de bibliotecários e serviços que são voltados para pesquisa científica, então hoje o nosso ambiente é a biblioteca universitária na universidade.

Então na primeira etapa, através da formação dos profissionais da informação como especialistas capazes de realizar a gestão e a curadoria de dados de pesquisa mediante educação formal em instituições de ensino e eventos da área.

A segunda etapa ela vem através do treinamento de pesquisadores e estudantes, depois que você tem profissionais formados nessa área, nós temos esses profissionais trabalhando para formação e desenvolvimento de competências desses usuários, os pesquisadores, os alunos e instituições. A gente tem a informação como competência da informação,, que é uma tendência agora de estudos da literatura estrangeira, e nossa intenção de pesquisa vem buscar esse conhecimento de como anda a literatura nacional.

Aqui a gente entra um pouco mais na introdução em que os profissionais da informação são capazes de ensinar essas competências a partir da informação que eles possam receber na sua formação profissional, e os professores também possuem papel importante nesta formação desses profissionais bibliotecários formados para dados.

O objetivo geral dessa pesquisa é identificar se existem na literatura nacional da CI estudos que contemplem a formação dos profissionais da informação em gestão e curadoria de dados de pesquisa, e estudos que tratem sobre o desenvolvimento da competência em dados para pesquisadores e estudantes de graduação e pós-graduação. Os objetivos específicos são: a)

identificar trabalhos pertinentes ou relacionados às II Workshop de Informação, Dados e Tecnologia, UFPB, Brasil temáticas; b) avaliar como as temáticas estão sendo apresentadas nos artigos; c) caracterizar o estado atual da literatura da CI sobre as temáticas; d) promover a discussão sobre os temas na CI brasileira.

Na primeira etapa a gente fez a coleta de dados, a gente procurou trabalho nas principais bases de dados científicas, BRAPCI, SCIELO, LISA, LISTA, Scopus, Web of Science e Google Acadêmico. A gente buscou utilizando essas palavras-chave, a gente tentou fazer uma busca mais ampla de trabalhos, a gente fez a leitura do título, resumo, palavra-chave depois a gente passou para o texto completo para identificar melhor se tratavam deste assunto ou se aproximavam.

Então a gente identificou sete artigos, um livro, uma tese e uma monografia, por critério de exclusão a gente preferiu trabalhar somente com os artigos. Nos nossos trabalhos a gente apresenta a resenha dos sete artigos que nós achamos, então a gente fez uma periodização da análise de conteúdo, a gente criou um quadro e também fizemos essas resenhas dos trabalhos para passarmos uma ideia do conteúdo desses trabalhos.

Aqui são os resultados, onde temos os sete artigos em ordem cronológica, 2012-2018, e a gente apresentou os temas, os objetivos dos trabalhos, se apresentou menção de dados de pesquisa, se apresentou competência em dados de pesquisa e se apresentou formação do PI em Gestão e Curadoria de Dados de Pesquisa. Então a gente com esse quadro identifica que são trabalhos na predominância da ciência da informação, eles têm temática desde preservação, ciência de dados, bibliometria, curadoria. Nos objetivos gerais a gente identificou que nenhum desses trabalhos buscavam falar sobre a formação dos profissionais e nem da competência destinado aos pesquisadores e alunos de graduação e pós-graduação, a maioria mencionou os dados de pesquisa, porém nenhum deles estava destinado para falar sobre a temática que nós buscamos identificar. Então temos o quadro detalhado segundo o nosso objetivo.

As considerações finais Observam-se, atualmente, dificuldades para encontrar artigos na CI no Brasil quanto à formação do profissional da informação em gestão e curadoria de dados de pesquisa e sobre o desenvolvimento da competência de dados em estudantes e pesquisadores pelos serviços de informação científica. Então a gente não encontrou artigos que estavam destinados a isso.

Os artigos selecionados para análise tratam de modo incipiente sobre esses assuntos, pois não eram os seus objetivos principais. Apenas um artigo discute brevemente sobre algumas atividades relacionadas ao desenvolvimento de competência em dados de pesquisa e quatro artigos indicam sobre necessidade de formação do profissional da informação para atividades relacionadas ao contexto de dados. Considera-se a necessidade de realizar discussões e pesquisas sobre essas temáticas na literatura nacional da área de modo a tentar estimular a mudança dos currículos atuais das Escolas de Ciência da Informação e dos serviços prestados aos estudantes e pesquisadores no Brasil, pois torna-se imprescindível para a CI acompanhar as transformações na ciência e evoluir conjuntamente com as práticas de produção e comunicação científica.

Então a gente alcançou este objetivo e a gente percebe que tem possibilidades de pesquisas futuras, como a gente buscou trabalhos nacionais, poderíamos buscar talvez se existem pesquisadores escrevendo em inglês, a gente acha que não mas há essa possibilidade, então

existem possibilidades de estudos futuros a partir do que a gente encontrou. É isso, nossas referências.

Obrigado.

Slides da apresentação

Título: A Ciência da Informação e a educação em gestão e curadoria de dados de pesquisa.

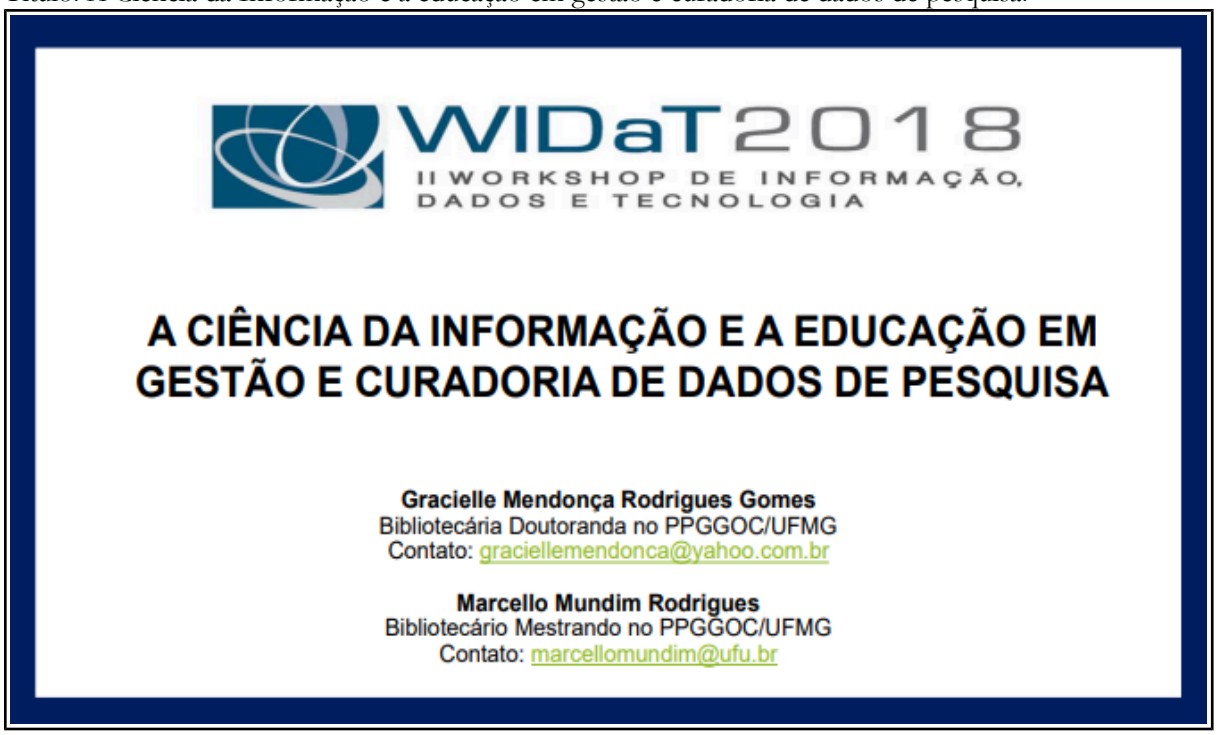

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=45

Política de compartilhamento de dados científicos: a adoção nos periódicos da Ciência da Informação

Renata Lemos dos Anjos[a] *e Marynice de Medeiros Matos Autran*[b]

Resumo: Desde 1665, a comunicação científica continua prioritariamente direcionada à publicação dos resultados em periódicos científicos. Esses resultados provêm de análises realizadas em nas investigações científicas por meio dos dados que são coletados para a pesquisa, ou gerados com a pesquisa. Com o desenvolvimento das Tecnologias Digitais de Informação e Comunicação, a comunicação científica passou por várias transformações. Atualmente, depara-se com um novo paradigma: a do compartilhamento de dados. A presente pesquisa exploratória e documental, investigou se os periódicos da área de Ciência da Informação possuem uma política de compartilhamento de dados científicos. Foram selecionados periódicos com o CiteScore maior ou igual a 0.50. Dos quinze periódicos analisados, 53% apresentam políticas e diretrizes para o compartilhamento de dados, seja de forma obrigatória ou flexível. Concluiu-se que a prática do compartilhamento de dados por parte dos periódicos em Ciência da Informação, encontra-se nos seus em fase inicial e apresenta perspectivas de breve consolidação.

Palavras-chave: Política de compartilhamento de dados; Periódicos; Ciência da informação.

Scientific Data Sharing Policy: Adoption in Information Science journals

Abstract: Since 1665, scholarly communication has continued to focus primarily on publication of results in scientific journals. These results come from analyses carried out in scientific investigations through data collected for research, or generated through research. With the development of Digital Information and Communication Technologies, scholarly communication has undergone several transformations. Nowadays, we are seeing a new paradigm: the data sharing. This exploratory and documentary research investigated whether the Information Science journals have a policy of sharing scientific data. Journals were selected with the CiteScore greater than or equal to 0.50. Of the fifteen journals analyzed, 53% present policies and guidelines for data sharing, whether in a mandatory or flexible way. The practice of data sharing by Information Science journals is in initial phase and presents prospects of brief consolidation.

Keyword: Data sharing policy; Journals; Information science.

a Universidade Federal da Paraíba (UFPB). E-mail: renatalemosdosanjos@gmail.com. ORCID: https://orcid.org/0000-0002-4599-3494. Currículo: http://lattes.cnpq.br/8287662863078416

b Universidade Federal da Paraíba (UFPB). E-mail: marynice.autran@gmail.com. ORCID: https://orcid.org/0000-0003-0786-1957. Currículo: http://lattes.cnpq.br/0437948815138207

1 Introdução

Em 1665 foram publicados os primeiros periódicos científicos, na Inglaterra, o Philosophical Transactions of the Royal Society e na França, o Journal des Sçavans. Desde então, a Comunicação Científica – CC, direciona à publicação, prioritariamente, os resultados de pesquisas para publicação em periódicos científicos (ANJOS, 2016). Esses resultados provêm de análises realizadas no curso das investigações, por meio dos dados coletados para a pesquisa, ou gerados a partir desta.

Com a emergência das Tecnologias Digitais de Informação e Comunicação – TDIC, tanto a própria ciência, quanto a CC passaram por transformações, afirmando o seu caráter evolutivo, mutável e dinâmico no que concerne ao seu modo de divulgar e comunicar a ciência (TARGINO, 2000). Essas transformações referem-se à adaptação ao cenário eletrônico, de forma que os processos de publicação dos periódicos científicos foram alterados, tanto nos moldes de avaliação e comunicação entre autores, editores, pareceristas e leitores, quanto nos moldes de disseminação e acesso às publicações (NASSI-CALÒ, 2014).

Diante de tal realidade, a CC encontra-se imersa no fenômeno da e-Science, considerado como o quarto paradigma científico (GRAY, 2007). Em linhas gerais a e-Science consiste no uso e no intensivo compartilhamento de dados provenientes de investigações científicas, fazendo com que se tornem matéria prima para outras investigações, por meio da sua reutilização (SAYÃO; SALES, 2014).

Nesta perspectiva, fundamentando-se no compartilhamento intensivo de dados e em seu posterior reúso, periódicos das mais variadas áreas do conhecimento estão dando especial atenção aos dados resultantes de investigações científicas, bem como solicitando aos autores que disponibilizem, juntamente com o artigo final, o conjunto de dados utilizados na pesquisa, de forma a incentivar políticas de compartilhamento de dados científicos.

Em concordância com Nassi-Calo (2014) ao referir que "[…] quanto mais pesquisadores disponibilizarem abertamente seus dados em repositórios de acesso aberto, maior a probabilidade de que outros possam replicar seu trabalho, com benefícios evidentes para todos". Nesta concepção, a política de compartilhamento de dados científicos, atualmente, vem sendo incentivada. Percebemos que um mesmo conjunto de dados possibilita várias vertentes de exploração, e podem também validar ou revogar uma determinada pesquisa e artigo científico. O incentivo a essas práticas de compartilhamento de dados, faz a comunicação científica desenvolver-se cada vez mais, além de aumentar a qualidade da ciência.

2 Objetivos

Esta pesquisa busca analisar a adoção da política de compartilhamento de dados nos periódicos da área da Ciência da Informação com CiteScore maior ou igual a 0.50 e verificar como ocorre esse compartilhamento/disponibilização, se de maneira obrigatória ou flexível.

3 Procedimentos Metodológicos

Trata-se de uma pesquisa exploratória e documental, que buscou identificar nas homepages dos periódicos informações sobre a adoção de políticas de compartilhamento de dados.

Foram selecionados os periódicos da área de Library and Information Sciences (Biblioteconomia e Ciência da Informação) de acesso aberto, que estão indexados na base de dados bibliográfica Scopus. Essa base apresenta, entre outras métricas, o CiteScore que mede a influência de determinado periódico em sua área por meio do quociente entre a quantidade de vezes que o periódico foi citado em determinado ano, no caso 2017, e a quantidade de documentos (artigos) disponíveis nos últimos três anos (2014, 2015, 2016).

Como critério de seleção, escolhemos aqueles periódicos que possuem CiteScore maior ou igual a 0.50, no ano de 2017, o que totalizou o universo de 15 títulos, os quais atendiam a esse critério. (Quadro 1).

Quadro 1 – Periódicos da área da Ciência da Informação com CiteScore ≥ 0.50.

Periódico	CiteScore
Scientific Data	6.08
Journal of Cheminformatics	3.98
College and Research Libraries	1.70
Library and Information Science Research	1.70
Communications in Information Literacy	1.44
Journal of the Medical Library Association – JMLA	1.14
Informing Science	1.04
Em busca	0.88
D-Lib Magazine	0.86
Information Research	0.84
Revista Espanola de Documentacion Cientifica	0.83
LIBER Quarterly	0.73
Journal of Information Literacy	0.68
Journal of Information and Organizational Sciences	0.55
Language Documentation and Conservation	0.50

Fonte: Dados da Pesquisa, 2018.

Posteriormente à identificação dos periódicos, partimos para uma visita às homepages dos mesmos, em busca de informações sobre a política de compartilhamento de dados que adotam. Ressalta-se que foram visitadas as abas sobre "Política" e "Guia para autores" de todos esses títulos em busca de informações sobre as políticas ou diretrizes de apoio e incentivo ao compartilhamento dos dados científicos.

4 Resultados

Mediante as informações obtidas, elaboramos o Quadro 2, que relaciona os periódicos que apresentam uma política de compartilhamento de dados – PCD de uma maneira geral, e como se dá esse compartilhamento, se de maneira obrigatória o compartilhamento de dados é inerente ao processo de submissão – ou opcional – o compartilhamento de dados fica a critério do pesquisador, e o periódico apresenta diretrizes para determinada prática.

Conforme exposto no Quadro 2, notamos a existência de periódicos que apresentam a política de compartilhamento de dados, seja essa política obrigatória, ou apenas informa aos autores como proceder com essa prática, de forma flexível, deixando que os mesmos escolham

como conduzir os seus dados. Descreveremos resumidamente de que forma ocorrem ambas as políticas, obrigatória ou flexível.

Observamos que, dentre os 15 periódicos selecionados, oito apresentam políticas e/ou diretrizes sobre o compartilhamento de dados, representando 53%, enquanto que nos outros sete (47%) não foram encontradas informações acerca do assunto. (Gráfico 1).

Quadro 2 – Política de compartilhamento de dados.

Periódico	**PCD**	**Compartilhamento/ Disponibilização**
Scientific Data	X	Obrigatório
Journal of Cheminformatics	X	Obrigatório
College and Research Libraries	-	-
Library and Information Science Research	X	Flexível
Communications in Information Literacy	X	Flexível
Journal of the Medical Library Association – JMLA	X	Flexível
Informing Science	X	Flexível
Information Technology and Libraries	-	-
D-Lib Magazine	-	-
Information Research	-	-
Revista Espanola de Documentacion Cientifica	-	-
LIBER Quarterly	X	Flexível
Journal of Information Literacy	-	-
Journal of Information and Organizational Sciences	X	Flexível
Language Documentation and Conservation	-	-

Fonte: Dados da Pesquisa, 2018.

Dos oito periódicos que apresentam política ou diretrizes para o compartilhamento de dados, duas exigem que os autores compartilhem os dados oriundos de suas investigações, o que corresponde a dois periódicos (22%), e outras seis (seis periódicos, 78%), sugerem em suas diretrizes formas de compartilhamento dos dados científicos, conforme mostra o Gráfico 2.

No que concerne aos dois periódicos que exigem a prática de compartilhamento de dados, observamos que o periódico Scientific Data, hospedado na Nature.com, lidera no ranking do CiteScore da Scopus de 2017. Este periódico apresenta como condição para publicação, a disponibilização de materiais, dados, códigos e/ou protocolos associados à pesquisa (NATURE, 2018).

Nessa mesma perspectiva, o periódico Journal of Cheminformatics, também argumenta que a submissão de um artigo implica que os materiais descritos, incluindo os dados brutos, softwares

e algoritmos relevantes para chegar a conclusão da pesquisa, deverão estar disponíveis (JOURNAL OF CHEMINFORMATICS, 2018.

No que concerne ao incentivo à prática do compartilhamento/disponibilização dos dados de maneira flexível, o periódico Library and Information Science Research, da editora Elsevier, apresenta diretrizes que incentivam a prática do compartilhamento de dados, além de encorajar o depósito dos dados da pesquisa em um repositório de dados relevante e citar/vincular este conjunto de dados em seu artigo (ELSEVIER, 2018).

Por sua vez, o periódico Communications in Information Literacy informa que os dados coletados com a pesquisa podem ser enviados como arquivo suplementar, ficando a critério do pesquisador incluí-los ou não (COMMUNICATIONS IN INFORMATION LITERACY, 2018).

Gráfico 1 – Política de compartilhamento de dados.

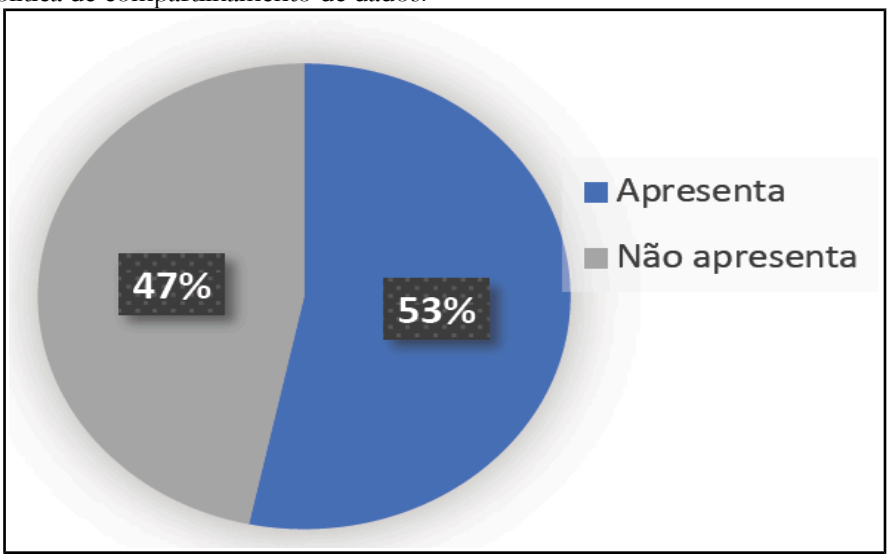

Fonte: Dados da Pesquisa, 2018.

Gráfico 2 – Adoção da política de compartilhamento de dados.

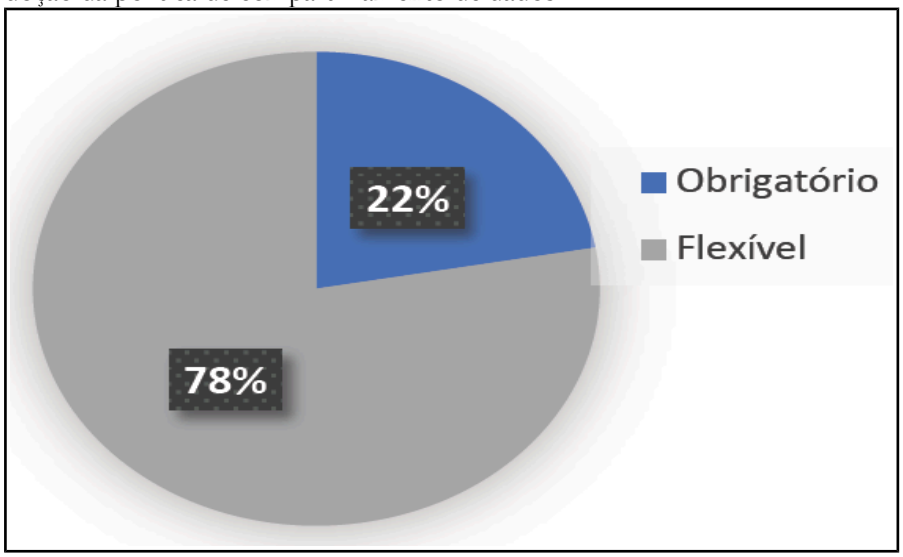

Fonte: Dados da Pesquisa, 2018.

Outro periódico, que também deixa a critério do pesquisador o compartilhamento/disponibilização dos dados é o Journal of the Medical Library Association, o qual recomenda que, ao serem solicitados, os pesquisadores disponibilizem os dados utilizados em sua investigação, além de recomendar que os pesquisadores mantenham esses dados por um período de cinco anos (JOURNAL OF THE MEDICAL LIBRARY ASSOCIATION, 2018).

O Informing Science também deixa a critério do pesquisador compartilhamento/disponibilização dos dados, mas incentiva a prática solicitando que disponibilize os dados aos leitores por meio de um link (inserido no artigo) em que os dados estejam armazenados (INFORMING SCIENCE, 2018).

O periódico LIBER Quarterly argumenta que, quando apropriado, e a critério do pesquisador, os dados devem ser enviados juntamente com o trabalho, e devem ser armazenados no repositório de dados Dataverse Harvard. Recomenda, ainda, que os pesquisadores atribuam um identificador persistente ao conjunto de dados apropriados ao entendimento da pesquisa e o forneçam na elaboração, submissão e publicação do artigo no periódico (LIBER QUARTERLY, 2018).

Por fim, o Journal of Information and Organizational Sciences destaca que a comissão editorial faz uso dos dados para orientar seu trabalho na publicação e aprimoramento do periódico, deixando a critério do pesquisador o seu compartilhamento/disponibilização, de forma que, se o fizerem, o periódico garante a privacidade dos dados, em termos de, violação, acesso, portabilidade, entre outros (JOURNAL OF INFORMATION AND ORGANIZATIONAL SCIENCES, 2018).

Percebe-se que, dentre os periódicos selecionados, 53% apresentam incentivo à prática de compartilhamento de dados, seja de forma obrigatória, ou flexível, deixando que o próprio pesquisador decida o destino de seus dados.

4 Considerações Finais

A política de compartilhamento de dados há de ser amplamente utilizada por periódicos das mais diversas áreas do conhecimento, visando a colaboração entre pesquisadores, o desenvolvimento da comunicação científica, e o progresso da ciência.

Como visto, a prática do compartilhamento de dados nos periódicos de Ciência da Informação, encontra-se em fase inicial, porém com perspectivas de se consolidar, o que vem a corroborar com o fato de que a comunicação científica encontra-se diante de um novo paradigma, ou seja: o compartilhamento/disponibilização dos dados de pesquisa, conforme preconiza a e-Science.

A pesquisa revelou que, dos 15 títulos analisados, oito praticam o compartilhamento/disponibilização dos dados, seja de forma obrigatória ou opcional. Dessa forma, dois periódicos exigem que os autores depositem em repositórios públicos o conjunto de dados utilizados na investigação. Coincidentemente, esses periódicos foram os mais procurados e citados no ano de 2017 pela comunidade científica da Ciência da Informação e lideram o ranking do CiteScore.

Os outros sete periódicos incentivam os pesquisadores a compartilharem seus dados possibilitando seu uso e reúso pela comunidade científica.

Concluímos citando Mueller e Passos (2000, p. 20) que as TDIC possibilitam "[…] um mundo mais justo, em que o acesso à informação [dados] fosse estendido a todos os cantos da Terra, e onde o isolamento dos cientistas do Terceiro Mundo fosse amenizada". Dessa forma podemos afirmar que as TDIC proporcionaram transformações na comunicação científica e que essas transformações continuam em curso e as potencialidades tecnológicas desafiam a transição.

Referências

ANJOS, R. L. **Desvendando as percepções e práticas adotadas pelos pesquisadores dos Programas de Pós-Graduação em Ecologia do Nordeste brasileiro na gestão dos dados científicos**. 2016. 63 p. Trabalho de Conclusão de Curso (Biblioteconomia) – Universidade Federal da Paraíba, João Pessoa, 2016.

COMMUNICATIONS IN INFORMATION LITERACY. **Author Guidelines.** Online. Disponível em: <https://pdxscholar.library.pdx.edu/comminfolit/policies.html>. Acesso em: 25 set. 2018.

ELSEVIER. **Research Data Guidelines**. Online. Disponível em: <https://www.elsevier.com/authors/author-services/research-data/data-guidelines>. Acesso em: 25 set. 2018.

GRAY, J. **eScience**: a transformed scientific method. Palestra apresentada no Conselho Nacional de Pesquisa dos Estados Unidos (NRC-CSTB). Mountain View, Califórnia, 11 jan. 2007. Disponível em: <http://research.microsoft.com/enus/um/people/gray/talks/NRCCSTB_eScience.ppt>. Acesso em 25 set. 2018.

INFORMING SCIENCE. **Article Submission Guidelines.** Online. Disponível em: <https://www.informingscience.org/Journals/InformingSciJ/ArticleSubmission>. Acesso em: 25 set. 2018.

JOURNAL OF INFORMATION AND ORGANIZATIONAL SCIENCES. **Submissions**. Online. Disponível em: <https://jios.foi.hr/index.php/jios/about/submissions#authorGuidelines>. Acesso em: 25 set. 2018.

JOURNAL OF THE MEDICAL LIBRARY ASSOCIATION – JMLA. **Author guidelines**: data retention. Online. Disponível em: <http://jmla.mlanet.org/ojs/jmla/about/submissions#authorGuidelines>. Acesso em: 25 set. 2018.

LIBER QUARTERLY. **Submissions**: author guidelines. Online. Disponível em:<https://www.liberquarterly.eu/about/submissions/>. Acesso em: 25 set. 2018.

MUELLER, S. P. M.; PASSOS, E. J. L. As questões da comunicação científica e a ciência da informação. In: MUELLER, S. P. M.; PASSOS, E. J. L. (Orgs.). **Comunicação científica**. Brasília: Departamento de Ciências da Informação e Documentação da UnB, 2000, 144p.

NASSI-CALÒ, L. Movimento Open Data se consolida internacionalmente. **SciELO em Perspectiva**, 2014. Disponível em: <http://blog.scielo.org/blog/2014/07/14/movimentoopen-data-se-consolida-internacionalmente/>. Acesso em: 25 set.2018.

NATURE. **Authors e referees**: Availability of data, material and methods. Online. Disponível em: <http://www.nature.com/authors/policies/availability.html>. Acesso em 25 set. 2018.

SAYÃO, L. F.; SALES, L. F. Dados abertos de pesquisa: ampliando o conceito de acesso livre. **Revista Eletrônica de Comunicação, Informação e Inovação em Saúde,** Rio de Janeiro. v. 8, n. 2, p. 76-92, 2014.. Disponível em: <http://www.reciis.icict.fiocruz.br/index.php/reciis/article/view/611/1252>. Acesso em: 26 set. 2018.

TARGINO, M. G. A região geográfica como fator interveniente na produção de artigos de periódicos científicos. In: MUELLER, S. P. M.; PASSOS, E. J. L. (Orgs.). **Comunicação científic**a. Brasília: Departamento de Ciência da Informação da Universidade de Brasília, 2000. p. 51-72.

Vídeo da apresentação

Título: Política de compartilhamento de dados científicos: a adoção nos periódicos da Ciência da Informação.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=46

Transcrição da apresentação

Oi, boa tarde. Eu vou apresentar o trabalho intitulado Política de compartilhamento de dados científicos: A adoção nos periódicos da Ciência da Informação. Eu sou a Renata, sou mestranda aqui do Programa de Pós-Graduação em CI, e o artigo foi feito junto com a professora Marynice.

Em 1665 foram publicados os primeiros periódicos científicos, Philosophical Transactions of the Royal Society na Inglaterra e o Journal des Sçavans na França, então desde essas publicações, a comunicação científica direciona prioritariamente apenas os resultados das publicações, e a gente sabe que para se chegar nos resultados, a gente percorre um longo caminho que seriam os dados, a gente coleta dados, a gente gera dados, a gente analisa para depois publicar como resultado, mas, na verdade, é apenas o resultado que vai nos artigos finais.

E com a emergência das Tecnologias Digitais de Informação e Comunicação, a comunicação científica ela vem passando por transformações, como inicialmente a gente tem periódicos no cenário impresso, depois foram adaptados os periódicos eletrônicos, em que a gente acessa por smartphone, tablets, computadores, que é onde nós temos o cenário das publicações ampliadas, que é feito por ligamentos, você pode colocar localização, você vai navegando.

Então diante disso a comunicação científica encontra-se imersa no caminho da e-Science como o quarto paradigma científico. A e-Science consiste no uso e intensivo compartilhamento desses dados , isso em todo o processo científico.

Fundamentando-se nisso alguns periódicos, já começam a incentivar essa prática do compartilhamento de dados, professor Sayão ontem falou aqui dos periódicos de artigos de dados negativos, que são dados de experiências que deram errado mas com a importância deles serem compartilhados caso os pesquisadores querem fazer o mesmo experimento já economiza tempo, e assim por diante. Então da mesma forma está havendo incentivo no compartilhamento de dados.

O artigo objetivou em analisar essa adoção da prática de compartilhamento de dados no cenário dos periódicos da ciência da informação. É uma pesquisa exploratória e documental com análise qualitativa. A gente selecionou os periódicos da área de biblioteconomia e ciência da informação na base de dados Scopus e nós definimos como amostra deste universo aqueles periódicos com CiteScore acima de 0.50, esse CiteScore é uma média feita entre a quantidade de citações do ano, que o último ano foi 2017, em relação aos documentos publicados nos últimos três anos, ou seja, 2014, 2015 e 2016, a gente tem essa média que é o CiteScore.

Então nós tivemos 15 periódicos com CiteScore acima de 0.50. Definido esse universo, a gente visitou o local de cada um desses periódicos procurando se tem política de compartilhamento de dados, algum guia de compartilhamento de dados, ou diretrizes.

Desses 15 a gente teve que 53% apresentam alguma forma de política de compartilhamento de dados enquanto 47% não apresentam. Entre os que apresentam nós tivemos que o compartilhamento em 22% é de forma obrigatória, e nos outros 78% é de forma flexível, que a gente vai ver mais a frente como funciona.

Coincidentemente ou não, os dois periódicos que tem o maior CiteScore são os que tem a política de compartilhamento de dados de forma obrigatória, Scientific Data apresenta como

condição para publicação, a disponibilização de materiais, dados e códigos e/ou protocolos associados à pesquisa, então para publicar você precisa disponibilizar tudo o que você disponibilizou durante a pesquisa. Este outro periódico Journal of Cheminformatics, também argumenta que a submissão de um artigo implica que os materiais descritos, incluindo os dados brutos, softwares e algoritmos relevantes para chegar a conclusão da pesquisa, deverão estar disponíveis.

E aqui estão os outros que se dão de forma flexível mas que de alguma forma eles incentivam a prática do compartilhamento de dados. Aqui eles incentivam a prática de compartilhamento de dados encorajando o depósito dos dados no repositório, aqui eles falam que você pode enviar o artigo final e o artigo suplementar informando como você fez todo o processo com os dados, nesses aqui eles dizem que você tem que manter seus dados por cinco anos, porque se um usuário do periódico entrar em contato com você, você tem que disponibilizar os dados para ele, se não você tem que manter por no mínimo cinco anos. Aqui ele manda você linkar no artigo publicado ao conjunto de dados, para que os usuários também tenham acesso a estes dados. Aqui ele comenta que a comissão editorial também pode fazer uso do conjunto de dados caso você compartilhe para aprimorar o periódico e além de você quiser compartilhar os dados com o periódico, o periódico vai garantir a privacidade em termos de violação, acesso e portabilidade. Esse recomenda que você deposite os dados em um repositório Dataverse, que inclusive foi a oficina oferecida aqui na segunda feira falando sobre o Dataverse, além do identificador persistente que sempre vai acompanhar este conjunto de dados.

Por fim a gente pode que a prática de dados ela é nos periódicos da ciência da informação está em fase inicial, a gente já vê algumas revistas que são obrigatório e outras que estão de alguma forma incentivando. As referências utilizadas na apresentação e é isso.

Obrigada.

Slides da apresentação

Título: Política de compartilhamento de dados científicos: a adoção nos periódicos da Ciência da Informação.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=46

Métodos multicritérios para auxiliar o processo de tomada de decisão sobre empreendimentos imobiliários utilizando modelos BIM

Bárbara Carvalho Diniz[a], Guilherme Ataíde Dias[b] e Alzira Karla Araújo da Silva[c]

Resumo: O presente trabalho apresenta a utilização de informações obtidas em modelos de informações da construção (Building information Modeling – BIM) e a avaliação de empreendimentos imobiliários, em uma estrutura multicritérios. As informações sobre os possíveis projetos de construção, reforma, ampliação, aquisição, ou aluguel de edificações são utilizadas para viabilizar um processo de tomada de decisão. Os modelos funcionam como uma base para a representação digital de dados ou informações de uma construção e trazem diversas possibilidades de análise. Assim, a análise multicritério classifica os empreendimentos imobiliários representados como modelos BIM. A hierarquização do problema envolve as relações entre metas, critérios que expressam metas e alternativas. A análise comparativa entre os critérios considerados e a interação com os elementos que compõem os modelos de projetos de construção proporcionou a execução prática de um problema que interliga dados de ambientes distintos com um método de análise multicritérios. A avaliação de viabilidade do processo construtivo reforça a necessidade de expansão da metodologia e da amostra, para se definir os elementos que compõem a tomada de decisão no setor de empreendimentos imobiliários.

Palavras-chave: Métodos Multicritérios; Analytic Hierarchy Process (AHP); Modelagem de Informações da Construção; Building Information Modeling (BIM).

Multicriteria methods to aid the decision-making process on real estate projects using BIM models

Abstract: This work presents the development of a multicriteria method to evaluate real estate projects based on information retrieved from Building Information Modeling (BIM). Information on possible construction, renovation, expansion, acquisition or rental of buildings is used to enable a decision-making process. The models work as a basis for the digital representation of data or information of a construction and bring diverse possibilities of analysis. Thus, the proposed method classifies the real estate ventures represented as BIM models. Complex problems in a hierarchical structure involve relationships between goals, criteria that express goals, and alternatives. Given this complexity, the proposed analysis method evaluates hierarchical structures expressed from objectives, or criteria, and alternatives. Thus, the Analytic Hierarchy Process (AHP) is used, which occurs at successive levels, beginning with the construction of hierarchies, followed by the definition of priorities and finally a verification of the logical consistency in order to arrive at a comparative result between the alternatives.

Keyword: Multicriteria Methods; Analytic Hierarchy Process (AHP); Building Information Modeling (BIM).

a Universidade Federal da Paraíba (UFPB). E-mail: dinizbarbara6@gmail.com. Currículo: http://lattes.cnpq.br/1170521418066570

b Universidade Federal da Paraíba (UFPB). E-mail: guilhermeataide@ccsa.ufpb.br. ORCID: https://orcid.org/0000-0001-6576-0017. Currículo: http://lattes.cnpq.br/9553707435669429

c Universidade Federal de Minas Gerais (UFMG). E-mail: alzirakarlaufpb@gmail.com. ORCID: https://orcid.org/0000-0003-3499-2530. Currículo: http://lattes.cnpq.br/9118083826048075

1 Introdução

Com a constante demanda por utilização de novos espaços e tendo em vista a disponibilidade de ativos imobiliários, o gerenciamento de informações pode ser muito útil no processo de tomada de decisão na área de Arquitetura, Engenharia e Construção (AEC).

Novos projetos imobiliários envolvem diversas atividades como aquisição, construção, ampliação, reforma ou aluguel de edificações. Assim, a decisão acerca de qual empreendimento realizar deve ser pautada na elaboração de projetos com os adventos tecnológicos utilizados desde sua concepção, podendo ser beneficiada com a melhoria da Gestão de Projetos em todas suas fases.

Os atuais recursos de Tecnologia da Informação e Comunicação (TIC) permitem que os processos de elaboração de projeto ou desenho assistido por computador (Computer-Aided Design – CAD), incorporem diversos recursos informacionais, indo muito além de um simples uso de computadores como ferramentas gráficas para a criação de desenhos técnicos.

Nesse contexto, além de fornecer ferramentas para a representação de formas geométricas utilizando como base a tecnologia CAD, o processo conhecido como modelagem de informações da construção (Building Information Modeling – BIM) procura otimizar a elaboração de projetos de construções.

Para Chiavenato (2004), o planejamento possibilita a determinação antecipada das atividades que devem ser desempenhadas, dos objetivos serão alcançados e auxilia as organizações a se organizarem para atingirem as metas pretendidas.

Novas ferramentas que se baseiam em desafios de projetos em geral, tais como orçamentos, prazos e excelência do produto, podem auxiliar as organizações a obterem melhores resultados e à aproximação do objeto executado ao proposto no planejamento inicial.

De acordo com o Instituto de Gerenciamento de Projetos (Project Management Institute – PMI)[6], "o Gerenciamento de Projetos é a aplicação de conhecimentos, habilidades e técnicas para a execução de projetos de forma efetiva e eficaz." As informações dos modelos utilizados, preenchidas durante todo o ciclo de vida dos projetos, fornece e define um ciclo de vida dos dados, o que possibilita a avaliação de importâncias em momentos distintos.

A identificação de informações de várias fontes externas e internas a projetos da área de AEC possibilita a inclusão de dados nos modelos digitais gerados para representar esses projetos (modelos BIM). Destes modelos foram considerados três para a estruturação dos problemas de forma hierárquica. A análise dos critérios, então, demonstra uma dentre as possibilidades de se chegar a uma solução desejada, baseada em comparações par-a-par entre eles, de um processo que por vezes se torna imprescindível para a tomada de decisão.

6 Project Management Institute – PMI. Disponível em: <https://brasil.pmi.org/>. Acesso em: 10 set. 2018.

2 Objetivos

O objetivo deste trabalho é viabilizar a utilização da modelagem de informações da construção (BIM) em um processo de tomada de decisão em empreendimentos imobiliários por meio de uma análise multicritérios. O método de análise a ser adotado utiliza a identificação dos elementos que compõem a estrutura de decisão e pretende realizar uma comparação das possíveis alternativas de projetos da área. Considera-se os dados sobre empreendimentos dos modelos BIM como premissa para a automação do preenchimento de alguns critérios de análise exigidos pelo método. É esperado, ainda, avaliar os resultados obtidos com relação ao processo decisório e verificar a viabilidade de continuidade da pesquisa, com melhorias e ajustes no método, bem como sua aplicação a outros cenários.

3 Procedimentos Metodológicos

3.1 Métodos Multicritérios

A modelagem de problemas complexos em uma estrutura hierárquica envolve as relações entre metas, critérios que expressam metas e alternativas. A estrutura hierárquica expressa a partir do objetivo ou objetivo para os critérios e alternativas em níveis sucessivos (SAATY & VARGAS, 2001).

O método utilizado possui três princípios para sua aplicação. A construção de hierarquias, em que o problema é estruturado em níveis hierárquicos e é um passo fundamental para compreendê-lo. A definição de prioridades, que se baseia na capacidade de perceber as relações entre objetos e situações diversas. A comparação entre os pares de critérios e a consistência lógica, em que o Analytic Hierarchy Process (AHP) permite avaliar o modelo de priorização construído quanto à sua consistência, fazendo uso de conceitos matemáticos, principalmente princípios e propriedades de matrizes.

Para este trabalho, optou-se por um método de análise multicritério que fosse do domínio dos autores, possibilitando a execução e para a avaliação da viabilidade da pesquisa. Uma vez considerada executável e viável, os dados provenientes das entrevistas não estruturadas vão ser relacionados entre si e entre as informações ou os critérios advindos dos modelos BIM. Isso permite a construção e a triangulação das evidências traduzidas pelo estudo de caso, apresentado em trabalhos anteriores (BONATTI; BARACHO; 2015, 2016).

A descrição e as etapas de cálculos estão descritas nestes trabalhos. A definição de prioridades entre os critérios é realizada entre os elementos da hierarquia identificada. São geradas as matrizes de julgamento (sempre matrizes quadradas), onde o número na linha i e na coluna j dá a importância do critério Ci em relação à Cj. A importância relativa entre os elementos visa minimizar a inconsistência da elaboração das matrizes de julgamento. O grau de inconsistência reflete a adequação dos julgamentos realizados pelos gestores e um grau máximo é estipulado, também descrito nos trabalhos anteriores.

3.2 Recuperação da Informação em Ambiente BIM

O processo tecnológico conhecido como modelagem de informações da construção (BIM) surgiu com a evolução das aplicações gráficas voltadas para a geração de desenhos técnicos (CAD) ocorrida na década de 1990. Essa nova forma de se projetar, ou melhor, de modelar as

informações de uma construção, bem a aplicação de soluções CAD à indústria de AEC são amplamente discutidas em trabalhos como Eastman et al. (2005) e Björk e Laakso (2010). Algumas das principais características, recomendações e formas de uso das diversas tecnologias associadas ao BIM, ou simplesmente tecnologia BIM, podem ser obtidas em Eastman et al. (2011) e em Porto et al. (2015), em que é apresentado um detalhamento das características e recomendações para a implantação e melhor aproveitamento dessa tecnologia. O BIM também é amplamente discutido em trabalhos como os de Jacoski (2003 e 2008), Flemming et al. (2004), Isikdag e Underwood (2009), Pereira Junior e Baracho (2015) e Laiserin (2018), e pode ser considerado um novo padrão da indústria, assim como aconteceu com a tecnologia CAD.

Com o uso da tecnologia BIM, todas as informações necessárias em um projeto de construção ficam contidas em um modelo digital ou virtual, e ela pode ainda ser utilizada na automação da apresentação de documentos, melhorando aspectos como a construtibilidade, a análise de conflitos, o planejamento, a elaboração de cronogramas (4D), a análise de custos e orçamentação (5D), entre outros. Vale ressaltar que o ciclo de vida do processo de BIM abrange toda a vida útil de uma edificação ou construção, conforme mostrado na Fig.1, retirada de Mello (2012).

Figura 1 – Processo BIM.

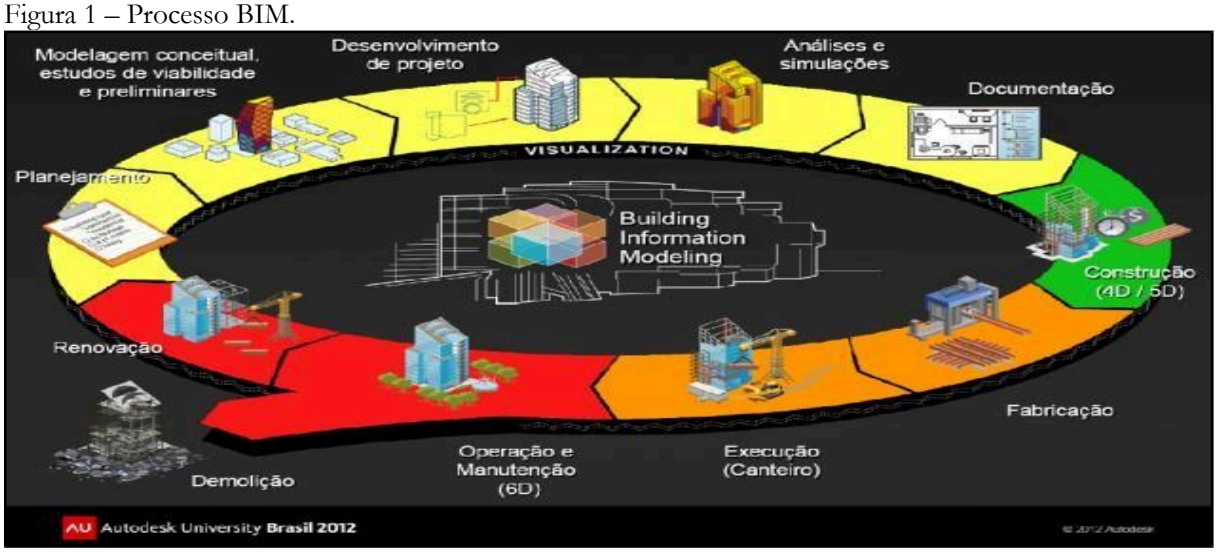

Fonte: Mello, 2012.

O BIM pode ser entendido como a tecnologia responsável pela gestão de uma enorme quantidade de informações relativas às construção, sendo também um grande repositório de informações. Nesse contexto, o uso da tecnologia BIM no mundo traz desafios e oportunidades para a realidade brasileira (WATSON, 2011; BRYDE et al., 2013). Essa tecnologia também já está se consagrando e ganhando destaque como ferramenta para elaboração e gestão de projetos de Arquitetura e Engenharia no Brasil (PORTO et al., 2015; PEREIRA JUNIOR; BARACHO, 2015).

Os softwares BIM são executados em plataformas ou ambientes de CG e utilizam diversos recursos de TIC para permitir a manipulação de modelos digitais de uma edificação ou construção. Esses softwares utilizam as representações digitais multidimensionais e paramétricas,

bem como, intrinsecamente, os paradigmas da programação orientada a objetos (POO), que é uma tecnologia para programação de computadores em que "objetos" são os elementos fundamentais que representam as entidades envolvidas no sistema. Mais detalhes sobre a POO podem ser obtidos em trabalhos como o de Gamma et al. (2000). A Fig.2 apresenta um modelo BIM criado com o uso do software Revit.

Muitos dos softwares que utilizam a tecnologia BIM também oferecem ferramentas para se estender suas funcionalidades, mediante a criação de novas interfaces dentro de seus ambientes (aplicativos de extensão conhecidos como plug-ins ou add-ins), aumentando ainda as capacidades do BIM.

Esses aplicativos de extensão podem ser desenvolvidos com vistas a acessar, via código-fonte, os componentes paramétricos dos modelos BIM, que representam as partes construtivas, e com isso recuperar informações úteis em diversos contextos. Assim, as informações contidas nos modelos BIM permitem diversas análises, como a proposta neste trabalho.

Figura 2 – Modelo BIM com Componente Construtivo ("família de parede") Selecionado.

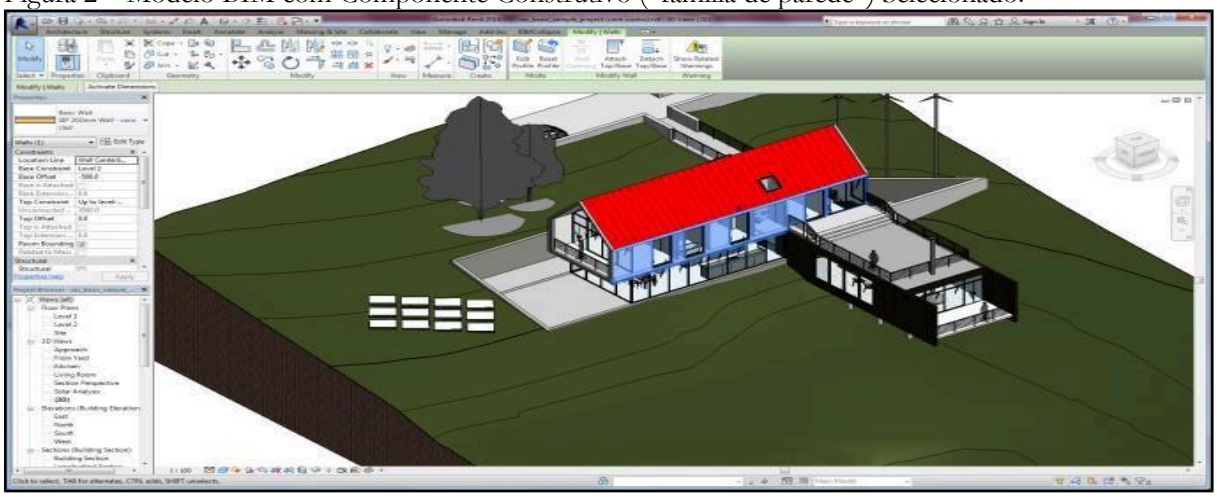

Fonte: Autores.

A Figura 3 mostra um protótipo desenvolvido para ler dados de um modelo BIM e preparar um orçamento global da obra com base nos custos de cada componente construtivo.

Figura 3 – Aplicativo de Extensão Criado para Calcular o Orçamento de um Modelo BIM

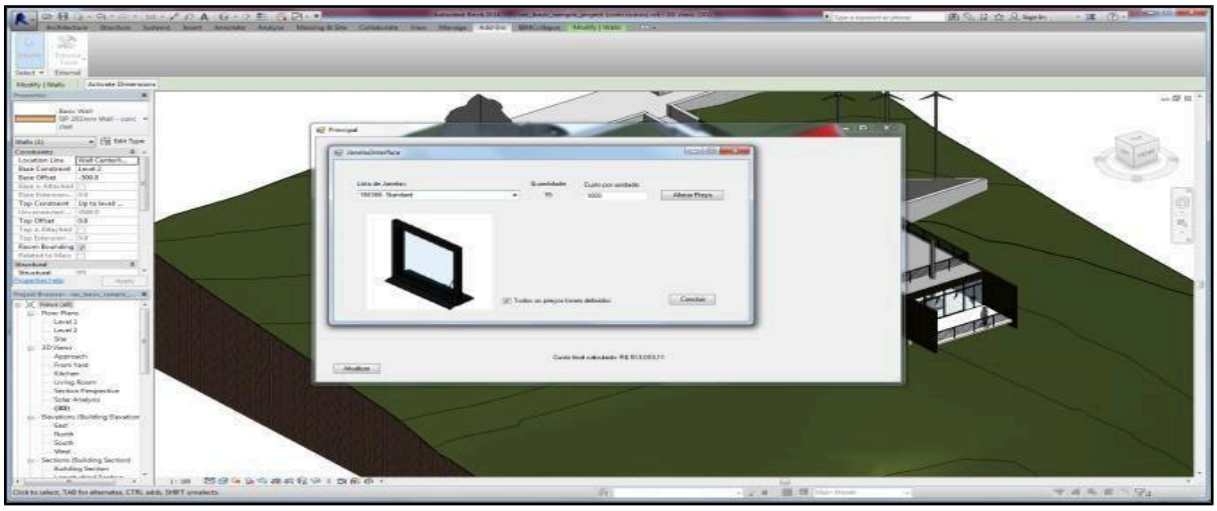

Fonte: Autores.

Nota-se que a elaboração de soluções computacionais para problemas de Engenharia utilizando a tecnologia BIM pode se associar ao uso de diversas ferramentas e metodologias. Alguns trechos de códigos-fonte, úteis para o desenvolvimento de aplicativos de extensão para o software Revit, se encontram disponibilizados em páginas da internet, como Tammik (2018).

Tendo em vista esses exemplos, pretende-se desenvolver futuramente um aplicativo de extensão para recuperar automaticamente informações dos modelos BIM e alimentar o os critérios a serem utilizados pelo software que implementa a análise multicritérios proposta. Nessa análise, cada modelo BIM, que se refere a um empreendimento, é então avaliado de acordo com uma comparação feita por especialistas da área.

4 Resultados

As informações contidas no contexto de um processo e de modelos BIM, recuperadas a partir de funcionalidades presentes em uma ferramenta ou software, foram insumos para a execução e o resultado apresentado. Com o uso destas informações, o método multicritérios permitiu a análise comparativa entre os critérios considerados e foram considerados três cenários de projetos. Também foi realizada uma avaliação dos resultados obtidos.

4.1 Análise Multicritério

Os critérios foram definidos a partir das informações extraídas dos modelos BIM acrescidos de outros, baseados em considerações de respondentes especialistas do setor de AEC. A avaliação desses critérios e o cálculo de consistência permitem organizar os resultados de cada um dos respondentes. Para a execução, as matrizes de julgamento são processadas, e tal processo define a prioridade de um empreendimento em detrimento aos demais.

4.2 Definição dos Critérios

Em um ambiente BIM, alguns critérios podem ser obtidos automaticamente a partir dos modelos. Além, foram considerados critérios subjetivos, por exemplo, a intenção do gestor de empreender projetos em determinada área ou que utilize certos materiais ou mesmo que ele julgue ter mais expertise para executar. Assim, foram propostos os seguintes critérios: C1: Custo

global da obra ou do empreendimento: critério objetivo, obtido com base no modelo BIM; C2: Nível de detalhamento do projeto/modelo: este critério utiliza uma escala própria dos modelos, mas normas BIM podem ser aplicadas; C3: Complexidade do modelo: considera-se algumas variáveis internas do modelo BIM, como tipo e quantidade de materiais e existência de componentes com geometria curva. Outras variáveis externas, como tipo de terreno, tipo de fundação e agressividade do ambiente também poderiam ser adotadas; C4: Maturidade da organização com relação ao uso do BIM: não possui um valor especificado, pois avalia aspectos como a experiência da organização empreendedora, a quantidade de profissionais treinados e a existência de software apropriado; C5: Experiência do empreendedor: critério que considera o interesse pessoal/organizacional pelo empreendimento.

4.3 Avaliação

Os dados criados para avaliar o modelo proposto são dados computacionais, uma vez que a entrada de dados foi definida a partir de modelos criados para testes e os resultados foram obtidos a partir de simulações utilizando o software Revit, para os modelos BIM. Os três empreendimentos a serem avaliados são A1: projeto de uma casa com dois pavimentos a ser reformada. O nível de detalhamento do modelo BIM é muito baixo. Materiais padrão foram adotados e a geometria modelada é apenas aproximada, mas o custo é bem baixo; A2: projeto de uma nova edificação com cinco pavimentos. O nível de detalhamento do modelo BIM é mediano e a especificação é de materiais de referência, mas as geometrias refletem a realidade, devendo, portanto, haver poucas mudanças durante a execução. Entretanto não foi feita a atribuição de custos, e existe um limite de orçamento; A3: projeto de nova casa com dois pavimentos. O modelo BIM possui nível de detalhamento bastante alto, com cobertura total de componentes construtivos. A especificação de materiais reflete exatamente o que deve ser executado e foi feita a atribuição de custos a todos componentes, porém, o custo executivo foi o mais alto entre os projetos.

A partir deste cenário, um especialista participou da simulação. Com escala de conformidade de valores (1 – igual, 2 – pouco mais importante, 3 – mais importante e 5 – muito mais importante), chegou-se à matriz.

Tabela 1 – Correlação entre Critérios.

C1	**C2**	**C3**	**C4**	**C5**
1	2	3	1/3	1/2
1/2	1	3	1/2	1
1/3	1/3	1	2	3
3	2	1/2	1	1
2	1	1/3	1	1

Fonte: Autores.

A matriz reflete as comparações de pares. Para exemplificar, em um objetivo global (novo empreendimento), o custo (C1) é quanto importante em relação ao detalhamento do modelo BIM (C2)?

Assim, as importâncias (ponderação) dos critérios são determinadas em relação ao objetivo. Denomina-se a Prioridade Global a normalização desta matriz e, seguindo os passos metodológicos, define o vetor de prioridade global (VPG).

Definem-se então as importâncias dos critérios em relação às alternativas. A Prioridade Média Local (PML), gerando sua matriz correspondente. A normalização e o procedimento metodológico definem os vetores de PMLs.

Tabela 2 – Exemplo de Correlação entre Alternativas de Empreendimentos (C1)

A1	**A2**	**A3**
1	2	5
1/2	1	3
1/5	1/3	1

Fonte: Autores.

O somatório da multiplicação das PMLs pelo VPG é a última etapa do cálculo definido pela análise e gera o resultado que define a Prioridade Global, como se segue.

A prioridade global reflete a importância dada aos critérios envolvidos em relação ao objetivo global e em relação às alternativas, expressando em números as considerações dos respondentes.

Figura 4 – Resultados da Análise.

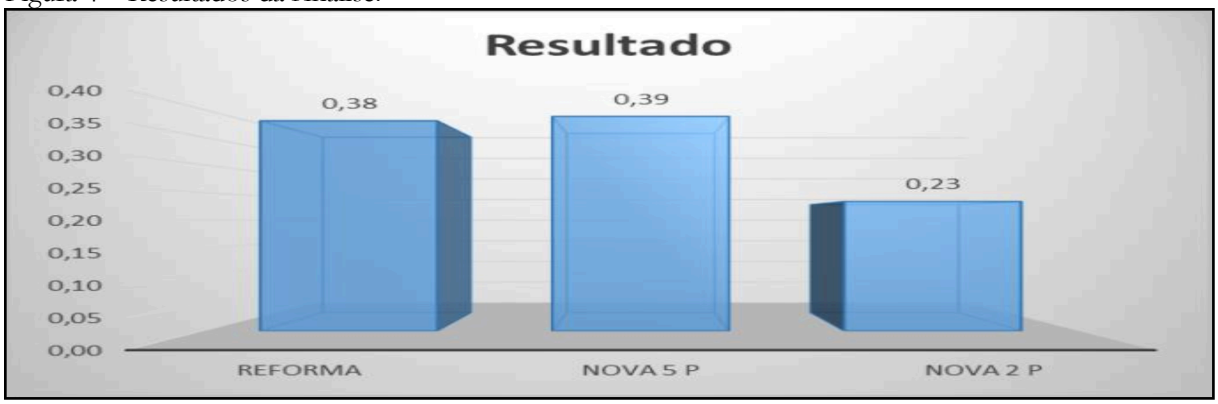

Fonte: Autores.

5 Considerações Finais

No contexto informacional, o BIM funciona como uma base para a representação digital de dados ou informações de uma construção, não sendo apenas um desenho ou projeto estático.

Os modelos representam os componentes dos sistemas construtivos de forma dinâmica, podendo se interligar a diversos outros repositórios ou sistemas de informação.

O método proposto apresenta uma forma de se explorar o potencial do BIM em conjunto com uma avaliação subjetiva, adotando critérios intangíveis. As análises realizadas verificaram o funcionamento do método, mas ressalte-se que foram utilizados dados computacionais, gerados ou obtidos com base em modelos criados especificamente para testes. Com isso sugere-se como trabalho futuro que os dados de entrada dos modelos sejam adaptados à realidade de possíveis

utilizadores desse método, que devem avaliar os resultados e calibrar as entradas de acordo com as particularidades de suas organizações.

Referências

CHIAVENATO, Idalberto. **Administração nos novos tempos.** 2. ed. Rio de Janeiro: Elsevier, 2004.

BONATTI, R. A.; BARACHO, R.M.A.; BARACHO, F. R. A. C.; PESSANHA, C. P.; REZENDE, M. M. S.; LIMA, F. B.; SILVA, C. H. F. **Análise de projeção e viabilidade técnica de novos empreendimentos para geração de energia elétrica.** Anais… Enancib 2016, 2016.

BONATTI, R. A., BARACHO, R. M. A. **A gestão da informação e o processo decisório no setor energético:** mensuração de critérios e alternativas. *Pesquisa Brasileira em Ciência da Informação e Biblioteconomia*, v. 10, p. 237-249, n. 2015.

BJÖRK, B-C., LAAKSO, M., **CAD standardisation in the construction industry** – A process view. Automation in Construction. v.19, n.4, 398-406 pp, 2010.

BRYDE, D., BROQUETAS, M., VOLM, J.M., **The project benefits of Building Information Modelling (BIM)**, International Journal of Project Management. Volume 31, Issue 7, Pages 971-980, 2013. ISSN 0263-7863.

EASTMAN, C. M., WANG, F., You, S. -J., Yang, D., **Deployment of an AEC industry sector product model.** Computer-Aided Design. v.37, n.12, 1214-1228 pp, 2005.

EASTMAN, C. M., TEICHOLZ, P., SACKS, R., LISTON, K., **BIM Handbook:** A Guide to Building Information Modeling for Owners, Managers, Designers, Engineers, and Contractors – Second Edition. John Wiley & Sons, New Jersey. 2011.

FLEMMING, U., ERHAN, H., ÖZKAYA, I., **Object-oriented application development in CAD:** a graduate course. Automation in Construction. v.13, 147-158 pp, 2004.

GAMMA, E., HELM, R., JOHNSON, R., VLISSIDES, J., **Padrões de Projeto: Soluções Reutilizáveis de Software Orientado a Objetos**. Porto Alegre, RS: Bookman. 363p. Trad.: Salgado, L. A. M., 2000.

ISIKDAG, U., UNDERWOOD, J., **Two design patterns for facilitating Building Information Model-based synchronous collaboration**, Automation in construction, 2009.

JACOSKI, C. A., **Integração e Interoperabilidade em Projetos de Edificações** – uma implementação com IFC/XML. 2003. 217f. Tese (Doutorado em Engenharia de Produção e Sistemas) - Universidade Federal de Santa Catarina. Florianópolis, SC, Brasil, 2003.

____, A Integração da Comunicação em Projetos de Construção Utilizando Tecnologias da Informação. In: Conferência Construção, Portugal. FEUP-Porto/Portugal, 2004.

____, O Intercâmbio de Dados entre SIG e Projetos de Edificações – A Busca pela Interoperabilidade, Universidade Comunitária Regional de Chapecó. 2008. Disponível em <http://claudio.jacoski.googlepages.com/artigo_jacoski_sigac.pdf>. Acesso em 23 mar. 2017.

LAISERIN, J., **The BIM Page**, The Laiserin Letter. 2018. Disponível em: <http://www.laiserin.com>. Acesso em 29 set. 2018.

MELLO, R., **BIM e Custos:** maximize os dados do modelo com o Navisworks e o Quantity Takeoff. Autodesk University Brasil, 2012. Disponível em: <http://static-wd.autodesk.net/content/dam/au/Brasil-2014/documents/materialapoio/2012/AUBR-44_Apostila.pdf>. Acesso em: 29 set. 2018.

PEREIRA JUNIOR. M. L., BARACHO, R. M., **Relações entre a Gestão da Informação e do Conhecimento e Uso de Sistema BIM por Arquitetos e Engenheiros.** 4ª Seminário Ibero-americano Arquitetura e Documentação. Belo Horizonte, 2015.

PORTO, M. F., FRANCO, J. R. Q., BARACHO, R. M. A., **Paradigma de Utilização da Tecnologia BIM para Projeto Arquitetônico e de Engenharia.** 4ª Seminário Ibero-americano Arquitetura e Documentação. Belo Horizonte, MG, Brasil. 2015.

SAATY, T. L.; VARGAS, L. G. **Models, Methods, Concepts & Applications of The Analytic Hierarchy Process.** Boston: Kluwer Academic Publishers. 2001.

TAMMIK J., **The Building Coder.** Blogging about the Revit API. 2018. Disponível em: <http://thebuildingcoder.typepad.com>. Acesso em 29 set. 2018.

WATSON, A., **Digital buildings** – Challenges and opportunities, Advanced Engineering Informatics, Volume 25, Issue 4, Pages 573-581, 2011. ISSN 1474-0346.

Vídeo da apresentação

Título: Métodos multicritérios para auxiliar o processo de tomada de decisão sobre empreendimentos imobiliários utilizando modelos BIM.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=47

Transcrição da apresentação

Boa tarde pessoal, eu também sou aluno do professor Guilherme, da disciplina que ele deu na UFMG, e juntei com outros colegas, juntei com o Rogério que está cursando o doutorado em ciência da informação, eu faço engenharia mas estou tentando mudar o meu programa, e a professora Renata Baracho que é orientadora dele e potencial orientadora minha nessa transição.

Então, a gente juntou estes métodos multicritérios que eles já estavam estudando na ciência da informação e trouxemos isso para a realidade de empreendimentos imobiliários onde se utiliza essa tecnologia chamada BIM que é de modelação de informação da construção para avaliar alguns empreendimentos, tirando um pouco da subjetividade desse projeto.

Na introdução a gente fala um pouco do que seria o BIM, sobre a área de arquitetura, engenharia e construção, e projetos neste conceito que nós estamos estudando, ampliação, construção, empreendimento imobiliário como um todo.

Então as Tecnologias de Comunicação e Informação ligadas a estes projetos, tem duas tecnologias que interessam a gente, uma tecnologia um pouco mais antiga que é o CAD que já está bem consagrado que é você simplesmente pegar um espaço no gráfico e fazer projetos, desenhos no computador, você pode agregar também a tecnologia CAD mais informação, e hoje em dia tem um novo conceito no processo que é conhecido como modelagem de informações na construção, que é onde você utiliza a base CAD e agrega diversas informações ao seu modelo. Ainda na introdução a gente fala um pouco que se aplica ao mercado de arquitetura, engenharia e construção.

A metodologia multicritério utilizada ela estrutura um problema hierarquicamente através de três modelos, é realizado uma análise entre os critérios adotados para avaliar cada alternativa, podendo auxiliar no processo de tomada de decisão. Inicialmente esta análise era mais subjetiva, a gente está tentando trazer alguns critérios um pouco mais objetivos para direcionar as decisões, e viabilizar a utilização do BIM nessa avaliação de alternativas de investimento, então a gente tem que identificar os elementos que compõem esta estrutura de decisão que o método trabalha e comparar com possíveis alternativas de projetos nessa área.

Então o objetivo do trabalho é basicamente recuperar dados sobre empreendimentos imobiliários a partir de modelos BIM, automatizar o preenchimento de alguns critérios de análise que vão subsidiar esse método, avaliar os resultados obtidos, e verificar a viabilidade de continuidade desta pesquisa, quem sabe virar uma proposta de projeto, ajustes e melhorias do método para aplicação em outros cenários, viabilização do uso do BIM no processo de tomada de decisã.

Como procedimento tecnológico proposto foi seguir este método multicritério, AHP – Analytic Hierarchy Process ele têm três princípios para publicação, a construção das hierarquias para efetuar o problema, depois define as prioridades com base comparativa programática, ele é basicamente um método que utiliza umas comparações de correlação entre as alternativas utilizando matrizes. Se você compara um critério em relação ao outro e cada alternativa relacionada a cada critério.

É feito uma contextualização então do BIM, do histórico do BIM, como ele surgiu a partir do CAD, o que é possível fazer com ele, você pode melhorar aspectos de confiabilidade, pode

identificar conflitos nos projetos de edificação por ordem, melhora o planejamento fazendo cronograma utilizando os modelos, orçamentação dos modelos antes de começar a construir, elaborando todo o ciclo de vida de uma construção.

Aqui está uma figura clássica onde esse processo de modelação de processo de construção, desde a concepção até uma eventual demolição ou reforma. Então a ideia é recuperar informações do modelo para fomentar essa análise.

Então basicamente, os softwares BIM ele tem API's que permitem você entrar nos modelos e obter as informações, então esse aqui é um exemplo de como isso é feito, este aqui é um aplicativo desenvolvido utilizando um software livre. A proposta é desenvolver um aplicativo para poder implementar essa metodologia, a análise aqui não teve esse desenvolvimento, a gente extraiu os dados a partir dos modelos mas sem automatizar essa parte, a gente simulou isso analisando os critérios colocando peso com o que obtém relativamente nos modelos BIM. Então as informações contidas no modelo elas vão alimentar alguns critérios e depois nós vamos analisar os resultados. Então foram definidos estes critérios, lembrando que foi mantido um pouco do caráter subjetivo, porque ele pede os critérios que são gerados através do modelo BIM e coloca peso e realiza uma análise em cima deles. Então nós definimos neste artigo esses cinco critérios, custo global da obra ou do empreendimento, nível de detalhamento do projeto/modelo, complexidade do modelo, maturidade da organização com relação ao uso do BIM, sendo esses dois últimos os mais subjetivos, com relação ao uso do BIM, dependendo da organização que utilizar o BIM este critério pode ter uma nota mais alta, e a experiência do empreendedor a gente considerou critério.

Estou pegando os três projetos para simular isso, uma casa com dois pavimentos, com um nível de detalhamento mais baixo, com um custo também mais baixo porque é mais simples, projeto de uma nova edificação com cinco pavimentos com um nível de detalhamento médio, com especificação média para a gente pegar de referência não tão detalhado e o terceiro modelo mais detalhado, com materiais exatamente que vão ser construídos, utilizados na construção, então a gente simulou isso.

Com relação a cada critério, primeiro ele pondera o que ele entende dos critérios, a escala de conformidade adotada foi essa aqui, um, dois, três e cinco. Então por exemplo o critério dois ele é duas vezes mais importante que o um, o três é um pouco mais importante, dois é um pouco importante, três seria o mais importante, também a matriz tem uma relação inversa, C1 em relação ao C2 e C2 em relação ao C1.

Com relação ao critério C1 e as alternativas, como esse critério é avaliado pelo avaliador que simulou isso. Ele prefere ao dois em relação ao um, prefere ao três em relação ao um. Ele cria essas prioridades médias locais, então a gente chegou neste cenário, onde os dois ficaram praticamente empatados, os dois primeiros, então entraria no final uma análise mais subjetiva, porque quem é que vai escolher o resultado, é apenas para auxiliar na tomada de decisão.

Então as considerações finais aqui é que no contexto informacional o BIM, ele funciona como uma base para apresentar os dados e informações sobre construção e não é mais só um projeto, desenho de construção.

Esses modelos representam os componentes nos sistemas construtivos de uma maneira dinâmica, inclusive ele pode se interligar a diversos outros repositórios e sistemas de informação. E o método apresenta uma forma de explorar esse potencial em conjunto com a avaliação subjetiva que continua existindo adotando critérios tangíveis.

Essa análise então verificada no funcionamento do método, a gente conseguiu mais ou menos mostrar que ele é viável, agora a ideia é aprofundar. Ressaltando que foram utilizados dados simulados e dados para testes.

E fica como sugestão para trabalhos futuros, adaptar, moldar, para cada realidade de cada organização que for utilizar. Referências utilizadas.

É isso.

Slides da apresentação

Título: Métodos multicritérios para auxiliar o processo de tomada de decisão sobre empreendimentos imobiliários utilizando modelos BIM.

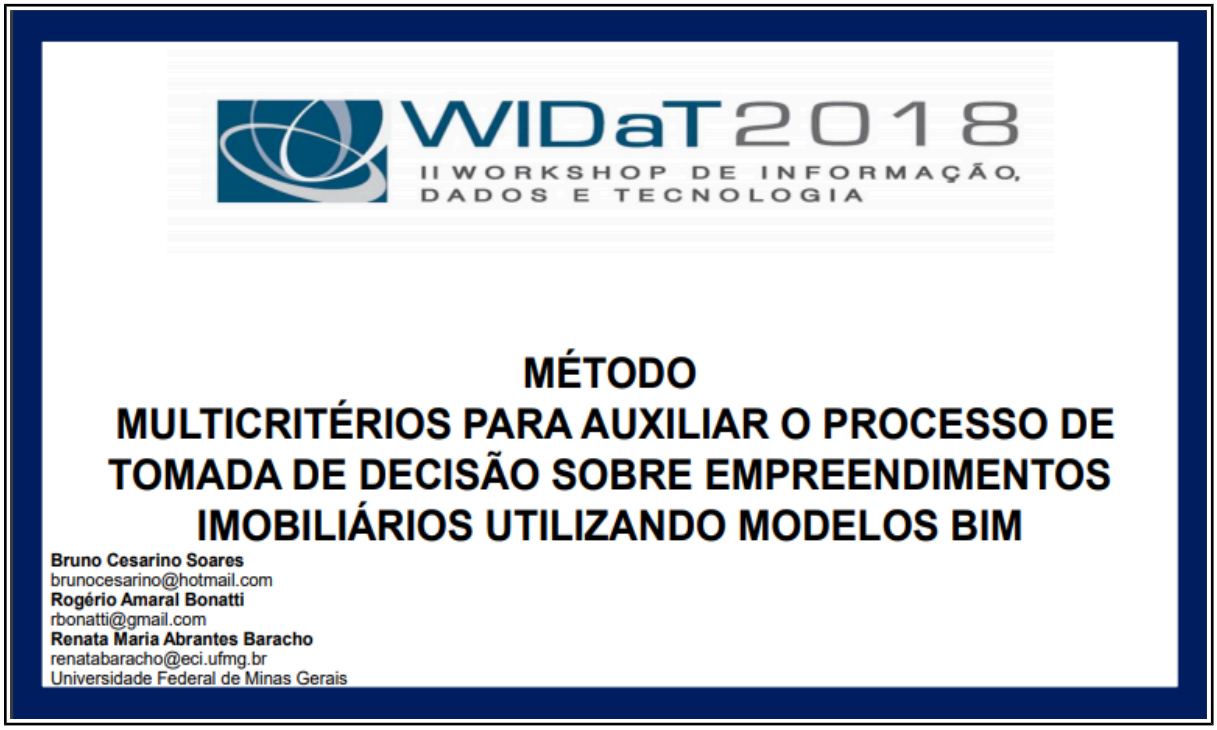

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=47

Web Scraping do ResearchID: proposta de sistema para o monitoramento de Índice H de pesquisadores no Brasil

Alexandre Ribas Semeler[a], Adilson Luiz Pinto[b] e Arthur Longoni Oliveira[c]

Resumo: A dimensão dos dados aponta uma nova tendência de estudos e práticas que vem sendo adotada por cientistas da informação interessados em estudos métricos que visem o uso de dados de citação e referências. Essas abordagens ressaltam métodos e tecnologias que garantem a interoperabilidade e a criação de uma identidade única para autores e de documentos científicos. O ResearcherID é um sistema de identificação de autores científicos, criado em 2008 pela Thomson Reuters com o objetivo de resolver o problema da identificação de autores. O ResearcherID foi adotado pelo Conselho Nacional de Pesquisa do Brasil como fonte de dados para coleta do Índice H nacional. Este indicador é aplicado para medir a produtividade e visualização do impacto de cientistas baseando-se nos seus artigos mais citados. Nesse contexto, a proposta desse estudo será a de medir o índice H dos pesquisadores brasileiros cadastrados no ResearcherID. Os procedimentos metodológicos exigem a aplicação de conhecimentos inerentes a linguagem de programação Python. São utilizadas técnicas de web scraping para recuperação de informação no ResearcherID. O resultado do estudo consolida-se na forma de dois scripts em Python (Anexo A e B) tais programas objetivam-se como base para a elaboração de um sistema de monitoramento do índice H no ResearcherID.

Palavras-chave: Dados de Citação; ResearcherID; Índice H; Web Scraping.

Web Scraping in ResearchID: proposal to the monitoring system of H-index of the researchers in Brazil

Abstract: The data dimension presents a new trends in studies and practices adopted by information scientists interested in metric studies that aim at the use of data citation and data references. These trends emphasize methods and technologies that ensure interoperability and the creation of a unique identity to authors and scientific documents. The ResearcherID is a system of identification of scientific authors, created in 2008 by Thomson Reuters with the purpose of solving the problem of the identification of authors. The ResearcherID was adopted by the National Research Council of Brazil as data source to validation and collection of the national H-index. This indicator is applied to measure the productivity and visualization of the impact of scientists based on their most cited articles. The aim of this study will be to measure the H-index of Brazilian researchers enrolled in ResearcherID. The methodological procedures require the application of knowledge inherent in the Python programming language. The web scraping techniques are used for information retrieval in ResearcherID. The results of the study are consolidated in two Python scripts (Annex A and B). Such programs are intended as a basis for the development of an H-index monitoring system in ResearcherID.

Keyword: Data Citation; ResearcherID; H-index; Web Scraping.

a Universidade Federal do Rio Grande do Sul (UFRGS). E-mail: alexandre.semeler@ufrgs.br. ORCID: https://orcid.org/0000-0002-8036-4271. Currículo: http://lattes.cnpq.br/1564154234554393

b Universidade Federal de Santa Catarina (UFSC). E-mail: adilson.pinto@ufsc.br. ORCID: https://orcid.org/0000-0002-4142-2061. Currículo: http://lattes.cnpq.br/4767432940301118

c Universidade Federal do Rio Grande do Sul (UFRGS). E-mail: arthur.holiver@gmail.com. Currículo: http://lattes.cnpq.br/7483194676718999

1 Introdução

A dimensão dos dados digitais aponta uma nova tendência de estudos e práticas que vem sendo adotada por cientistas da informação interessados em estudos métricos, em específico aqueles que visem o uso de dados de citação bibliográfica.

Os estudos métricos com base neste tipo de dados não são algo novo, desde a década de 1963 são desenvolvidos pelo Institute for Scientific Information vide o exemplo do Science Citation Index. No entanto, a identificação precisa de autores e suas citações junto com a integração de suas publicações em uma única identidade científica são questões ligadas ao contexto digital e justificam a realização deste estudo, que tem como objetivo identificar a variação do Índice H Brasileiro.

Segundo Hirsch (2005), o Índice H é um indicador de quantificação para a produtividade e visualização do impacto de cientistas baseando-se nos seus artigos mais citados.

O processo de busca por informação em dados de citação, principalmente, quando estes dados tratam o Índice H podem indicar uma frente de pesquisa. Uma frente de pesquisa é composta pelo conjunto de autores mais citados em um determinado campo e indicam a elite de autores. Assim, os dados de citação podem refletir a produtividade e a visibilidade dos autores.

Tendo em vista o desenvolvimento dos índices de citação e algumas tecnologias que retratam o Índice H mundial, conforme explanado por Rice e Southall (2016), a Clarivate Analitics desenvolveu em 2008 ResearcherID sistema utilizado para rastrear citações em conjuntos de dados da literatura científica de impacto internacional.

O ResearcherID é um sistema de identificação de autores científicos, criado pela Thompson Reuters com o objetivo de resolver o problema da identificação de autores. O ResearcheriD se integra com a Web of Science (Science Citation Index), é um identificador digital único, gratuito e persistente, que distingue um pesquisador de outro e resolve o problema da ambiguidade e semelhança de nomes de autores e indivíduos, substituindo as variações de nome por um único código numérico facilitando o registro de informações ele automatiza a atualização das publicações e dados de citação possibilitando a interoperabilidade entre as publicações e suas citações a partir de uma única conta. (RESEARCHERID, 2018)

Esse ID científico é um código de 11 dígitos, ex.: (J-9183-2016), na forma de caracteres alfanuméricos sendo único para cada individuo. O ResearcherID impede ambiguidades na identificação de autores e colaboradores em publicações. Seu funcionamento é semelhante ao do Digital Object Identifier (DOI), código para objetos como artigos científicos, teses e dissertações (RESEARCHERID, 2018; RICE; SOUTHALL, 2016).

O ResearcherID é um identificador único que permite que os pesquisadores gerenciem suas listas de publicações, rastreiem suas contagens de citações e índice h. (RESEARCHERID; 2018)

A utilização desses IDs favorece a localização e a contagem das publicações, além de reunir os dados de citações recebidas pelo conjunto de trabalhos de sua autoria possibilitando a visualização do Índice H.

O conselho Nacional de Pesquisa do Brasil (CNPq) adotou o ResearcherID para validar os dados sobre citações a publicações científicas de impacto internacional na sua plataforma de currículos Lattes, vide apêndice F. O CNPq utiliza o ResearcherID, para coletar e validar

automaticamente os dados sobre o número total de citações, número de trabalhos e Índice H, dos pesquisadores que possuem publicações científicas de impacto internacional na Web of Science por meio do ResearcherID.

Nesse sentido, a proposta desse estudo será a de medir o índice H dos pesquisadores brasileiros cadastrados no ResearcherID, contar o número de publicações e visualizar o número de publicações com citação na WOS.

No que segue essa pesquisa exigiu a aplicação de conhecimentos inerentes a técnicas e tecnologias utilizadas para coleta, de dados de citação. Como método de coleta utilizou-se um conjunto de rotinas e padrões de programação para extrair as informações do ResearcherID. Tais procedimentos metodológicos exigem o desenvolvimento de máquinas de busca com a linguagem de programação Python.

A seguir apresentam-se os objetivos, os procedimentos metodológicos e os resultados desse estudo com maiores detalhes.

2 Objetivos

O objetivo geral desta proposta é o de desenvolver scripts em Python para monitorar o Índice H de pesquisadores brasileiros no ResearcherID. Para isso, desenvolvem-se os seguintes objetivos específicos:

A) Automatizar a coleta do Índice H de pesquisadores registrados no ResearcherID;
B) Criar scripts de web scraping em linguagem de programação Python para coleta de dados de citação;
C) Medir o índice H dos pesquisadores brasileiros cadastrados no ResearcherID, contar o número de publicações e visualizar o número de publicações com citação na WOS.

3 Procedimentos Metodológicos

Os procedimentos metodológicos fundamentam-se na web scraping das métricas de citação do ResearcherID. O método adotado para este estudo foi o web scraping em Python, método que se define como processo de extração e combinação de conteúdos web de forma sistemática e automatizada. Em tal processo, um agente de software, o scraping, simula o comportamento de navegação humano em servidores web copiando e reorganizando dados desorganizados em dados organizados (GLEZ-PENA et al., 2013).

Existem diferentes técnicas de busca para web scraping: a manipulação de HTTP, a mineração de dados, as ferramentas de scraping, a cópia manual e os microformatos. A manipulação de HTTP permite a colheita de dados estáticos e dinâmicos de um site através de uma solicitação HTTP. A mineração de dados é um processo automático que reconhece as informações de um site de acordo com scripts predefinidos que contêm dados incorporados. Ferramentas de scraping são softwares utilizados para extrair informações relacionadas a sites ou a funcionalidades e/ou estruturas de dados na web. As ferramentas de scraping também servem para extrair dados de redes sociais e são úteis para todos os tipos de atividades de marketing web. A cópia manual, embora existam ferramentas de scraping disponíveis, às vezes é necessária, por exemplo, em alguns casos em que a informação do site for bloqueada contra qualquer forma web

scraping. Por fim, os microformatos são referentes às tecnologias da web semântica, como dados abertos vinculados via RDF. Esses são conjuntos de informações geralmente elaboradas para serem intercambiadas via vocabulários e ontologias (WEBSTER, 2015).

O funcionamento de um web scraping ocorre da seguinte maneira: (a) acesso ao site via protocolo de comunicação web (HTTP), durante o processo de solicitação e resposta entre um cliente, normalmente um navegador da web, e um servidor da web; (b) o programa de scraper analisa o HTML e pode extrair seu conteúdo; (c) armazena o output em conteúdo textual, com o objetivo de transformar o conteúdo extraído em uma representação estruturada para posterior análise e armazenamento (GLEZ-PENA et al., 2013).

O objetivo da web scraping é transformar os dados desestruturados da web em representações estruturadas, como aquelas de formatos tabulares, por exe.: os tipos de arquivos Comma Separated Values (CSV), Tab Separated Values (TSV), e/ou eXtensible Markup Language (XML). Essses formatos permitem a análise do conteúdo de sites da mesma forma que permitem salavar a navegação feita os browsers web, como o Chrome ou FireFox Mozilla.

No que segue apresenta-se uma sumarização dos procedimentos metodológicos, conforme o quadro 1.

Quadro 1 – Caracterização do método.

Caracterização do método	
Tipo de pesquisa	Exploratória e Descritiva
Estratégia	Uso de linguagens de programação para coletar o esquema de métricas do ResearcherID
Natureza	Quantitativa
Panorama geral da investigação	Índice H de pesquisadores brasileiros
Amostra	43.114 – IDS em 17 set. 2018
Corpus total	108.000 – IDS em 17 set. 2018
Instrumentos de coleta	Web scraping
Softwares	IDE = Pycharm Python=2.7 Módulos = Codecs, BeautifulSoup, Selenium
Fonte de coleta de dados	ResearcherID

Fonte: Dados da Pesquisa (2018).

Com base nesses procedimentos apresentam-se os resultados da pesquisa.

4 Resultados

Os resultados obtidos nesse estudo representam um possível modelo para execução automatizada do processo de coleta de dados de citação oferecidos pelo ResearcherID. Subdividem-se em um plano técnico, criação de scripts para extração automática das informações no ResearceherID e a interpretação destes dados.

4.1 Resultados técnicos

Como resultado técnico obteve-se dois scripts em Python os quais são aplicados para o monitoramento do índice H dos pesquisadores brasileiros cadastrados no ResearcherID, contar o número de publicações e visualizar o número de publicações com citação desses pesquisadores na Web of Science. Os mesmos podem ser visualizados no Anexo A e B deste trabalho.

O apêndice A, apresenta o script1, o qual executa a primeira coleta de dados no ResearcheriD. O script1 automatiza o web scraping das informações sobre: o nome de pesquisadores, sua instituição, o código ID e as áreas do conhecimento relacionadas ao seu ID. O script1 salva uma lista contendo, o um conjunto de dados com todos os IDS de pesquisadores brasileiros que possuem registro no ResearcherID, a lista contém (43.114) pesquisadores brasileiros registrados em 19 de novembro de 2018. O script1 possui um dispositivo de tratamento de falhas, que garante que quando interrompida a extração, em caso de timeout na página, a extração é reiniciada no último ponto valido. O script1 também evita as duplicações de IDs.

Os resultados da coleta feita pelo script1 são salvos em um arquivo .TSV e contem as seguintes informações: Nome do pesquisador, a instituição, o código no ResearcherID e as palavras-chave. Estes dados servem para o script2 como base para uma nova coleta de dados sobre as métricas de citação do ResearcherID .

O apêndice B representa o script2, o qual lê a lista de dados escrita pelo script1 e executa a coleta de informações sobre as métricas de citação do ResearcherID. O script2 lê os registros do arquivo .TSV e gera links (http://www.researcherid.com/rid/+ ID do pesquisador) usando os IDs do arquivo .TSV. Estes Links são únicos e representam os dados de citação de cada pesquisador. O script2 é paralelizado em 8 processos iguais, cada processo de coleta de informações de (1/8) dos links gerados a partir do arquivo .TSV, essas informações serão salvas em um único arquivo .TSV contendo os dados de citação da base, em especial: ID, total de publicações na lista, publicações com dados de citação, A soma de citações no tempo, a média de citações por artigo e o Índice H dos pesquisadores brasileiros.

4.2 Interpretações da coleta

Os resultados da coleta permitem não apenas a visualização do Índice H, mas também outras informações apresentadas pelo ResearcheriD como: total de publicações na lista, publicações com dados de citação, a soma de citações no tempo, a média de citações por artigo e o Índice H. Ressalta-se que os Índices H discrepantes e aqueles que não correspondem a autores únicos, como aqueles utilizados para medir instituições ou mesmo aqueles feitos erroneamente foram excluídos da análise por não representarem o objetivo deste trabalho.

Assim a coleta permitiu visualizar algumas situações, conforme o apêndice C, de um total de 40.114 pesquisadores cadastrados no ResearcherID, (9560) pesquisadores não possuem métricas no ResearcherID (N/A), ou seja nunca foram citados no Science Citation Index. Outros (960) possuem publicações com zero citação, ou seja, estes trabalhos não possuem impacto na WOS ou ainda não foram citados. As 10 maiores frequências de índice a H estão entre 1 e 10: (1=4006, 2=3454,3=3244, 4=2752, 5=2572, 6=2141, 7=1823, 8=1651, 9=1410, 10=1231).

Com base nos 40114 IDs a média do Índice H nacional é (7,97), levando-se em consideração pesquisadores únicos e aqueles que possuem índice H maior que zero, ou seja, um montante de (32.255) pesquisadores brasileiros.

A frente de pesquisa nacional pode ser visualizada no apêndice D e concentra-se no campo científico da Física. Conforme a Tabela 2 contida neste anexo o ID (B-2946-2012) possui o maior índice H nacional válido (96). Este índice é de um professor do Instituto de Física Gleb Wataghin da Universidade Estadual de Campinas (UNICAMP). O segundo maior índice H (92) também corresponde a área de Física, conforme o ID (L-6239-2016), pertence a um professor do Instituto de Física da Universidade de São Paulo. Ambos atuam na área de Física Nuclear e são Bolsistas de Produtividade em Pesquisa do CNPq – Nível 1D.

O apêndice D também permite visualizar e ranquear os pesquisadores brasileiros conforme a variação dos Índices H mais altos (mínimo 60 e máximo 96). O ID que recebeu mais citações (39544) é (L-1621-2016) de um professor da Universidade Estadual do Rio de Janeiro que também atua na área de Física nuclear sendo Bolsista de Produtividade em Pesquisa do CNPq - Nível 1C.

Já as publicações com citação na WOS compreendem o montante de (877.624) estas são publicações que receberam no mínimo 1 citação em periódico com fator de impacto. O número total de publicações registradas nas listas foi (1.146.855), no entanto este número é prejudicado ao representar o número de produções do Brasil na WOS, pois alguns pesquisadores não preencheram seus IDs apenas com a sua produção na WOS mas com outras fontes de dados de citação como Google Scholar e Scopus.

Por fim, o ID (K-5168-2013) possui a maior média de citações recebidas (99.88) no ReseacherID a coordenadora do Núcleo de Pesquisa em Asma e Inflamação das Vias Aéreas (NUPAIVA), com índice H (22) a pesquisadora da Universidade Federal de Santa Catarina valida todasua produção na Plataforma Lattes.

No entanto, chamou a atenção que os maiores índices H brasileiros (140), (105) e (103) não serem válidos, pois foram realizados com objetivos diversos e não com o objetivo de validar os dados de citação no Lattes CNPq. É necessário ter em mente que o ReserchерID é um identificador pessoal de autor e possui o objetivo de fornecer métricas para produção de autores únicos e não de instituições, ressaltando também que não é uma ferramenta para pesquisa bibliográfica.

Assim o índice H 140, (A-9780-2017), atribuído ao Instituto de Física, Gleb Wataghin da UNICAMP e o índice H 105, (M-2664-2016), que representa o Instituto de Física de São Carlos da Universidade de São Paulo prejudicam a visualização do índice H nacional de autores já que são índices de um conjunto de autores de uma instituição. Outra discrepância é o índice H 103 (E-4724-2015), de um estudante do Laboratório de Raioisótopos do Centro de Energia Nuclear na Agricultura – CENA, que foi construído de maneira errônea pois o autor em sua lista pessoal de publicações insere produções científicas de outros autores de certo ele utilizou a plataforma para visualizar a produção em sua área de pesquisa desconhecendo o objetivo do ResearcherID, tão pouco ele valida seu Lattes com os dados.

Este três casos ressaltam a relevância desta proposta de trabalho. Pois a visualização do Índice H nacional é usada pelo CNPq como estratégia para fomentar e desenvolver novas pesquisas, pautando-se na relevância e no impacto dos pesquisadores atribuída pela WOS, nas mais diversas áreas do conhecimento. No entanto, é necessário fazer o uso correto da plataforma ResearcherID que é um instrumento de validação de citações utilizada pela plataforma Lattes do CNPq.

5 Considerações Finais

O Índice H é usado pelo CNPq como um dos indicadores para pautar a distribuição de Bolsas de Pesquisa e para pautar a relevância acadêmica da produção científica no Brasil. Conhecer o Índice H nacional torna-se tarefa de suma relevância. Pois o Índice H indica o impacto e a relevância dos trabalhos mais citados ao longo do tempo. Revelando a visibilidade e o uso da produção científica de impacto internacional de cada pesquisador.

Considera-se esse estudo como uma estratégia fundamental para medir a variação do Índice H nacional, a variação da média de citações de impacto internacional, medir a soma das citações da produção científica nacional, assim como para visualizar o total de publicações nacionais na lista do ResearcherID com citações.

Por fim, ressalta-se que os dados de citação e os IDs de autores são ferramentas necessárias para visualização do impacto internacional do que é produzido em nosso país, sendo automatização desse processo de suma aplicabilidade em estudos métricos que visem o uso de dados para qualificar a produção científica nacional. Conclui-se que os usuários brasileiros deveriam ter maior critério ao utilizar o ResearcherId, pois a ferramenta é utilizada pelo CNPq para validar o impacto da produção nacional na Web of Science uma das principais e mais respeitadas bases de dados e documentos bibliográficos.

Agradecimentos

"O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Código de Financiamento 001".

Referências

GLEZ-PEÑA, D. et al.. Web scraping technologies in an API world. **Briefings in Bioinformatics**, v. 15, n. 5, p. 788-797, 2013. Disponível em:<http://bib.oxfordjournals.org/content/15/5/788>. Acesso em: set. 2018.

HEIRICH, J. An index to quantify an individual's scientific research output. **PNAS, v.** 102, n. (46), 2005. Disponível em: https://doi.org/10.1073/pnas.0507655102>. Acesso em: set. 2018.

PYTHON. Disponível em: <https://www.python.org/>. Acesso em set. 2018.

ResearcherID. Disponível em: < http://www.researcherid.com > Acesso em: set. 2018.

RICE, R.; SOUTHALL, S. **The data librarian's handbook**. London: Facet Publishing, 2016.

WEBSTER, S. **What Is Scraping**? The Basics For Everyone. 2015. Disponível em: https://myhelpster.com/what-is-scraping-the-basics-for-everyone/. Acesso em: set. 2018.

Apêndice A – Script1: coleta de informações gerais no ResearcherID

```
# coding: utf-8
"""
Created on Sep 17 2018
"""

import codecs
from bs4 import BeautifulSoup
import selenium.common.exceptions
# from selenium import webdriver
from selenium.webdriver.common.by import By
from selenium.webdriver.support.ui import WebDriverWait
from selenium.webdriver.support import expected_conditions as ec
from selenium.webdriver import Firefox
# import os

url = 'http://www.researcherid.com/ViewProfileSearch.action'    # define url alvo
# Caso a execução seja feita com Chrome
# chromedriver = "../scripts/chromedriver"            # path do chromedriver
# os.environ["webdriver.chrome.driver"] = chromedriver
# driver = webdriver.Chrome(chromedriver)                          # abre browser

# abre arquivo para escrita dos resultados
with codecs.open('../dados/csv/RESEARCHID_Extraction2.tsv', 'w', 'utf-8-sig') as results:
    results.write('Name\tInstitution\tResearcher ID\tKeywords\n')   # escreve headers
results.close()
id_list = []
counter = 0     # inicializa contador de resultados e erros
errors = 0

driver = Firefox()
while True:
    try:
        driver.get(url)                                                  # navega para a url
        # espera carregamento da combobox para escolher o Pais alvo
        WebDriverWait(driver, 10).until(ec.presence_of_element_located((By.CSS_SELECTOR,
                                                                        '#country >
option:nth-child(33)'))).click()
        break
    except selenium.common.exceptions.TimeoutException:
        continue

# clica para submeter pesquisa
driver.find_element_by_css_selector('#submitImage > img').click()
# define limite de paginas para serem acessadas nos resultados
page_limit = int(WebDriverWait(driver, 10).until(ec.presence_of_element_located(
    (By.CSS_SELECTOR, '#criteria_requestedPage_total'))).text) // 50 + 1
# espera combobox carregar para mostrar 50 resultados por pagina
WebDriverWait(driver, 10).until(ec.presence_of_element_located((By.CSS_SELECTOR,
                                                               '#resultsPerPage >
option:nth-child(3)'))).click()

for page in range(page_limit):      # percorre paginas de resultados da busca
    # espera tabela de resultados ser carregada
    WebDriverWait(driver, 10).until(ec.presence_of_element_located(
        (By.CSS_SELECTOR, '#resultContainer > table:nth-child(23) > tbody > tr:nth-
child(2) > td > table > tbody')))
    # define raiz da arvore de resultados para parsing
    root = BeautifulSoup(driver.page_source, 'lxml').find('td', {'class':
'resultsTableBox'}).findNext('tbody')
    with codecs.open('../dados/csv/RESEARCHID_Extraction2.tsv', 'a', 'utf-8-sig') as
results:
        for item in root.findAll('tr')[1:]:     # percorre itens na tabela
            data = item.findAll('td')           # lista todos os resultados
            rid = data[4].getText().replace('\n', '').replace(' ', '')
            if rid in id_list:
                continue
            else:
                id_list.append(rid)
                # escreve resultados no arquivo de output
                results.write('%s\t%s\t%s\t%s\n' % (data[1].a.getText().replace('\n', ''),
                                                   data[2].getText().replace('\n', ''),
                                                   rid,
                                                   data[5].getText().replace('\n', '')))
                counter += 1        # incrementa contador de resultados
        results.close()
    if page < page_limit:       # testa se as paginas de resultados ja acabaram
        # clica em next page caso contrario
        WebDriverWait(driver, 10).until(ec.presence_of_element_located(
            (By.CSS_SELECTOR, '#resultContainer > table:nth-child(22) > tbody > tr >
td:nth-child(2) > table > '
                              'tbody > tr > td:nth-child(7) > span > img'))).click()
    print counter
    try:        # tenta esperar pelo carregamento de um item da pagina como teste
        WebDriverWait(driver, 20).until(ec.presence_of_element_located(
            (By.ID, 'pageNumnull')))
    except selenium.common.exceptions.TimeoutException:     # em caso de timeout, trata o
erro
        driver.get(url)     # navega para a url alvo novamente
        errors += 1         # incrementa counter de erros
        # reinicia a pesquisa
        WebDriverWait(driver, 30).until(ec.presence_of_element_located(
            (By.CSS_SELECTOR, '#country > option:nth-child(33)'))).click()
        driver.find_element_by_css_selector('#submitImage > img').click()
        WebDriverWait(driver, 40).until(ec.presence_of_element_located(
            (By.CSS_SELECTOR, '#resultsPerPage > option:nth-child(3)'))).click()
        page -= 1       # reduz contador de paginas navegadas em 1
        element = WebDriverWait(driver,
10).until(ec.presence_of_element_located((By.XPATH, '//*[@id="pageNumnull"]')))
        element.clear()     # limpa caixa de texto com numero de paginas
        element.send_keys('%s' % page)      # escreve numero de paginas na caixa de texto

driver.find_element_by_xpath('/html/body/div[3]/form[2]/table/tbody/tr/td/div/table/tbody/
tr[2]/td[2]/div/div/'

'table[1]/tbody/tr/td[2]/table/tbody/tr/td[5]/a/img').click()  # clica em "go"
driver.quit()
print errors, 'errors happened. Extraction finished.'
```

Fonte: Dados da pesquisa (2018).

Apêndice B – Script2: coleta das métricas de citação do ResearcherID

```
# coding: utf-8
"""
Created on Aug 27 2018
"""
import codecs
from bs4 import BeautifulSoup
from multiprocessing import Pool
import selenium.common.exceptions
from selenium.webdriver.common.by import By
from selenium.webdriver.support.ui import WebDriverWait
from selenium.webdriver.support import expected_conditions as ec
from selenium.webdriver.firefox.options import Options
from selenium.webdriver import Firefox
# import os
# from selenium.webdriver.chrome.options import Options
# from selenium import webdriver


################################################################################################################
###############
master = codecs.open('../dados/csv/RESEARCHERID-ALL-METRICS.tsv', 'r', 'utf-8')
id_list = master.readlines()[1:]
master.close()
for x in range(len(id_list)):
    id_list[x] = '%s' % id_list[x].split('\t')[0][1:]
################################################################################################################
###############
options = Options()
options.add_argument("--headless")


class Control:
    def __init__(self):
        self.counter = 0
        self.article_accumulator = 0
        self.with_citation_accumulator = 0
        self.h_index_accumulator = 0
        self.existent_h_index_counter = 0


def id_cleaning(a_link):
    if '\r\n' in a_link:  # testa finais de linha para verificar se usam \n ou \r\n
        return a_link.replace(' ', '').replace('\r\n', '\t')  # troca final por \t e tir
blank spaces
    else:
        return a_link.replace(' ', '').replace('\n', '\t')


def get_metrics_info(a_soup):    # function que extrai dados alvo da pagina
    return (a_soup.find(id='metrics_totalArticleCount').getText(),
            a_soup.find(id='metrics_articleCountForMetrics').getText(),
            a_soup.find(id='metrics_timesCited').getText(),
            a_soup.find(id='metrics_averagePerItem').getText(),
            a_soup.find(id='metrics_hindex').getText())


def parallel_scraping(a_trio):
    global id_list
    driver = Firefox(firefox_options=options)
    for item in a_trio[0]:  # for para percorrer a lista de links
        rid = id_cleaning(item.split('\t')[2])
        if rid in id_list:
            continue
        link, name = 'http://www.researcherid.com/rid/' + rid, item.split('\t')[0]
        a_trio[2].counter += 1  # incrementa counter para acompanhar progresso
        print a_trio[2].counter, ': Extracting: %s' % link

        driver.get(link)  # acessa link alvo
        try:

river.find_elements_by_xpath('/html/body/div[3]/div/table/tbody/tr/td[1]/table/tbody/tr[
/td[2]/'
                                     'div[1]/ul[1]/''li[2]/a')[0].click()
            # clica para mostrar citation metrics
        except IndexError:
            print '%s apparently got no citation metrics' % link  # exception tratada
            continue
        a_file = codecs.open(a_trio[1], 'a', 'utf-8-sig')
        try:
            WebDriverWait(driver, 10).until(ec.presence_of_element_located(
                (By.CSS_SELECTOR, '#metrics_hindex')))
        except selenium.common.exceptions.TimeoutException:
            a_file.write(link.split('/')[-1] + '\t' + 'TO\tTO\tTO\tTO\tTO\n')
        else:
            root = BeautifulSoup(driver.page_source, 'lxml')  # parsing inicial
            data = get_metrics_info(root)
            if data != '':
                a_trio[2].article_accumulator += int(data[0])
                a_file.write(link.split('/')[-1] + '\t' + '%s\t%s\t%s\t%s\n' % data)
                if data[-1] > 0:
                    a_trio[2].with_citation_accumulator += int(data[1])
                    a_trio[2].h_index_accumulator += float(data[-1])
                    a_trio[2].existent_h_index_counter += 1
            else:
                a_file.write(link.split('/')[-1] + '\t' + 'NA\tNA\tNA\tNA\tNA\n')
                # aguarda carregamento da pagina para escrever no arquivo de output
        finally:
            a_file.close()
    driver.quit()  # fecha browser


if __name__ == '__main__':
    pool = Pool(processes=8)
    # geckodriver = "../scripts/geckodriver"    # path do geckodriver para firefox

    # chrome_options = Options()
    # chrome_options.add_argument("--headless")
    # chromedriver = "../scripts/chromedriver"    # path do chromedriver
    # os.environ["webdriver.chrome.driver"] = chromedriver

    with codecs.open('../dados/csv/RESEARCHID_Extraction2.tsv', 'r', 'utf-8-sig') as
esearch:  # abre arquivo
        link_list = research.readlines()[1:]    # extrai linhas do arquivo em uma lista
    research.close()                            # fecha arquivo

    with open('../dados/error_logs/ResearcherIDanonScraping.txt', 'w') as log:
        out_file1 = codecs.open('../dados/csv/RESEARCHIDresultsPart1-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file2 = codecs.open('../dados/csv/RESEARCHIDresultsPart2-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file3 = codecs.open('../dados/csv/RESEARCHIDresultsPart3-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file4 = codecs.open('../dados/csv/RESEARCHIDresultsPart4-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file5 = codecs.open('../dados/csv/RESEARCHIDresultsPart5-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file6 = codecs.open('../dados/csv/RESEARCHIDresultsPart6-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file7 = codecs.open('../dados/csv/RESEARCHIDresultsPart7-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        out_file8 = codecs.open('../dados/csv/RESEARCHIDresultsPart8-8.tsv', 'w', 'utf-8-
g')  # abre arquivo de output
        file_list = [out_file1, out_file2, out_file3, out_file4, out_file5, out_file6,
t_file7, out_file8]

        octan = len(link_list) // 8
        pool.map(parallel_scraping, [(link_list[:octan-1],
'../dados/csv/RESEARCHIDresultsPart1-8.tsv', control1),
                                     (link_list[octan:2*octan-1],
'../dados/csv/RESEARCHIDresultsPart2-8.tsv', control2),
                                     (link_list[2*octan:3*octan-1],
'../dados/csv/RESEARCHIDresultsPart3-8.tsv', control3),
                                     (link_list[3*octan:4*octan-1],
'../dados/csv/RESEARCHIDresultsPart4-8.tsv', control4),
                                     (link_list[4*octan:5*octan-1],
'../dados/csv/RESEARCHIDresultsPart5-8.tsv', control5),
                                     (link_list[5*octan:6*octan-1],
'../dados/csv/RESEARCHIDresultsPart6-8.tsv', control6),
                                     (link_list[6*octan:7*octan-1],
'../dados/csv/RESEARCHIDresultsPart7-8.tsv', control7),
                                     (link_list[7*octan:],
'../dados/csv/RESEARCHIDresultsPart8-8.tsv', control8)])
        total_H_index = 0
        total_existent_H_index = 0
        total_cited = 0
        total_articles = 0
        elements_counter = 0
        for x in control_list:
```

Fonte: Dados da pesquisa (2018).

Apêndice C – Tabela 1 – Rank de Frequências do Índice H Brasileiro

H index	Freq.	H index	Freq.
0	960	41	17
1	4006	42	25
2	3454	43	5
3	3244	44	21
4	2752	45	5
5	2572	46	12
6	2141	47	10
7	1823	48	12
8	1651	49	16
9	1410	50	7
10	1231	51	6
11	1082	52	3
12	931	53	9
13	748	54	9
14	671	55	7
15	604	56	7
16	526	57	1
17	498	58	7
18	369	59	5
19	355	60	4
20	307	61	3
21	253	62	6
22	251	63	1
23	205	67	3
24	183	68	2
25	159	69	5
26	126	71	2
27	143	73	1
28	96	75	3
29	85	76	3
30	90	77	2
31	66	80	2
32	46	83	2
33	57	84	2
34	37	85	1
35	42	86	1
36	38	92	1
37	22	96	1
38	26	103	1
39	15	105	1
40	28	140	1
		N/A	9576

Fonte: Dados da Pesquisa (2018).

Apêndice D – Frente de Pesquisa Nacional Conforme Índice H

ResearcherID	Total in Pub. List	With Citation Data	Sum of Times Cited	Average Citations/Article	H-index
B-2946-2012	438	438	31845	72.87	96
L-6239-2016	408	406	29667	73.07	92
D-3532-2012	833	820	39622	48.50	86
L-1621-2016	866	745	39544	53.22	85
C-4007-2013	619	619	37172	60.15	84
D-4476-2013	520	520	27898	53.65	84
C-4007-2013	619	619	37125	60.07	83
C-7679-2016	611	298	34566	115.99	83
G-9573-2012	755	755	25892	34.29	80
J-4630-2016	2718	2630	42617	16.20	80
G-5410-2012	784	310	20400	65.81	77
L-4142-2016	501	488	28821	59.30	77
B-2309-2010	1275	884	24380	27.58	76
B-5403-2013	444	444	28660	64.70	76
G-6218-2012	446	434	27145	62.98	76
D-1707-2012	284	284	22006	77.49	75
E-8874-2010	459	321	18207	56.72	75
M-6631-2013	777	710	23832	33.66	75
K-6137-2016	237	219	37949	173.28	73
F-2141-2010	264	229	25332	110.62	71
F-2141-2010	265	230	25334	110.15	71
D-2408-2015	419	419	21673	51.85	69
F-7161-2010	348	321	22952	71.50	69
F-7161-2010	348	321	22983	71.60	69
F-7161-2010	194	194	14769	76.13	69
L-2418-2014	545	541	18434	34.07	69
M-3090-2014	254	254	28564	112.46	68
K-6892-2013	753	527	24014	46.09	68
L-3893-2016	540	540	19042	35.26	67
E-6926-2013	540	540	19115	35.40	67
E-6926-2013	172	158	22547	142.70	67
G-6877-2012	828	653	14993	23.03	63
I-7972-2012	185	169	18890	111.78	62
B-6589-2008	474	454	13153	28.97	62
J-5803-2014	474	454	13181	29.03	62
J-5803-2014	372	372	20303	54.58	62
K-1918-2012	372	372	20325	54.64	62
O-7715-2015	202	202	13956	69.09	62
C-9336-2011	590	431	11811	27.86	61
F-8692-2017	504	504	16341	32.42	61
H-1692-2011	665	645	16647	25.81	61

C-3323-2013	499	499	14448	28.95	60
D-3175-2013	372	371	12043	32.46	60
I-7663-2012	256	249	12957	52.46	60
J-5104-2015	1169	1117	18297	16.38	60

Fonte: Dados da pesquisa (2018).

Apêndice E – Validação do Índice H no Lattes CNPq

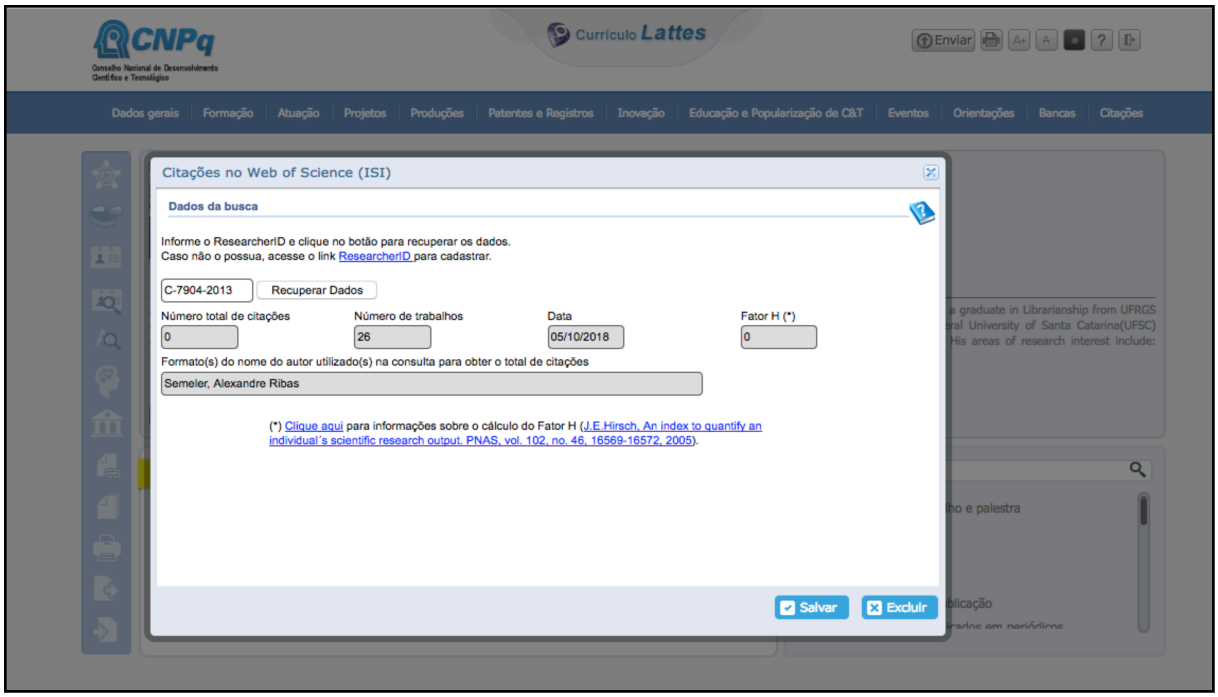

Fonte: Dados da Pesquisa (2018).

Vídeo da apresentação

Título: Web Scraping do ResearchID: proposta de sistema para o monitoramento de Índice H de pesquisadores no Brasil.

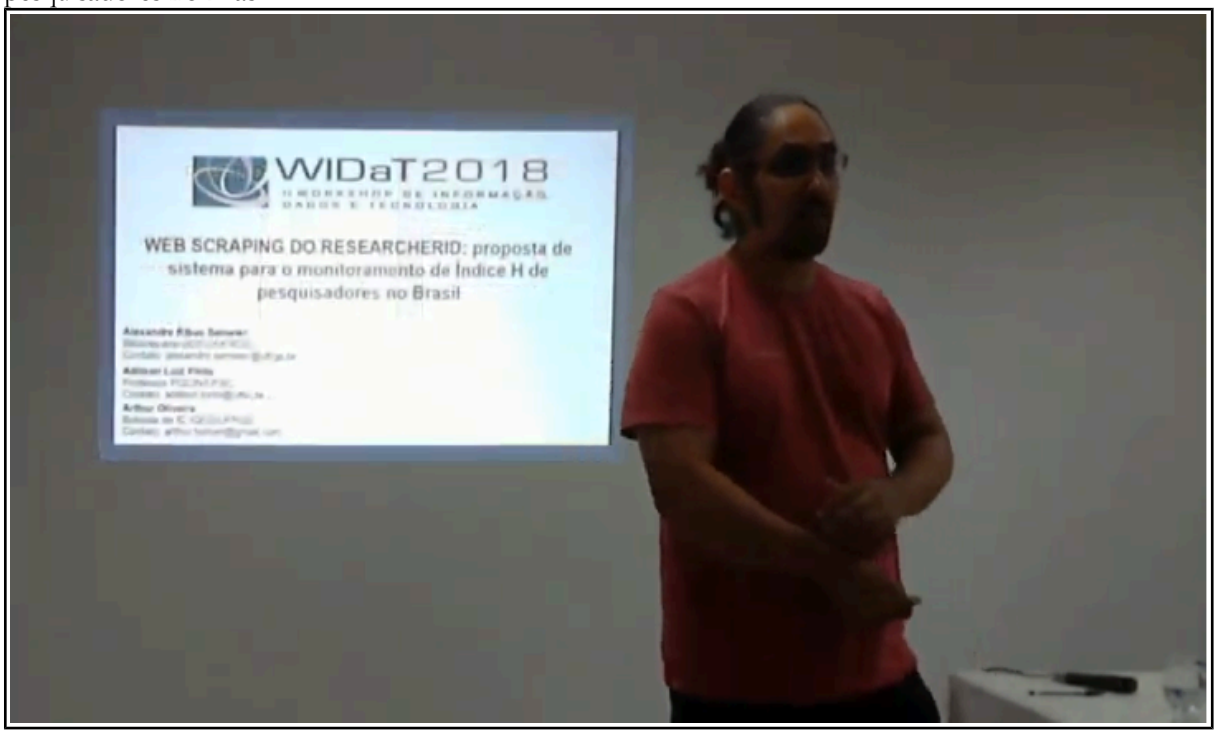

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=48

Transcrição da apresentação

Bom, primeiro eu gostaria de falar que este trabalho inicialmente, bom sou pós-doutorando do Programa de Pós-Graduação de Ciência da Informação da UFSC, sou bibliotecário do instituto de geociência da UFSC, e esse trabalho é uma aplicação prática de um serviço que eu estou propondo para minha universidade para que ele componha uma parte de um documento diário para avaliação de docentes que vão se candidatar para progressão de titular e para alinhar e comparar programas de pós-graduação. No entanto, eu não posso utilizar os dados porque é um trabalho que está sendo desenvolvido, eu vou falar sobre o índice nacional, o índice H.

A primeira parte a gente tem uma ferramenta desenvolvida pela Thompson que oferece a versão do índice H para todo mundo, e o Brasil é o país que mais utiliza a ferramenta para gerar o Índice H, muitas vezes para instituições, para escolas, mas também para pessoas que é o objetivo da ferramenta, são 108 mil pesquisadores brasileiros que utilizam a ferramenta.

O CNPQ adota esta ferramenta para validar o índice H ou fator H como o CNPQ chama, desses pesquisadores brasileiros, geralmente esse fator ele é mais válido para pessoas que têm mais tempo, para pesquisadores no caso, mas ela fica dentro da academia e o CNPQ usa isso para pautar a distribuição de bolsa de produtividade e para distribuição de fomento para projeto de pesquisa. Na área de geociência que é a área que eu tenho maior conhecimento.

Enfim, essa é a ferramenta adotada pelo CNPQ, ela fornece essas informações sobre a produção e o impacto científico que ela tem internacionalmente, é um indicador usado para medir a internacionalização da produção científica. Então qual é o objetivo do trabalho? Desenvolver uma forma automatizada para extrair esse índice H dos pesquisadores brasileiros, fazendo isso com a linguagem de programação Python e identificar esse índice H em uma frente de pesquisa nacional, quais são os pesquisadores brasileiros que possuem maior impacto em produção científica na base de dados da Thompson.

Como foi então desenvolvido esse trabalho? A pesquisa foi uma pesquisa exploratória, descritiva dos dados, de natureza quantitativa, o corpus de estudo foram 108 mil id's, identificadores, ela foi feita totalmente automatizada, foi utilizado o scraping para a raspagem dos dados, como é uma base proprietária ela não permite que a gente fique raspando ela em looping, tem que ser com calma, tempo de 10 segundos, uma navegação de humano, então para automatizar esta navegação eu utilizei algumas bibliotecas de Python, uma biblioteca para raspagem que se chama BeautifulSoup que é para fazer o scraping, e o Selenium para poder fazer essa automatização e não ficar tão agressivo e a base proibir esse acesso aos dados.

E também um multiprocesso que é para poder, como é extraído muitos dados dela, muito tempo, a coleta sem a volumização dos dados levou em média 14 dias, é muito tempo, dividindo o processo em oito processadores da máquina, deu para reduzir o tempo da coleta para quatro dias, o que acontece essa coleta se modifica, os dados se modificam, as pessoas inserem mais informações, mais produções, e isso modifica o valor do índice, modifica a lista de publicações, então o que acontece, tem um dispositivo para falhas, então quando quebra a raspagem, quando se encerra a coleta o script retoma do último tempo válido, da última coleta válida, comparar a coleta que ele já tem e verifica se ela se modificou e reinicia-se, então ele coleta outros arquivos

diferentes, conclui a coleta e salva em um novo arquivo, a onde ele vai fazer a soma das publicações e identificar, o nome, tem nome de pessoas, primeiramente.

O código está disponível no Github, o código e a primeira extração feita em setembro, ela já se modificou de 108 mil já são 108.900 id's,. Então eles abrem e coletam as métricas de informação, a quantidade de publicação, as publicações com citação e o índice H, as publicações com citação, são publicações com citação na Web of Science, quer dizer que elas não são aquelas publicações no Google, aquelas citações em outras bases de dados, somente as publicações que estão no Science Citation Index na Thompson.

Nessa coleta maior eu identifiquei a frente de pesquisa nacional, quais são os pesquisadores com pesquisa de maior impacto internacional, são pesquisadores da área de física nuclear, medicina e psicologia, esses índices são fáceis de identificar porque a frequência é um, de 108 mil pesquisadores a frequência é um, mas está distribuído, ciências humanas, enfim de um a dez, as ciências humanas ficam de um a três, de um a quatro, depende muito do pesquisador, mas a média e que a gente tem muita gente, dos 108 mil pesquisadores a maioria é zero, zero citações nessa base de dados e as pessoas não fazem bom uso às vezes da base de dados, elas usam para medir uma instituição, o script veio no caso para resolver para as pessoas que usam para medir uma instituição, você teria que colocar todas as pessoas e coletar esse grupo e verificar a média deles, então muitas pessoas fazem mal uso da plataforma, perde todo o sentido.

Então a maioria desses professores de física são titulares, são bolsistas de produtividade pelo CNPQ, para finalizar o resultado a média nacional dos 108 mil é 7,97 nosso índice H de produção.

A automatização é um processo importante, pois está em constante desenvolvimento, as pessoas estão sempre inserindo seus dados lá e o script se aplica também em pequenos grupos, no meu caso do meu trabalho que é serviço aplicado medir o programa de pós-graduação, medir o grupo de pesquisa, departamentos.

O que vai ser feito daqui para frente, desenvolver um script para validar, qual foi o problema da validação, foram as pessoas que utilizam a plataforma por brincadeira, sem compreender que o índice tem que ser validado pelo CNPQ, então eu preciso verificar quem validou sua produção no Lattes, isso já foi feito mas não deu tempo de falar aqui, uma interface gráfica e a comparação com outros países, principalmente União Soviética e Estados Unidos.

É isso, gostaria de agradecer a CAPES porque eu sou bolsista de pós-doutorado.

Muito obrigado.

Slides da apresentação

Título: Web Scraping do ResearchID: proposta de sistema para o monitoramento de Índice H de pesquisadores no Brasil.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=48

Suporte à gestão de dados de pesquisa nas bibliotecas: identificação de serviços a partir da literatura

Fernanda Gomes Almeida[a] *e Marcos de Souza*[b]

Resumo: Artigo de natureza exploratória que objetiva inventariar, por meio da literatura, os serviços para suporte à gestão de dados científicos realizados em bibliotecas. Pretende ainda propor uma categorização e classificação dos serviços conforme as categorias propostas. A identificação dos artigos que compõem o corpus desta pesquisa foi realizada por meio de buscas em bases de dados, Google Acadêmico e referências citadas. Os artigos foram lidos, codificados e categorizados com o auxílio do software NVivo, sendo as categorias criadas a partir da revisão de literatura. Foram obtidas cinco categorias de serviços nos 58 artigos analisados: Infraestrutura, Técnico, Suporte, Educacional e Outros. Os serviços mais presentes nos artigos são os das categorias Educacional e Suporte, representando uma extensão dos serviços já realizados pelas bibliotecas. Conclui-se que a classificação proposta carece de reanálise e reagrupamento de serviços, pois é provável que a partir da literatura e de um melhor entendimento da área surja uma nova hierarquização ou que categorias sejam unificadas ou remanejadas.

Palavras-chave: Dados de pesquisa. Gestão de dados de pesquisa. Bibliotecas. Serviços.

Support for research data management in libraries: identification of services from the literature

Abstract: This is an exploratory paper that aims to inventory, through the literature, the services to support for research data management in libraries. It also intends to propose a categorization and classification of services according to the proposed categories. The identification of the articles that compose the corpus of this research was carried out through searches in databases, Google Scholar and references cited. The articles were read, coded and categorized with the aid of the NVivo software, and the categories were created based on the literature review. Five categories of services were obtained in the 58 analyzed articles: Infrastructure, Technical, Support, Educational and Others. The most present services in the articles are those of the Educational and Support categories representing an extension of services already performed by libraries. It is concluded that the proposed classification requires a reanalysis and regrouping of services, since it is probable, that from the literature and from a better understanding of the area a new hierarchy will emerge or that categories will be unified or re-managed.

Keyword: Research data. Research data management. Libraries. Services.

a Universidade Federal de Minas Gerais (UFMG). E-mail: usernanda@gmail.com. ORCID: https://orcid.org/0000-0001-7913-827X. Currículo: http://lattes.cnpq.br/5601300780102290

b Universidade Federal de Minas Gerais (UFMG). E-mail: marcosdesouza82@gmail.com. ORCID: https://orcid.org/0000-0002-9829-7249. Currículo: http://lattes.cnpq.br/3958131052236839

1 Introdução

Atualmente é reconhecido o potencial informacional dos dados de pesquisa por parte de pesquisadores, instituições acadêmicas e agências de fomento. Além desse reconhecimento, uma série de pressões externas como o reúso de dados, os requisitos das agências financiadoras, as boas práticas de pesquisa, a reputação das instituições (ASHLEY, 2012), bem como o crescimento e o desenvolvimento da pesquisa colaborativa, as práticas de pesquisa aberta (Open Access, Open Science, Open Data) (CHIWARE; BECKER, 2018) vêm fazendo com que o gerenciamento de dados científicos seja uma preocupação crescente nas universidades (ASHLEY, 2012). Desta forma, o potencial dos dados aliado às pressões externas representam oportunidades para que as bibliotecas ofereçam serviços voltados ao gerenciamento de dados (KRAFT, 2015).

Os serviços de suporte à gestão de dados de pesquisa (SSGDPs) são os "[…] serviços que uma biblioteca oferece aos pesquisadores em relação ao gerenciamento de dados […]" (TENOPIR; BIRCH; ALLARD, 2012, p. 7, tradução nossa), abordando o ciclo de vida completo dos dados.

Diversos nomes foram sugeridos na literatura para designar basicamente os mesmos tipos de serviços, contudo uma pesquisa não exaustiva apontou que "research data management services" e "research data services" foram os temos mais utilizados.

As universidades – e as bibliotecas – estão começando a descobrir como a gestão de dados de pesquisa deve ser apoiada em termos de consultoria, treinamentos ou de infraestrutura para armazenamento, compartilhamento e curadoria de dados (COX; PINFIELD, 2014), porém, quais são os serviços que as bibliotecas podem oferecer?

Nos últimos anos diversos artigos têm identificado os variados SSGDPs desenvolvidos e/ou planejados pelas bibliotecas nos Estados Unidos e Europa (SI et al., 2015; TENOPIR et al., 2016, 2017; TENOPIR; BIRCH; ALLARD, 2012; YOON; SCHULTZ, 2017), assim como outros trabalhos têm apresentado os serviços desenvolvidos em instituições (AKERS et al., 2014; GOLDMAN; KAFEL; MARTIN, 2015; HIOM et al., 2015; KNUTH; JOHNSON; HAUSER, 2015; PERRIER et al., 2018; SEARLE et al., 2015; SESARTIC; TÖWE, 2016; TENOPIR et al., 2016, 2017; YOON; SCHULTZ, 2017).

Este trabalho tem como objetivo inventariar, por meio de revisão de literatura, os serviços de suporte à gestão de dados desenvolvidos em bibliotecas. Além disso, pretende propor uma categorização de serviços, bem como classificar esses serviços conforme as categorias propostas.

2 Referencial teórico

Recentemente foi percebido que a gestão dos dados de pesquisa constitui o aspecto mais desafiador para as instituições (PRYOR, 2014). Para as bibliotecas, a gestão de dados representa uma oportunidade para que desempenhem um papel ainda mais ativo no processo de pesquisa. Em primeiro lugar, as bibliotecas acadêmicas podem fornecer serviços de consultoria relacionados ao gerenciamento e conservação de dados de pesquisa. Segundo, as bibliotecas podem fornecer a infraestrutura para armazenamento e curadoria de dados. Em terceiro lugar, as bibliotecas acadêmicas podem apoiar os bibliotecários a se tornarem membros ativos em equipes

de pesquisa e de propostas de concessão como consultores em curadoria de dados (TENOPIR; BIRCH; ALLARD, 2012, p.41, tradução nossa).

Nos últimos anos, autores têm propostos níveis, classificações ou categorias de serviços. Algumas dessas são apresentadas na próxima seção.

2.1 Trabalhos relacionados

Geraci, Humphrey e Jacobs (2012) propõem a classificação de serviços em três níveis principais: serviços de coleção – criação e manutenção de coleções; serviços de referência em dados ou curadoria de dados; e serviços de computação – armazenamento, entrega e uso de dados.

Reznik-Zellen, Adamick e McGinty (2012) propõem três níveis de serviço: educação - bibliotecas educam sua comunidade sobre gestão de dados. Este é um nível mais básico de serviços; consulta – suporte sobre uma variedade de questões relevantes para a gestão de dados de pesquisa e; infraestrutura – fornecimento de infraestrutura para gerenciamento e curadoria de dados.

Hiom et al (2015) classificam os serviços em: assistência ao gerenciamento de dados; advocacy e treinamento; armazenamento e suporte à publicação e; presença na web, mídia social e métricas.

Si et al (2015) dividem os serviços em seis aspectos: introdução aos dados de pesquisa; diretrizes do plano de gerenciamento de dados; curadoria de dados e serviços de armazenamento; treinamento em gerenciamento de dados; referência em gerenciamento de dados e; recomendação de recursos.

Tenopir, Birch e Allard (2012) afirmam que os serviços podem ser do tipo informativo/consultivo ou serviços técnicos. Segundo esses autores, os serviços informativos/consultivos são os mais comumente presentes nas bibliotecas.

Yoon e Schultz (2017) examinaram websites de bibliotecas acadêmicas americanas e classificaram os seus serviços em quatro áreas: serviço, informação, educação e rede (links para recursos externos). Contudo, a classificação varia bastante, dependendo do entendimento dos autores.

3 Procedimentos metodológicos

Esta é uma pesquisa de natureza exploratória realizada por meio de levantamento de artigos publicados em periódicos, cuja temática é o suporte à gestão de dados de pesquisa realizado nas bibliotecas. Os artigos foram identificados a partir de pesquisas em bases de dados como a Library and Information Science Abstracts (LISA), Library, Information Science & Technology Abstracts (LISTA), Information Science & Technology Abstracts (ISTA), Google Acadêmico e referências citadas.

A busca retornou 160 resultados, contudo, este trabalho apresenta o inventário e categorização obtida a partir de serviços mencionados em 58 (36,25%) artigos. Assim, este trabalho retrata os primeiros resultados da pesquisa, uma vez que, por questão de tempo, não foi possível realizar o inventário e classificação de todos os 160 artigos encontrados na pesquisa.

Os 160 artigos foram importados para o software de pesquisa qualitativa NVivo, da QSR International. Desses, 58 artigos foram lidos, codificados e categorizados. A seleção desses 58 artigos que compõem o corpus desta pesquisa foi realizada ao acaso, sem intenção prévia.

Para a categorização dos serviços, foram criados nós – categorias de serviços –, estruturados em cinco temas principais – Infraestrutura, Técnico, Suporte, Educacional e Outros.

A categoria "Infraestrutura" é formada pela infraestrutura técnica – como os repositórios e ferramentas ou plataformas para assistência à pesquisa e à gestão de dados – e as políticas institucionais.

Na categoria "Técnico" estão as tarefas técnicas realizadas pelas bibliotecas como a documentação de dados e metadados, depósito de dados, preservação, garantia de acesso, publicação, dentre outros.

A categoria "Suporte" é formada pelos serviços que visam à informação, orientação, aconselhamento e consultoria sobre os mais variados assuntos referentes à gestão e curadoria de dados, como a elaboração de planos de gestão de dados, padrões de metadados, acesso aberto aos dados, melhores práticas de pesquisa, e outros.

A categoria "Educacional" abrange os serviços voltados para a formação em gestão e curadoria de dados como treinamentos, cursos, eventos, elaboração de guias, templates, websites, data literacy, etc.

Nos serviços classificados na categoria "Outros" estão a auditoria para identificação das práticas e necessidades dos pesquisadores; o desenvolvimento de políticas, padrões, diretrizes; a divulgação e promoção de serviços; a identificação de colaboradores, participação em grupos de pesquisa; o planejamento, implementação e avaliação de serviços; etc.

As categorias e subcategorias de serviços (nós e subnós) seguem uma estrutura hierárquica e foram criados com base no referencial teórico da pesquisa e a partir dos temas que emergiram dos artigos analisados.

Após a categorização inicial dos serviços, foi realizado um rearranjo das categorias, hierarquização de termos, uniformização de nomes e união das categorias com assuntos que apresentam afinidades temáticas.

4 Resultados

Os serviços mencionados nos 58 artigos foram classificados em cinco categorias principais, conforme a Figura 1.

Dos 58 artigos analisados, 21 apresentam serviços classificados na categoria Infraestrutura; 39 mencionam serviços da categoria Técnico; 42 apontam serviços agrupados em Suporte; 46 artigos mencionam serviços na categoria Educacional; enquanto 35 artigos tratam de serviços categorizados como Outros. Vale lembrar que um mesmo artigo pode apresentar serviços presentes em mais de uma categoria ao mesmo tempo.

Percebe-se que a maioria dos trabalhos menciona os serviços da categoria "Educacional" (46 artigos ou 79,31%), seguidos pelos serviços da categoria "Suporte" (42 artigos ou 72,41%), conforme apresentado na Figura 1. Assim, os serviços educacionais e de suporte são os mais frequentes, representando uma extensão dos serviços já realizados pelas bibliotecas, ampliados para o trabalho com dados científicos.

Figura 1: Categorias de serviços.

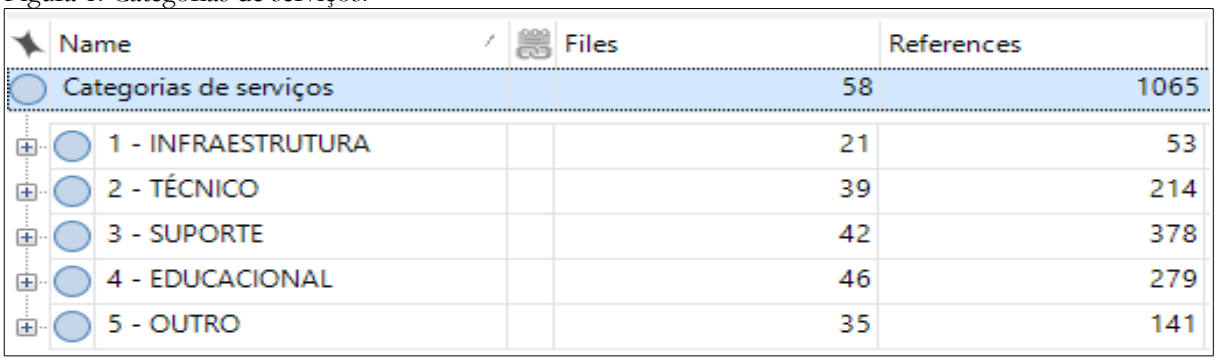

Name	Files	References
Categorias de serviços	58	1065
1 - INFRAESTRUTURA	21	53
2 - TÉCNICO	39	214
3 - SUPORTE	42	378
4 - EDUCACIONAL	46	279
5 - OUTRO	35	141

Fonte: Elaborado pelos autores.

Estes resultados estão de acordo com os trabalhos realizados por Tenopir, Birch e Allard (2012) e Tenopir et al (2017) que identificaram que os serviços informativos/consultivos são os mais realizados pelas bibliotecas; e Reznik-Zellen, Adamick e McGinty (2012) que afirmam que os serviços do nível educacional são os mais básicos. Segundo esses autores, mesmo as bibliotecas que estão fazendo pouco para apoiar a infraestrutura de dados de pesquisa em suas instituições ainda se envolvem em algum tipo de educação.

5 Considerações finais

Este trabalho faz parte de uma pesquisa ainda em andamento, apresentando resultados preliminares. Assim, não foi possível realizar a categorização dos serviços a partir de todos os artigos recuperados na busca realizada para a pesquisa, contudo o corpus utilizado nesta exploração permitiu chegar a um inventário satisfatório de serviços, uma vez que a cada nova inclusão de artigo, notou-se que havia pouca "novidade" em relação ao acréscimo de novos serviços.

Embora não seja possível listar aqui todos os serviços voltados para a gestão de dados de pesquisa realizados pelas bibliotecas, considera-se que este trabalho cumpriu seu objetivo de inventariá-los, bem como criar uma categoria de serviços e agrupá-los conforme a categorização proposta.

Uma visão geral desses serviços e categorias pode ser visualizada no Apêndice A. Em trabalho futuro, pretende-se descrever minuciosamente cada uma das categorias, assim como todos os serviços que a compõem.

Acredita-se, contudo, que a classificação proposta carece de uma reanálise e reagrupamento de serviços e categorias. A partir de um melhor entendimento da área é provável que surja uma nova hierarquização de categorias ou que elas possam ser unificadas ou remanejadas.

Referências

AKERS, K. G. et al. Building Support for Research Data Management: Biographies of Eight Research Universities. **International Journal of Digital Curation**, v. 9, n. 2, p. 171– 191, 2014. Disponível em: <http://www.ijdc.net/index.php/ijdc/article/view/327>. Acesso em: 27 ago. 2018.

ASHLEY, K. Research data and libraries: who does what. **Insights: the UKSG journal**, v. 25, n. 2, p. 155–157, 2012. Disponível em: <http://insights.uksg.org/articles/10.1629/2048-7754.25.2.155>. Acesso em: 21 set. 2018.

CHIWARE, E. R. T.; BECKER, D. A. Research Data Management Services in Southern Africa: a Readiness Survey of Academic and Research Libraries. **African Journal of Library, Archives and Information Science**, v. 28, n. 1, p. 1–16, 2018. Disponível em: <http://search-ebscohost-com.ez27.periodicos.capes.gov.br/login.aspx?direct=true&db=lih&AN=130261946&lang=pt-br&site=ehost-live&authtype=ip,cookie,uid>. Acesso em: 30 jul. 2018.

COX, A. M.; PINFIELD, S. Research data management and libraries: current activities and future priorities. ***Journal of Librarianship and Information Science***, v. 46, n. 4, p. 299– 316, 28 dez. 2014. Disponível em: <http://lis.sagepub.com/cgi/doi/10.1177/0961000613492542>. Acesso em: 24 ago. 2017.

GERACI, D.; HUMPHREY, C.; JACOBS, J. ***Data basics: an introdutory text.*** Ann Arbor: Inter-university Consortium for Political and Social Research (ICPSR), 2012. Disponível em: <https://doi.org/10.7939/R3251FK8F>. Acesso em: 14 set. 2018.

GOLDMAN, J.; KAFEL, D.; MARTIN, E. Assessment of Data Management Services at New England Region Resource Libraries. **Journal of eScience Librarianship**, v. 4, n. 1, p. e1068, 16 jul. 2015. Disponível em: <http://escholarship.umassmed.edu/jeslib/vol4/iss1/4/>. Acesso em: 22 ago. 2018.

HIOM, D. et al. Research data management at the University of Bristol. **Program: electronic library and information systems**, v. 49, n. 4, p. 475–493, set. 2015. Disponível em: <http://www.emeraldinsight.com/doi/10.1108/PROG-02-2015-0019>. Acesso em: 29 maio 2018.

KNUTH, S. L.; JOHNSON, A. M.; HAUSER, T. Research Data Services at the University of Colorado Boulder. **Bulletin of the Association for Information Science and Technology**, v. 41, n. 6, p. 35–38, ago. 2015. Disponível em: <https://www.asist.org/publications/bulletin/aug-2015/research-data-services/>. Acesso em: 30 jul. 2018.

KRAFT, A. **RADAR – A repository for long tail data**. 2015, Hanover, DE: IATUL, 2015. Disponível em: <https://docs.lib.purdue.edu/cgi/viewcontent.cgiZarticle=2099&context=iatul>. Acesso em: 13 fev. 2018.

PERRIER, L. et al. Developing research data management services and support for researchers: a mixed methods study. **Partnership: The Canadian Journal of Library and Information Practice and Research**, v. 13, n. 1, p. 1–24, 2018. Disponível em: <https://journal.lib.uoguelph.ca/index.php/perj/article/view/4115>. Acesso em: 30 jul. 2018.

PRYOR, G. Preface. In: PRYOR, G.; JONES, S.; WHYTE, A. (Org.). **Delivering research data management services: fundamentals of good practice**. London: Facet Publishing, 2014. p. vii–viii.

REZNIK-ZELLEN, R.; ADAMICK, J.; MCGINTY, S. Tiers of Research Data Support Services. **Journal of eScience Librarianship**, v. 1, n. 1, p. 27–35, 2012. Disponível em: <http://escholarship.umassmed.edu/jeslib/vol1/iss1/5/>. Acesso em: 29 maio 2018.

SEARLE, S. et al. Librarians as partners in research data service development at Griffith University. **Program: electronic library and information systems**, v. 49, n. 4, p. 440–460, set. 2015. Disponível em: <http://www.emeraldinsight.com/doi/10.1108/PROG-02-2015-0013>. Acesso em: 6 maio 2018.

SESARTIC, A.; TÖWE, M. Research Data Services at ETH-Bibliothek. **IFLA Journal**, v. 42, n. 4, p. 284–291, 27 dez. 2016. Disponível em: <http://journals.sagepub.com/doi/10.1177/078uopledrsfdrt340035216674971>. Acesso em: 30 jul. 2018.

SI, L. et al. Investigation and analysis of research data services in university libraries. **The Electronic Library**, v. 33, n. 3, p. 417– 449, jun. 2015. Disponível em: <http://www.emeraldinsight.com/doi/10.1108/EL-07-2013-0130>. Acesso em: 30 jul. 2018.

TENOPIR, C. et al. Research Data Services in European Academic Research Libraries. **LIBER QUARTERLY**, v. 27, n. 1, p. 23–44, fev. 2017. Disponível em: <https://www.liberquarterly.eu/articles/10.18352/lq.10180/>. Acesso em: 10 ago. 2017.

TENOPIR, C. et al. Research data services in european and north american libraries: Current offerings and plans for the future. **Proceedings of the Association for Information Science and Technology**, v. 53, n. 1, p. 1–6, 2016. Disponível em: <http://doi.wiley.com/10.1002/pra2.2016.14505301129>. Acesso em: 20 ago. 2018.

TENOPIR, C.; BIRCH, B.; ALLARD, S. **Academic Libraries and Research Data Services: Current Practices and Plans for the Future**. sl.: Association of College & Research Libraries (ACRL), 2012. Disponível em: <http://www.ala.org/acrl/sites/ala.org.acrl/files/content/publications/whitepapers/Tenopir_Birch_Allard.pdf>. Acesso em: 29 jun. 2017. (Whipe Paper).

YOON, A.; SCHULTZ, T. Research Data Management Services in Academic Libraries in the US: A Content Analysis of Libraries' Websites. **College & Research Libraries**, v. 78, n. 7, p. 1–19, nov. 2017. Disponível em: <http://crl.acrl.org/index.php/crl/article/view/16788>. Acesso em: 28 maio 2018.

Vídeo de apresentação

Título: Suporte à gestão de dados de pesquisa nas bibliotecas: identificação de serviços a partir da literatura

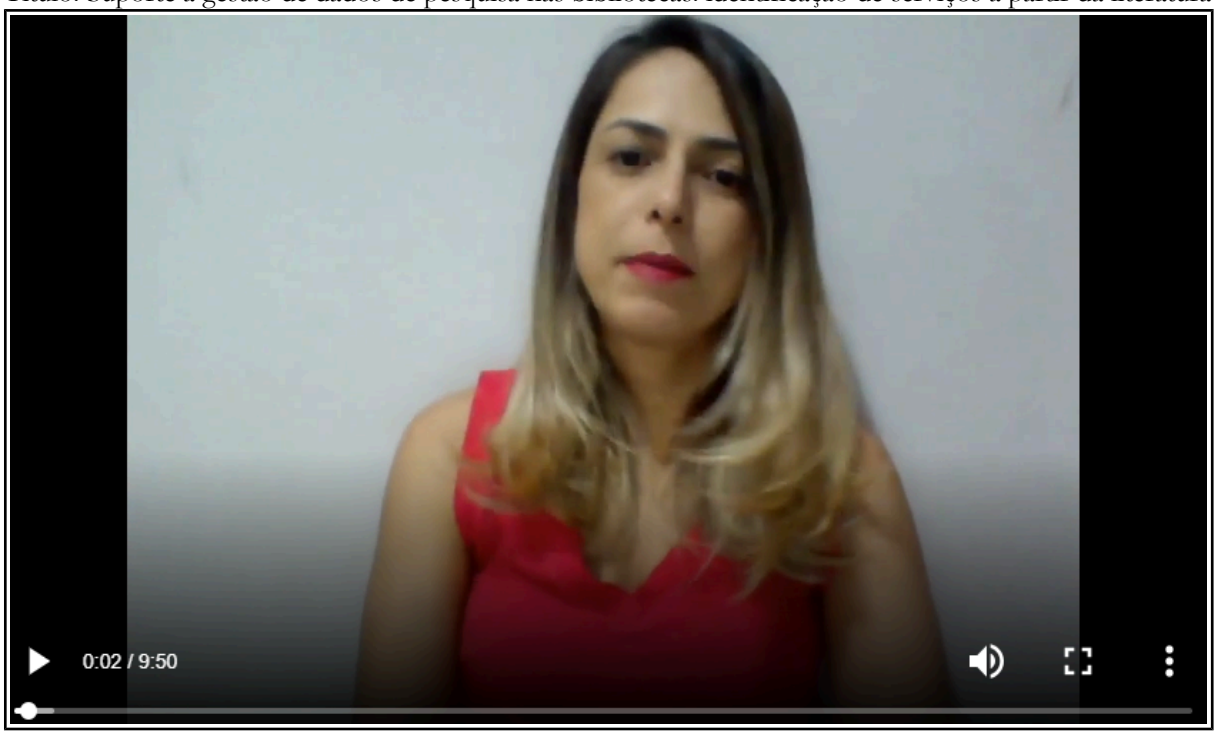

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=1

Transcrição da apresentação

Olá, meu nome é Fernanda e através deste vídeo, será apresentado o trabalho intitulado: Suporte à gestão de dados de pesquisa nas bibliotecas: identificação de serviços a partir da literatura. Este é um trabalho de autoria minha, Fernanda Gomes Almeida e Marcos de Souza, nós somos estudantes de doutorado do Programa de Pós-Graduação em Gestão e Organização do Conhecimento da UFMG.

Este trabalho faz parte do 2º Workshop de Informação Dados e Tecnologia (WIDAT) 2018, que ocorrerá entre os dias 27 e 29 de novembro de 2018 na cidade de João Pessoa na Paraíba.

A gestão de bases de pesquisa tem se tornado uma preocupação crescente nas instituições, isso devido ao reconhecimento do próprio potencial informacional dos dados de pesquisa tanto por parte dos pesquisadores quanto das instituições de pesquisa e das agências de fomento, aliado a isto, a gente tem as pressões externas quanto ao reúso de dados, requisitos de financiadores da pesquisa colaborativa e à ciência aberta, dentre outras pressões. Então tanto o reconhecimento do valor dos dados, quanto às pressões externas representam desafios e oportunidade para que as bibliotecas ofereçam serviços que apoiem os pesquisadores nas gestões dos dados gerais nas suas próprias pesquisas.

Então o que são esses serviços? São serviços que uma biblioteca oferece aos pesquisadores em relação ao gerenciamento de dados, abordando o ciclo de vida completo desses dados, isso vai desde o planejamento para a criação da coleta de dados, passando pela fase de tratamento, pela análise dos dados, a preservação, o acesso e reutilização desses dados.

As universidades e consequentemente as bibliotecas estão começando a descobrir como a gestão de dados deve ser apoiado tanto em termos de consultoria quanto o oferecimento de treinamentos da própria infraestrutura, seja para armazenamento, compartilhamento e procuradoria desses dados. Porém quais são esses serviços que a biblioteca pode oferecer?

Esse trabalho tem como objetivo, inventariar por meio da revisão de literatura os serviços de suporte e gestão de dados desenvolvido nas bibliotecas, então a partir daí, desse inventário dos serviços, propor uma categorização para esses serviços bem como classificá-los de acordo com as categorias propostas.

A metodologia deste trabalho é uma pesquisa que a gente trata de uma natureza exploratória, então ela foi utilizada por meio de um levantamento nos artigos publicados em periódicos cuja a temática é o suporte e gestão de dados de pesquisa realizado nas bibliotecas. O levantamento destes artigos foram realizados nas bases de dados na área de ciência da informação, Liza, Lista, Ista, além do Google Acadêmico e ainda as referências citadas nos artigos.

Nesse levantamento identificou 160 artigos, contudo esse trabalho que a gente apresenta, ele traz um inventário e a classificação obtida a partir de 58 artigos, assim esse trabalho retrata os primeiros resultados de uma pesquisa maior uma vez que até mesmo por questões de tempo não foi possível realizar o inventário e classificação de todos os 160 artigos encontrados na pesquisa.

Os 160 artigos foram importados para o software NVivo, um software para pesquisa qualitativa, em que desses 160 artigos, 58 artigos que compõem tópicos desta pesquisa, foram lidos, codificados e categorizados. A seleção, no entanto, desses 58 artigos não foi realizada ou na verdade ela foi realizada ao acaso sem intenção prévia.

A partir dos 58 artigos, seguiu para a categorização, que segue uma estrutura hierárquica que foram criadas com base nos trabalhos relacionados e também nos temas que emergiram a partir dos próprios artigos analisados, para essa categorização de serviço foram criadas "nós" ou categorias de serviços centrados em cinco temas principais: infraestrutura, técnico, suporte, educacional e outras.

Só para a gente saber não tem como falar de tudo que envolver cada uma dessas categorias, mas vou falar um pouquinho de cada uma delas. A categoria infraestrutura, contém as ferramentas da plataforma para gestão e curadoria de dados além das políticas da própria instituição.

Na categoria técnico a gente tem as técnicas e os serviços técnicos realizados pelas bibliotecas como a documentação de dados e metadados, o depósito de dados, a preservação, garantia de acesso, publicação, dentre outros serviços.

Na categoria suporte a gente tem os serviços que visa informação, orientação, aconselhamento e consultoria sobre os mais variados assuntos referência a gestão e curadoria de dados, como elaborar planos de gestão de dados, padrões de metadados, acesso aberto aos dados e melhores práticas de pesquisa.

Já a categoria educacional, abrange serviços voltados para formação em gestão e curadoria de dados como treinamento em discurso, os eventos, elaboração de guias, e os próprios sites, isso informação tanto pesquisador como a própria formação ainda também dos bibliotecários ou da equipe que faz parte desses serviços.

Na categoria "outros" a gente tem a identificação das práticas e necessidade dos pesquisadores, o desenvolvimento de políticas, padrões, diretrizes, divulgação e promoção de serviços, identificação de colaboradores, participação de grupos de pesquisa, planejamento de implementação e avaliação de serviços.

Após esta categorização inicial dos serviços foi realizado um rearranjo dessas categorias a uniformização de nomes e a união das categorias com assuntos que já representem as afinidades temáticas.

Como o resultado desse trabalho é de 58 artigos analisados, 21 deles apresentam serviços classificados na categoria infraestrutura, 39 apresenta os serviços que foram classificados na categoria técnico, 42 aponta os serviços agrupados na categoria suporte, 46 deles mencionam os serviços na categoria educacional e 35 artigos tratam de serviços categorizadas como outros. Assim vale lembrar que o mesmo artigo pode apresentar serviço tanto presente em uma categoria quanto em outra categoria também.

A partir desses resultados a gente percebeu que a maioria menciona serviços da categoria educacional 46 artigos, seguido pela categoria suporte com 42 artigos, e esse serviço dessas duas categorias educacional e suportes são serviços mais presentes nas bibliotecas.

Esses resultados que a gente descobriu a partir da literatura converge com outros trabalhos já publicados que apontam que esses dois tipos de serviços são os mais frequentes nas bibliotecas, contudo, o resultado desse trabalho é o próprio inventário, proposição de categorias e reclassificação desses serviço nessas categorias, isso tudo não dá para a gente mostrar ele, dá para citar cada um deles, mas pode ser conferido no apêndice deste trabalho que será publicado.

Este trabalho faz parte de uma pesquisa em andamento apresentando assim os resultados preliminares, apesar disso, o corpus utilizado nesta exploração com 58 artigos que não tinham chegado a inventário satisfatório de serviços, uma vez que cada nova inclusão de artigo para análise notou-se pouca novidade com relação ao acréscimo de novos serviços

Embora não seja possível falar aqui todos os serviços, considera-se que este trabalho cumpriu o objetivo de inventariá-los e classificá-los conforme a categorização que a gente propôs em cinco níveis.

Como trabalho futuro a gente pretende descrever minuciosamente cada uma dessas categorias, acredita-se com tudo na verdade que essa classificação proposta ainda carece de reanálise e re-educamento de serviços e categorias, até mesmo com a própria identificação a partir dos próprios artigos que a gente tem trabalhado.

Bom, então esse é o nosso trabalho caso queira mais informações entre em contato com gosto, os contatos estão disponíveis na descrição desse vídeo.

Revolução Científica? Reflexões para uma teoria crítica da Ciência dos Dados

Max Melquíades da Silva [a] *e Simone Cristina Dufloth*[b]

Resumo: O trabalho apresenta uma investigação teórico-conceitual que analisa, à luz da noção de paradigma científico na filosofia da ciência, especialmente os estudos epistemológicos pós-popperianos de Thomas Kuhn (1994) e Inre Lakatos (1979), as características do chamado quarto paradigma da ciência (e-Science). O paradigma da e-Science é apresentado por Gray e outros (2009) como um novo padrão intelectual de produção de conhecimento científico baseado no trabalho intensivo com dados tem conseguido consolidar uma ampla comunidade de prática de pesquisa ao redor do mundo. O trabalho evidencia o excesso de pesquisas de estudo de caso, em contraposição a escassos trabalhos teórico-conceituais que explicitem e discutam os fundamentos teóricos e epistemológicos da e-Science.

Palavras-chave: e-Science. Big data. Epistemologia.

Scientific revolution? Reflections for a critical theory of Data Science

Abstract: The paper presents a theoretical-conceptual research that analyzes, in light of the notion of scientific paradigm in the philosophy of science, especially the post-Popperian epistemological studies of Thomas Kuhn (1994) and Inre Lakatos (1979), the characteristics of the so-called fourth paradigm of science (e-Science). The paradigm of e-Science is presented by Gray et al. (2009) as a new intellectual standard of scientific knowledge production based on data intensive work has managed to consolidate a wide community of research practice around the world. The work evidences the excess of case study research, as opposed to scarce theoretical-conceptual works that explain and discuss the theoretical and epistemological foundations of e-Science.

Keyword: e-Science. Big data. Epistemology.

a Universidade Federal de Minas Gerais (UFMG). E-mail: iemax@bol.com.br. ORCID: https://orcid.org/0000-0003-3372-8615. Currículo: http://lattes.cnpq.br/5624247693651969

b Fundação João Pinheiro. E-mail: sduf@uol.com.br. ORCID: https://orcid.org/0000-0002-1963-7365. Currículo: http://lattes.cnpq.br/6166815079725368

1 Introdução

Se a história da ciência no século XX é caracterizada pela emergência de um sem número de recortes temáticos e a consolidação de diversas áreas do conhecimento com o status de ciências (SHAPIN, 1996), o fim do século reservava inovações tecnológicas que permitiriam aumentar a escala e a rapidez das transações informacionais – o que em última instância altera a forma e o ritmo do trabalho científico e a interação entre áreas do conhecimento.

A possibilidade de gerar novos dados de pesquisa em um volume sem precedentes é vista por cientistas de dados como uma realidade análoga à descrita pela lei de Moore ao se referir ao aumento progressivo da capacidade de processamento dos computadores com redução de custos: Em intervalos regulares de tempo o volume de dados cresce e o custo diminui: o desafio se desloca da obtenção para o tratamento e análise desses dados (SAYÃO e SALES, 2015). Nessa linha, Gray aponta para o fato de que a evolução em curso estaria transformando a própria dinâmica da ciência e seus paradigmas: "Quase tudo sobre ciência está mudando por causa do impacto da tecnologia da informação. A ciência experimental, teórica e computacional está sendo afetada pelo dilúvio de dados, e um quarto paradigma da ciência, 'intensivo em dados', está emergindo. O objetivo é ter um mundo em que toda a literatura científica esteja on-line, todos os dados científicos estejam on-line e eles interajam uns com os outros" (GRAY, 2009, 29).

Conforme Gray, uma das maiores referências em se tratando de quarto paradigma da ciência, mesmo nas "ciências de poucos dados" (Idem, p. 20) o trabalho do cientista consiste cada vez mais em analisar a informação disponível – com crescente emprego de recursos de software e hardware – em detrimento dos processos tradicionais de coleta. Nesse sentido, uma das mudanças mais significativas na pesquisa contemporânea residiria justamente no surgimento de "um novo padrão intelectual de produção de conhecimento científico – conhecido como o Quarto Paradigma Científico ou e-Science – caracterizado pela produção e uso intensivo de dados e pelo compartilhamento e colaboração baseados em rede de computadores de alto desempenho" (SALES e SAYÃO, 2015).

Mas como se constitui e evolui um paradigma científico? As transformações em curso no sentido de uma crescente ressignificação do dado como unidade de análise e sentido chegam a constituir um novo paradigma? A produção teórico-conceitual no campo da ciência da informação tem acompanhado o progressivo trabalho com big data?

2 Objetivos e metodologia

Este trabalho busca analisar, à luz da noção de paradigma científico na filosofia da ciência, as características do chamado quarto paradigma da ciência. O trabalho apresenta uma investigação exploratória através de revisão bibliográfica. No próximo tópico são apresentadas características acerca do chamado quarto paradigma da ciência como descritas por alguns de seus principais expoentes. Na sequência, analisa-se como surge um paradigma científico segundo a visão de Thomas Khum e Inre Lakatos, dois dos mais destacados nomes do pensamento científico pós-popperiano. Por fim, são discutidas questões acerca da base teórica que sustenta as discussões e trabalhos empíricos no campo da e-Science.

3 O chamado quarto paradigma da ciência: história e características

As inovações na pesquisa científica a partir das mudanças no volume de dados e no emprego de estratégias e instrumentos computacionais para sua análise tem sido chamada de e-Science e o primeiro registro histórico dessa nomenclatura é atribuído ao diretor-geral do Escritório de Ciência e Tecnologia do Reino Unido, John Taylor, em um documento de 1999. A utilização do termo, contudo, foi ganhando amplitude no decorrer da década de 2000, com o avanço das tecnologias de computação em nível de software e hardware. O termo, que experimentou algumas variações semânticas, talvez por sua amplitude, faz referência a métodos de obtenção de resultados científicos através da utilização de computação intensiva, paralela ou distribuída, de imensos volumes de dados.

O termo e-Science tem sido mais amplamente utilizado desde então, como "a aplicação da tecnologia da computação para a realização de investigação científica moderna, incluindo a preparação, experimentação, coleta de dados disseminação de resultados, armazenamento em longo prazo e acessibilidade de todos os materiais gerados através do processo científico, tais como modelagem e análise de dados, notebooks de laboratório, conjuntos de dados brutos e ajustados, produção de manuscritos e versões preliminares, pré-impressões, e publicações impressas e ou eletrônicas" (BOHLE, 2013, p. 1 – tradução nossa).

Outros conceitos têm sido empregados para designar a nova área científica: "eScience", "ciência orientada para dados" (data-driven Science), "ciberinfraestrutura", "quarto paradigma", "dos dados ao conhecimento". Em todos eles está presente a ideia de que cientistas da computação se unem a pesquisadores de diferentes domínios para o desenvolvimento de novos conceitos e teorias a partir de grandes massas de dados, em um trabalho que envolve hardware, software e processos que possibilitem a captura, armazenamento, análise e visualização dos dados.

A noção de um "quarto paradigma" da ciência ganha impulso a partir da publicação da obra homônima, em 2009, e da contribuição de diversos autores motivados pelo trabalho do cientista norte-americano James Nicholas "Jim" Gray. Gray foi um renomado cientista da computação que atuou em laboratórios científicos da IBM e da Microsoft. Entusiasta da noção de e-Science, Gray desapareceu no mar em 28 de janeiro de 2007 – junto com seu barco – poucos dias após proferir a palestra que, transcrita, abre o livro em questão[7]. Nele Gray apresenta sua visão sobre a evolução dos paradigmas científicos. Ele concebia a "ciência intensiva em dados" ou "e-Science" como um "quarto paradigma" da ciência (empírica, teórica, computacional e agora baseada em dados). A ciência empírica ou experimental caracteriza o primeiro paradigma, que cedeu lugar às generalizações teórico-conceituais resultantes do uso de modelos abstratos. O terceiro paradigma é baseado nas simulações assistidas por computadores ou outros equipamentos tecnológicos, enquanto o quarto paradigma é resultante da exploração de dados capturados ou gerados pela simulação.

7 Gray, um experiente marinheiro, possuía um iate de quarenta pés. Em 28 de janeiro de 2007, ele não retornou de uma curta viagem solo às Ilhas Farallon, a 43 km de San Francisco, para espalhar as cinzas de sua mãe. O tempo estava claro e nenhuma chamada de socorro foi recebida e nem sinais automáticos de emergência detectados. Uma busca de quatro dias pela Guarda Costeira usando aviões, helicópteros e barcos não encontrou nada. Em 16 de fevereiro, esta busca foi suspensa, e uma busca subaquática usando equipamentos sofisticados terminou em 31 de maio.

Em sua análise, Gray (2009) aponta alguns caminhos que caracterizam ou deveriam caracterizar o quarto paradigma:

- A comunicação científica pode deixar de apresentar apenas resultados finais na forma de publicações, mas passa a ter a possibilidade de também partilhar os próprios dados brutos da pesquisa, ampliando a possibilidade de falseamento e novas pesquisas utilizando os mesmos dados;
- As bibliotecas digitais podem experimentar novas formas de distribuição das publicações em diferentes países, idiomas e mais baixos custos em relação à publicação em revistas tradicionais;
- A revisão por pares pode experimentar novos processos ou estruturas digitais e serviços como wikis podem ser criados online para ampliar a discussão sobre os trabalhos após a publicação;
- A internet está se tornando um sistema orientado a objeto, cada vez mais dependente de ontologias, vocabulários controlados e esquemas conceituais que possibilitem dar mais confiabilidade ao significado das coisas e à interação entre diferentes sistemas;
- Bibliotecas de dados digitais podem ser fomentadas, para além de bibliotecas de publicações acabadas.

O paradigma emergente envolveria colaboração de pesquisadores em computação com pesquisadores de outras áreas do conhecimento, além de métodos computacionais sofisticados para lidar com grandes volumes de dados (Big Data), alçados agora à condição de objetos intelectuais de primeira grandeza. Computadores, bancos de dados e redes não são vistos e utilizados apenas como ferramentas, mas se tornam uma parte fundamental do processo de descoberta de conhecimento e mesmo de interpretação dos dados. Assim, o novo paradigma agrega, a seu instrumental, métodos e algoritmos para analisar os dados armazenados nessas bases de grande escala, além de protocolos de comunicação padronizados que possibilitem a interação entre todas essas fontes de dados.

No Brasil, Sayão e Sales (2015) são alguns dos mais entusiasmados pesquisadores engajados na reflexão e prospecção de um modelo e uma infraestrutura para e-Science, especialmente no que diz respeito a novas fontes de pesquisa, arranjos para novos serviços em diversos estágios do processamento dos dados de pesquisa e uma oportunidade para a reinvenção das bibliotecas de pesquisa. Para eles, "o digital não é o antagônico do impresso, como o rolo de papiro não é o antagônico do livro e a tecnologia não é algo estranho à biblioteca" (SALES e SAYÃO, 2015, p. 33). Embora neguem um eventual antagonismo, os autores se mostram entusiastas de uma ciência orientada para dados. Para eles, "a convergência de tecnologias de computação, armazenamento on-line, redes de alto desempenho, somados ao desenvolvimento de instrumentos científicos, escalas, dispositivos experimentais e sensores cada vez mais sofisticados e ao uso intensivo de simulações, desloca a pesquisa científica contemporânea na direção de uma ciência orientada por dados, onde o maior problema não é a escassez, mas sim o excesso de dados e a capacidade de interpretar seus padrões ocultos na forma" (Idem, p. 34).

4 O surgimento de novos paradigmas científicos

Nesta seção, recorreu-se aos estudos epistemológicos pós-popperianos de Thomas Kuhn (1994) e Inre Lakatos (1979), caracterizados por uma estreita conexão com a história da ciência na tentativa de compreensão dos programas de pesquisa científica[8].

Kuhn se debruçou sobre o que ele chamou de paradigma científico, termo com o qual buscava designar um conjunto de "conquistas científicas universalmente reconhecidas, que por certo período fornecem um modelo de problemas e soluções aceitáveis aos que praticam em certo campo de pesquisas" (KUHN, 1994, p. 23).

Esse conceito culmina na noção de programa de pesquisa. Com efeito, programa de pesquisa é como Kuhn (1994) chama o estudo acadêmico de determinado tema no interior de uma ciência ou conjunto de ciências – no caso de objetos caracterizados pela interdisciplinaridade. Ao redor daquele programa de pesquisa se reúne um grupo de pesquisadores denominado comunidade científica (KUHN, 1994).

Dentre os membros da comunidade científica, Kuhn (1994) afirma que alguns ganham destaque sobre os demais, devido, basicamente, a dois fatores: a ordem cronológica de publicação dos trabalhos – estudos precursores que enfatizam um aspecto particular do programa de pesquisa e que ganham adeptos podem fazer originar uma nova comunidade científica; outro fator é a originalidade, associada ao grau de aceitação dos trabalhos por parte dos demais membros da comunidade. Na teoria kuhniana a comunidade científica está caracterizada pela prática do que ele chama de ciência normal, que é a "pesquisa estavelmente baseada em um ou mais resultados alcançados pela ciência do passado, aos quais uma comunidade científica particular, por certo período de tempo, reconhece a capacidade de constituir o fundamento de sua práxis ulterior" (KUHN, 1994, p. 68).

A ciência normal consiste, então, na tentativa de realização das promessas do paradigma de pesquisa, aprofundando as pesquisas originárias e confrontando as formulações com a realidade, articulando novos conceitos e sugerindo novas ferramentas com as quais provê o paradigma. A teoria de Kuhn sugere que o trabalho do cientista normal órbita ao redor das noções basilares do paradigma e os eventuais problemas teóricos e práticos que encontrar tendem a significar antes uma deficiência do pesquisador do que das construções originárias do paradigma. Isso se deve à noção de ciência normal, que consiste no estado de uma ciência na qual, suas pesquisas e seus resultados são previsíveis e os métodos e resultados das pesquisas corroboram os resultados esperados da pesquisa. Entretanto, podem ocorrer crises, por meio de anomalias sucessivas que não se conformam com os resultados esperados. Se a quantidade desses "problemas" cresce demasiadamente, inicia-se um período de crise do paradigma em que se começa a questionar a validade de suas concepções iniciais: é a fase da ciência extraordinária, em que se colocam os dogmas em questão e cresce o movimento dos pesquisadores 'reformistas'. Esse movimento pode desencadear uma revolução científica, momento em que um novo paradigma sobressai em relação ao anterior por meio da "conversão" dos cientistas às promessas do novo paradigma. Kuhn (1994) afirma que essa conversão pode se dar por diversas razões: por convencimento, pela

8 Esta seção condensa parte da análise epistemológica desenvolvida por ocasião da dissertação de mestrado de um dos autores deste artigo (SILVA, 2008).

sedução que as novas ideias proporcionam (caráter emocional) por familiaridade, nacionalidade e até mesmo por razões estéticas.

A explicação oferecida por Kuhn ao progresso da ciência evidencia um elemento 'problemático' nesta. A ciência de que o autor fala já não é aquela catedrática da 'objetividade científica', da imparcialidade metodológica e das certezas conceituais: é uma ciência que pressupõe escolhas às vezes arbitrárias, cujos pesquisadores não podem ignorar assaltos da dimensão emocional e precisam endossar os dogmas que a sustentam, sob pena de 'perder seu chão', as bases teóricas de sua produção.

A mesma postura crítica quanto aos pressupostos metodológicos frequentemente empregados na atividade científica é encontrada na obra de Imre Lakatos (LAKATOS, 1979), que também estuda a temática dos programas de pesquisa e apresenta pontos de convergência e de divergência com o trabalho de Kuhn. Sobre as teorias científicas, Lakatos (1979) argumenta que é componente essencial ao progresso da ciência a concorrência entre programas de pesquisa antagônicos. A partir do estudo da crítica à teoria de Kuhn, Lakatos deu um importante passo na filosofia da ciência ao formular a tese segundo a qual os sistemas teoréticos são compostos por um núcleo forte portador de características que o definem como programa, circundado por um cinturão de suporte, constituído de hipóteses e suposições auxiliares que poderiam ser refutadas sem prejuízo para o programa como um todo.

Quando submetido a testes, o núcleo forte da teoria que possui o papel de "pressuposto básico" não é afetado, de modo que é o cinturão, e não a teoria central em si, que passa pelo processo de averiguação. Desta forma, uma anomalia em qualquer teste afeta unicamente o cinturão de proteção e jamais a teoria central (SILVA, 2008). Esse núcleo – por decisão metodológica dos pesquisadores – é considerado não falseável, isto é, geralmente não se contestam no interior do programa as ideias contidas no seu núcleo fundamental porque sua destruição implicaria problemas para o programa como um todo. A teoria de suporte que acaba sendo refutada pode ser substituída por outra, mas para Lakatos o caso mais comum é o de reforçar a cinta de proteção do núcleo com teorias ad hoc, ou seja, teorias auxiliares não possuem propósito algum a não ser o de sustentar o núcleo forte.

Embora sedutora, a teoria de Lakatos não escapou de importantes críticas. Ao extremo, pode-se cogitar que a priori nenhum programa de pesquisa poderia ser refutado, uma vez que seu núcleo não-falseável poderia ser mínimo a ponto de conter somente princípios amplamente aceitos, e suas teorias de suporte – que efetivamente desenvolvem as ideias do programa – podem ser pragmaticamente descartadas conforme tenham dificuldade de resistir a novas críticas. Lakatos admitia a existência dessa possibilidade mas asseverava que, para um programa científico, o acúmulo de teorias ad hoc é desconfortável. Com efeito, este acúmulo leva a comunidade científica a aderir a determinada teoria em detrimento de outra. A nova teoria nem sequer precisa responder a todas as questões que a anterior respondia, bastando que ela responda um número satisfatório de problemas (dentre esses, alguns que a anterior não conseguia responder) e não ter um número grande de fundamentações ad hoc (SILVA, 2008).

5 Considerações finais

As breves considerações sobre como Khum e Lakatos entendem a formação de um paradigma científico possibilitam lançar luzes sobre o atual momento histórico. Primeiramente, independentemente da designação que demos é inegável o fenômeno do trabalho com grandes dados na produção científica e seus resultados, cujos exemplos mais notórios são o projeto do genoma humano e os aceleradores de partículas que produzem uma infinidade de dados impossíveis de se processar e analisar sem um suporte computacional. O surgimento de uma comunidade de pesquisa trabalhando com grandes dados é, portanto, um fenômeno do mundo da práxis que convive com uma ainda incipiente produção teórico-conceitual que a fundamente. Uma rápida pesquisa em portais de periódicos demonstra que há muito mais pesquisa sobre casos de implementação de e-Science que estudos predominantemente acerca de sua epistemologia, seus fundamentos conceituais ou os aspectos éticos e políticos sem os quais o pensamento científico não se completa – permanece no campo da técnica.

Por sua vez, tentativas de refutação da e-Science não são raras, sendo Martin Frické um de seus maiores críticos. Frické (2015) é cético em relação à possibilidade de o big data produzir uma lógica de descobertas científicas universais ou ferramentas de inferência e refutação que torne a e-Science paradigmática. Para ele, a lógica indutiva por trás do trabalho com dados é falível e contaminada pela teoria: "Os instrumentos são construídos ou adotados à luz do que sabemos ou das teorias que temos", uma vez que "dados não falam (…); é necessário uma enorme quantidade de conhecimento básico ou suposições ou pesquisa prévia" (FRICKÉ, 2015, pp. 5-6).

Tal como vem se configurando, o fenômeno da e-Science, a despeito da resistência sofrida, vem diluindo ainda mais algumas tênues fronteiras entre várias ciências – queremos destacar as ciências da informação e da computação – sem chegar a constituir apenas uma disciplina autônoma (e-Science), mas uma concepção de ciência e de fazer científico distinta do que se via até então. Talvez não valha a pena entrar em uma discussão se é adequado ou não chamar esse movimento de um novo paradigma científico. O mundo e a natureza fornecem 'resistência' a nossas conceituações arbitrárias sob a forma de anomalias, situações em que fica claro que algo está errado com as estruturas atribuídas ao mundo por nossas construções conceituais aleatórias. Nesse sentido, o tempo e a produção teórico-conceitual da e-Science em diálogo com a tradição científica poderão atestar seu alcance e falsear seus pressupostos, embora seja forçoso reconhecer a urgência de mais fundamentos (núcleo fundamental e teorias ad hoc) para que se possa mais confortavelmente chamá-la de um novo paradigma científico. A esse respeito, embora sem mencionar especificamente a e-Science, refletia Boaventura Santos há 30 anos: "Depois da euforia cientista do século XIX e da consequente aversão à reflexão filosófica, bem simbolizada pelo positivismo, chegamos a finais do século XX possuídos pelo desejo quase desesperado de complementarmos o conhecimento das coisas com o conhecimento do conhecimento das coisas" (SANTOS, 1988, p. 57). Precisamos conhecer mais como a e-Science quer conhecer o mundo.

Referências

BOHLE, Shannon. (2013, 12 June). What is E-science and How Should it be Managed? **Scientific and Medical Libraries. Scilogs. Nature and Spektrum der Wissenshaft**.

Disponível em: http://www.scilogs.com/scientific_and_medica l_libraries/what-is-e-science-and-how-should-it-be-managed/. Acesso em setembro de 2018.

FRICKÉ, Martin. Big data and its epistemology. **Journal of the Association for Information Science and Technology**. 66, 4, p. 651-661 11 p., 2015.

GRAY, Jim. **Jim Gray on eScience**: A Transformed Scientific Method. Edited by Tony Hey, Stewart Tansley, and Krist in Tolle. In: Hey, T., Tansley, S. and Tolle, K. (Ed.). The Fourth Paradigm: dataintensive scientific discovery. Redmond, WA, USA: Microsoft Research, 2009.

KUHN, Thomas. **A estrutura das revoluções científicas**. São Paulo: Perspectiva, 1994.

LAKATOS, Inre; MUSGRAVE, Alan (Org.). **A crítica e o desenvolvimento do conhecimento**: Quarto volume das atas do colóquio internacional sobre Filosofia da Ciência, realizado em Londres em 1965. Trad.: Octavio Mendes Cajado. São Paulo: Cultrix e EDUSP, 1979.

SALES, Luana Farias; SAYÃO, Luís Fernando. Há Futuro para as Bibliotecas de Pesquisa no Ambiente de eScience? **Informação & Tecnologia**: Marília/João Pessoa, 2(1): 30-52, jan./jul., 2015.

SANTOS, Boaventura de Sousa. Um discurso sobre as ciências na transição para uma ciência pós-moderna. **Estudos avançados.** Vol.2 no.2 São Paulo May/Aug. 1988. http://dx.doi.org/10.1590/S0103-40141988000200007. Acesso em setembro de 2018.

SHAPIN, Steven. **The Scientific Revolution**. Chicago: The University of Chicago Press, 1996.

SILVA, Max Melquíades da. A gestão do conhecimento entre as propostas teórico-conceituais e a efetividade de sua implementação na administração pública: problemas e possibilidades. 2008. 175 f. **Dissertação** (Mestrado em Administração Pública) - Fundação João Pinheiro, Belo Horizonte, 2008.

Vídeo da apresentação

Título: Revolução Científica? Reflexões para uma teoria crítica da Ciência dos Dados.

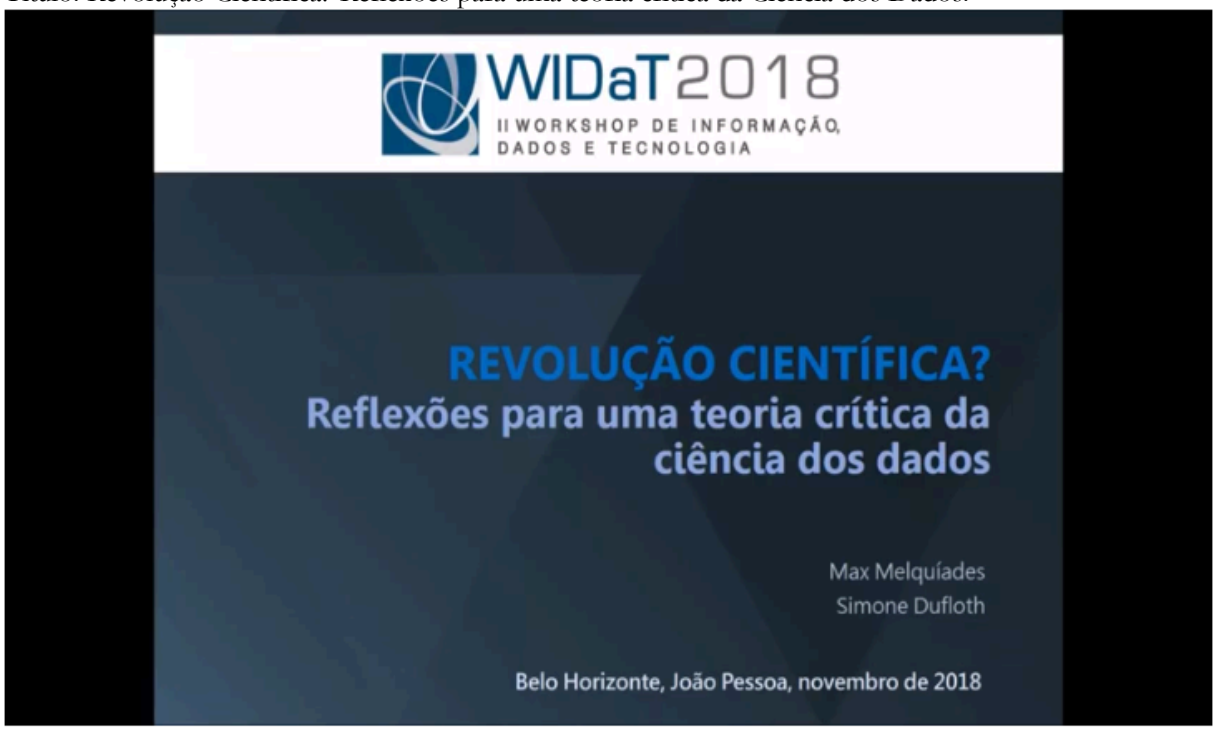

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=2

Transcrição da apresentação

Olá participantes do WIDAT 2018, meu nome é Max e eu quero apresentar esse trabalho que a gente submeteu para o evento: Revolução científica? Reflexões para uma teoria crítica da ciência dos dados. Um trabalho meu e da professora Simone Dufloth que deixo aqui as apresentações, professora Simone é Doutora em Ciência da Informação pela UFMG e eu Max sou doutorando em gestão e organização do conhecimento também pela UFMG e ficam aqui os nossos contatos.

Bem o trabalho vai seguir essa organização e o trabalho escrito segue essa organização em que a gente também a utilizou aqui para apresentação online. Vamos lá então, a gente sempre gosta de começar a falar desse tema falando sobre essas recentes inovações tecnológicas que tem permitido uma mudança significativa na forma de trabalho da ciência como escala de dados nunca antes vista.

Alguns teóricos têm feito paralelo com a lei de Moore, que trazia essa premissa de que a cada ano e meio aproximadamente, a velocidade de processamento das informações dos dados duplicaria com uma razoável redução também dos custos, nenhuma redução proporcional dos custos de produção de processadores e dos transistores que se utilizavam na época e agora a gente vive uma época também com um aumento significativo no volume de dados produzidos com redução dos custos de acesso a esses dados, de tal forma que o desafio nesse momento se desloca no tratamento desses dados em detrimento da sua obtenção que hoje se torna algo mais simples de se fazer em comparação com períodos passados, de tal forma que alguns teóricos têm falado da emergência de um quarto paradigma da ciência, que é um paradigma focado em uma lógica computacional de trabalho com grandes volumes de dados.

Então a partir disso a gente propôs essas questões de pesquisa como evoluir um paradigma científico? As transformações em curso no sentido de uma crescente ressignificação do dado como uma unidade de análise chega a constituir um novo paradigma? A produção teórico-conceitual no campo da ciência da informação tem acompanhado esse progressivo trabalho com Big Data?

A partir dessas questões a gente se propôs a este objetivo de analisar à luz da noção de paradigma científico na filosofia da ciência, as características desse paradigma da e-Science e fizemos isso em um trabalho eminentemente de revisão bibliográfica a gente se fundamenta muito na obra desses dois teóricos pós-popperianos, o Thomas Kuhn e Inre Lakatos, dois teóricos que abordam questão da evolução o progresso da ciência.

Então primeiramente a gente fala dessa noção do quarto paradigma, eles surgem na primeira década do ano de 2000 do século né 21 e um dos trabalhos mais significativos nesse sentido e o trabalho de Gray, que consegue uma ciência intensiva de dados efetivamente como um novo paradigma, sendo primeiro um paradigma da ciência empírica depois uma ciência teórica, e ciência computacional e agora já seria uma ciência baseada em dados, resultante dessa exploração de dados que são capturados da natureza ou gerados por simulações por experimentos sempre com suporte computacional.

Esse paradigma na perspectiva de Grey seria caracterizado entre outros por esses elementos uma comunicação científica que já não se restringe a comunicar resultados de publicações

finalizadas mas também dados de pesquisa ainda em construção, em dados primários e tal forma que outros pesquisadores possam também a partir desses dados fazer suas simulações, testar hipóteses, tentar refutar ou não, os resultados podem fazer um trabalho na tentativa de falseamento desses dados. Bibliotecas digitais que podem experimentar novas formas de publicações inclusive dados brutos. A revisão por pares passaria a ter essa possibilidade não apenas de descer uma palavra final para dizer que um elemento e tem um artigo, uma publicação pode efetivamente ganhar a comunidade científica, pode ser digamos é referendado, oficializada, publicada, mas você teria possibilidade de construções coletivas, você tem a possibilidade de utilizado pelas digitais ter uma construção permanente de um texto, ou seja, não é porque já recebi uma aprovação dos pares que esse texto está pronto, tá bom, e outros leitores, outros pares também podem continuar colaborando inclusive através de wikis para aperfeiçoar esse trabalho. A internet passa estar cada vez mais controlada por ontologias, vocabulários controlados e outras formas de trabalho propostas ou providas digamos assim pela ciência da informação e a colaboração entre pesquisadores também passa a ter muito mais possibilidades.

Nessa mesma linha no Brasil, Luís Fernando Sayão e Sales são dois dos teóricos mais conceituados nesse sentido de uma reflexão a cerca da e-Science, eles estão sobretudo nessa perspectiva de uma pensada, uma infraestrutura para e-Science e novas possibilidades para bibliotecas de pesquisa.

A partir dessa caracterização muito sucinta, muito breve, a gente traz mais elementos no trabalho escrito, a gente quis pensar o que os filósofos da ciência pensam de um paradigma científico? Até para a gente analisar que ponto que e-Science pode ser caracterizada efetivamente como o quarto paradigma.

Então a gente trouxe que as noções do Tomas Kuhn, com ele traz vários conceitos importantes para a gente compreender a evolução dos paradigmas científicos e a primeira não são Justamente a noção de paradigma que é um mapa, um roteiro através do qual os cientistas dentro de um determinado campo atuam na elaboração de propostas para solução de problemas daquele campo de pesquisa. A noção de enigma, problemas que o paradigma permite resolver e fazer avançar aquele campo do conhecimento, anormalidades problemas persistentes, meio que se recusam a ser resolvidos pelo conteúdo já provido pelo paradigma nesses elementos que desafiam as regras existentes naquele momento.

Isso introduz também de crise que é justamente essa desconfiança no paradigma, parte justamente de um excesso de anormalidades de elementos que aquele paradigma não dá conta de resolver, a noção de revolução científica que reside nessa ideia de uma ruptura e nisso toma com marca uma ruptura também com pensamento anterior a ele sobre todo o pensamento de Karl Popper, que enxergava possibilidade de uma evolução gradual na ciência.

O Thomas Kuhn não fala de rupturas abruptas, efetivamente de revoluções, ele entende que na ciência o progresso se dá dessa forma, através de revoluções realmente as marcantes e alguns exemplos clássicos aí para balizar essa perspectiva nessa disputa entre geocentrismo x heliocentrismo, então passa-se de uma visão em que a Terra era o centro do mundo, do universo, para uma visão em que a gente tem a verdade o sol como centro de um sistema solar de uma galáxia e vários outros cosmos, várias outras estrelas e planetas orbitando aquele corpo que seria

o sol. Também nessa perspectiva do criacionismo e do evolucionismo, nessa passagem de uma perspectiva de que um ser criou tudo para uma perspectiva já darwinista de que na verdade houve um processo de evolução que durou milhões de anos para você chegar, para as coisas chegarem até o grau status que estão hoje, a gente tem uma ruptura brusca na forma de concepção do mundo e da forma como as coisas evoluíram conforme cada perspectiva.

O Inre Lakatos ele traz de novidade em relação de partida de vários elementos convergentes em relação a teoria do Kuhn, mas a gente quis destacar programa de pesquisa, então ele percebe a ciência como organizar em torno de vários programas de pesquisa que oferecem regras metodológicas e o corpus teórico também que banaliza o trabalho do cientista e ele entende que o crescimento da ciência acontece por meio da competição entre programas de pesquisa rivais e essa noção de que todo o programa de pesquisa possui núcleo rígido, núcleo duro, tem várias traduções diferentes para esse conceito, mas sempre um núcleo duro que consiste nas ideias fundamentais daquele programa de pesquisas, essa é uma ação conjunto de construções que não pode ser refutado por que se não implicaria numa crise para todo esse programa de pesquisa e entorno deste núcleo rígido, dessas ideias fundamentais que constituem um programa de pesquisa, estaremos no cinturão protetor composto por teorias, hipóteses auxiliares que podem ser refutadas que podem ser falseadas sem maiores problemas para o programa como um todo, inclusive ideias ou teorias que vão surgindo ao longo do tempo até para dar conta de novos problemas que vão sendo identificados por aquele programa de pesquisa.

Parte dessa breve revisão de literatura a gente traz para discussão, algumas ideias e pensamentos no sentido de enxergar o mundo da prática, então a gente percebe que esse fenômeno do trabalho com grandes dados ou e-Science como um fenômeno do mundo da práxis ele é inegável e é de fato tem conseguido aglutinar uma grande comunidade de pesquisa em torno desse conceito, desse paradigma, tanto inclusive que esse evento que a gente tá participando é uma comunidade de pesquisa que tem já realizado ao longo dos últimos anos não só pesquisas de cunho teórico quanto prático, o que evidencia que esse fenômeno precisa ser discutido.

O que acontece que a gente identifica muito mais estudo de caso, muito mais estudos práticos do que essas formulações teóricas conceituais sobre as bases epistemológicas da e-Science enquanto paradigma científico.

Qual que é o núcleo duro da e-Science? Quais são as suas teorias de suporte? A gente pode caracterizar aquelas ideias propostas pelo Gray como sendo o núcleo duro, elas constituem um fundamento sólido e se algumas dessas ideias começam a ser refutadas no futuro próximo que a gente tem uma crise para esse programa de pesquisa ou para esse paradigma ou na verdade parte daquelas características seriam proposições auxiliares de suporte que podem ser refutadas sem maiores problemas, falta um pouco dessas discussões.

Tentativas de refutação ou críticas só isso já existem, Martin Frické um dos expoentes críticos é muito cético com relação a ideia, a possibilidade de um big data produzir uma lógica de descobertas científicas que possa ser amplamente aplicada, diversas ciências que eles, três paradigmas mencionados anteriormente, no paradigma teórico-empírico, teórico e o computacional, a gente tem uma a utilização ampla nas mais diversas ciências. A e-Science também teria essa possibilidade ou essa característica de universalidade? Algo a se pensar.

Martin Frické também é bastante cético com relação à possibilidade dessa forma de e-Science produzir conhecimento através da análise de muitos dados que consiste numa forma sobretudo de métodos indutivo de produção de conhecimento. Frické é muito cético com relação às possibilidades disso produzir conhecimento novo porque não entende que os nossos pré-conceitos, pré-juízos na hora de analisar dados empíricos ele já implica em uma visão de mundo que pode distorcer a nossa análise. Então a gente entende que embora seja forçoso reconhecer a urgência desses fundamentos teórico-conceituais para e-Science para que ela possa ser mais confortavelmente chamado de um paradigma científico no campo da prática ou práxis, ela efetivamente já é uma realidade.

Então a gente queria finalizar com essa frase de Boaventura Sousa Santos que dizia assim lá em 1988, final do século 20, ele dizia depois da euforia cientista do século XIX e da consequência aversão a reflexão filosófica bem simbolizada pelo positivismo, chegamos ao final do século 20, possuídos pelo desejo quase desesperado de complementarmos o conhecimento das coisas com conhecimento do conhecimento das coisas.

Aqui ele está falando de epistemologia, tá falando de não apenas fazer mas pensar o que fazemos como fazemos, qual que é a lógica subjacente ao trabalho dos cientistas no caso do cientista de dados, então a gente entende que é preciso conhecer mais sobre como a e-Science quer conhecer o mundo, pensar mais nessas bases epistemológicas.

Queremos agradecer e deixar os nossos dados para contato e convidá-los a fazer a leitura do texto completo e a continuar essa discussão aí nos diversos fóruns possíveis.

Um abraço.

Slides da Apresentação

Título: Revolução Científica? Reflexões para uma teoria crítica da Ciência dos Dados.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=2

Repositórios de dados de pesquisa: investigando sua adoção nos institutos brasileiros de pesquisa

André Luiz de França Madeiro[a]

Resumo: A ciência atual é baseada no uso e compartilhamento de dados de pesquisa por meio das Tecnologias de Informação e da Comunicação. Neste contexto é possível acessar estes dados em bancos de dados online conhecidos como repositórios digitais. Os repositórios de dados são um dos tipos desta categoria. Eles podem estar associados a instituições de pesquisa e destacam-se cada vez mais no cenário nacional e internacional. A pesquisa possui como objetivo geral investigar os repositórios de instituições brasileiras de pesquisa no que diz respeito ao suporte para a gestão de dados de pesquisa. A pesquisa apresentou um percurso metodológico bibliográfico, exploratório e quanti-qualitativo. Após a análise dos repositórios encontrados, percebemos uma incipiente presença de repositórios de dados de pesquisa no contexto das instituições de pesquisa brasileiras. Estima-se que este contexto tende a mudar devido à necessidade global de gerenciar novas produções de dados de pesquisa que aumenta constantemente. Novos repositórios de pesquisa poderão surgir à medida que a comunidade de pesquisadores e as instituições estiverem cientes dos benefícios proporcionados por eles e que o tema possa contribuir para novas investigações científicas.

Palavras-chave: Repositório de dados científicos. Instituições brasileiras de pesquisa. Gestão de dados de pesquisa.

Research data repositories: investigating its adoption in the Brazilian research institutes

Abstract: Nowadays science is based on the use and sharing of research data through Information and Communication Technologies. In this context it is possible to access this data in online databases known as digital repositories. Data repositories are one of a kind in this category. They can be associated with research institutions and are becoming more relevant in the national and international scenario. The research general objective is to investigate the repositories of Brazilian research institutions regarding the support of research data management. This research presents a bibliographic, exploratory and quanti-qualitative methodology. After the analysis of the repositories found, we noticed an incipient presence of repositories of research data in the context of Brazilian research institutions. It is estimated that this context tends to change due to the global need to manage new and constantly increasing research data productions. New research repositories may emerge as the research community and institutions are aware of the benefits they provide and the subject can contribute to new scientific research.

Keyword: Research Data Repositories. Brazilian Research Institutions. Research Data Management.

a Universidade Federal da Paraíba (UFPB). E-mail: andreluizfmadeiro@gmail.com. Currículo: http://lattes.cnpq.br/3513884666285069.

1 Introdução

A ciência atual está contextualizada no âmbito de um fenômeno conhecido como e-Science[9]. Segundo Oliveira (2016) este termo representa o quarto paradigma científico e o cientista Jim Gray foi seu precursor. No contexto histórico dos paradigmas da ciência, o primeiro paradigma foi marcado pela experimentação, ocorrido há mais de mil anos. O segundo fundamentou-se na ciência teórica com o surgimento de modelos e generalizações, no século XVII. O terceiro é representado na ciência computacional com base na simulação de fenômenos complexos. O paradigma atual caracteriza-se pela presença da geração intensiva de grande quantidade de dados que surgem do processo de investigação científica (OLIVEIRA, 2016).

Na ciência contemporânea, os dados de pesquisa não são insumos exclusivamente destinados para os pesquisadores que os produziram. Estes dados também devem beneficiar toda a comunidade científica através de estratégias que possibilitem o seu uso e reúso. Os dados podem estar disponibilizados através de repositórios de dados científicos com o acesso livre de barreiras geográficas e de restrições temporais

A relevância da temática em tela é de interesse dos pesquisadores, curadores de dados, comunidades científicas, órgãos de fomento à pesquisa, editores de periódicos científicos, gestores e executores de programas e projetos de dados de pesquisa, profissionais da computação e da Ciência da Informação em geral.

Devido a crescente expansão e compartilhamento do volume de dados de pesquisa, é necessário o estabelecimento e a consolidação de uma política de gestão de dados científicos, visando a garantia dos mesmos por meio de processos de curadoria, preservação, arquivamento e compartilhamento de coleções de dados de pesquisa, em sustentabilidade contínua e permanente (IBICT, 2016).

O valor dos dados de pesquisa em nossa contemporaneidade motivou o Instituto Brasileiro de Informação em Ciência e Tecnologia (IBICT) a lançar o "Manifesto de Acesso Aberto a Dados da Pesquisa Brasileira para Ciência Cidadã". Esta ação foi efetivada na data de 28 de setembro de 2016, configurando-se como um posicionamento brasileiro diante do movimento mundial ao acesso aberto à informação científica. O objetivo desta iniciativa foi incentivar o acesso livre, abrangente e ilimitado às fontes primárias de dados de pesquisa que tornam possível o uso, reúso, compartilhamento e reprodutibilidade em novos contextos de investigação científica (IBICT, 2016).

Dentre os mais variados tipos de repositórios existentes no Brasil, os associados com as instituições de pesquisa têm presença cada vez mais marcante na Internet. A pesquisa de Sayão e Sales (2016) é um exemplo deste assunto: os referidos pesquisadores trazem informações sobre repositórios de dados de pesquisa, sobre sua definição, objetivos, benefícios, apresentação de fluxos de gestão de dados de pesquisa em repositório de dados, tipos de repositórios de dados de pesquisa, valor e permanência de dados e análise dos repositórios Dryad e R3DATA.

Repositórios de dados associados a instituições de pesquisa são novas entidades que despontam na seara da Tecnologia da Informação. Eles favorecem a propagação das informações científicas e tecnológicas. De acordo com Sayão e Sales (2015, p.53):

9 O termo "data intensive science" é equivalente ao termo "e-Science". Doravante, adotaremos o termo "e-Science".

Os repositórios de dados de pesquisa são banco de dados que recebem, gerenciam e disseminam dados e conjuntos de dados de pesquisa. Eles constituem o lugar mais apropriado para que seus dados sejam preservados e possam ser recuperados, acessados e citados por outros pesquisadores, ou seja, tenham visibilidade em escala mundial.

2 Objetivos

No que se refere a problematização, esta pesquisa questiona de que forma se configuram os repositórios de pesquisa das instituições brasileiras de pesquisa no que diz respeito a gestão de dados de pesquisa.

A pesquisa possui como objetivo geral investigar os repositórios de instituições brasileiras de pesquisa no que diz respeito ao suporte para a gestão de dados de pesquisa. Quanto aos objetivos específicos elencamos os seguintes: identificar os repositórios de dados de institutos brasileiros de pesquisa; identificar a tipologia dos repositórios em institutos brasileiros de pesquisa; levantar características específicas dos repositórios de dados de institutos brasileiros de pesquisa; disponibilizar os dados coletados e o material de apoio usado na pesquisa no repositório de dados no repositório Dataverse[10] da UFPB.

3 Procedimentos Metodológicos

A trilha metodológica usada para a condução desta investigação baseou-se numa abordagem bibliográfica, de cunho exploratório, quanti-qualitativo.

A busca por textos para a revisão de literatura e para a identificação dos repositórios de dados foi realizada através das ferramentas de busca Google e Google Acadêmico no período compreendido entre agosto de 2017 a julho de 2018. Os descritores selecionados para a pesquisa foram: "repositórios brasileiros"; "repositórios de dados"; "brazilian repositories" e "data repositories".

Os sites R3DATA, ROAR e IBICT foram usados como fontes de referência para identificar os repositórios de dados existentes. O processo investigativo foi bastante exaustivo. Todos os repositórios levantados foram acessados para serem identificados com relação a sua tipologia e as características dos objetos digitais ora depositados. Para auxiliar na identificação de repositórios de dados de pesquisa, foram utilizados os estudos de Leite et al. (2012), Pampel et al. (2013) e Sales (2014).

A partir dos repositórios brasileiros identificados, verificou-se a existência de muitos repositórios institucionais. Após uma análise precisa, consultando os tipos de dados presentes, a finalidade da instituição, informações referentes dos repositórios, verificamos que alguns poucos destes repositórios poderiam ser classificados como repositórios de dados de pesquisa.

4 Resultados

Foram encontrados seis repositórios de dados em instituições brasileiras de pesquisa. Dentre os repositórios identificados como repositórios de dados, listamos os seguintes: PPBiodata, IBICT Dataverse, carpeDIEN, Portal GEOINFO de infraestrutura de dados espaciais da EMBRAPA, Portal da Biodiversidade e o repositório SinBiota (Sistema de Informação Ambiental

10 https://dataverse.ufpb.br/

do Programa Biota/Fapesp). Todos apresentam diversidade na tipologia dos dados em e variados formatos.

O repositório de dados científicos IBICT Dataverse encontra-se no site https://repositoriopesquisas.ibict.br/. Ele apresenta uma tipologia orientada para várias áreas do conhecimento, de acordo com as informações em seu site:

O IBICT está disponibilizando um repositório de dados de pesquisa que cuida da preservação a longo prazo e de boas práticas de arquivamento, para que os pesquisadores possam compartilhar, manter o controle e obter o reconhecimento de seus dados. O repositório suporta o compartilhamento de dados de pesquisa com citação de dados persistentes, permitindo que eles sejam reproduzidos. O Dataverse é um grande repositório aberto de dados de todas as disciplinas, criado pelo Institute for Quantitative Ciências Sociais da Universidade de Harvard (IBICT Dataverse, 2018, online).

O repositório IBICT usa o software Dataverse. O Dataverse (2018, online, tradução nossa) é definido como "um aplicativo da Web de código aberto para compartilhar, preservar, citar, explorar e analisar dados de pesquisa[11]".

O CarpeDIEN, pode ser acessado através do site http://carpedien.ien.gov.br/, é o nome do repositório do IEN (Instituto de Energia Nuclear). Apresenta uma tipologia voltada para "dados e informações em energia nuclear" (carpeDIEN, 2018, online) e faz uso do software DSpace. O DSpace (DSPACE, 2018, online, tradução nossa) é conhecido como o "software preferido das organizações acadêmicas, sem fins lucrativos e comerciais que criam repositórios digitais abertos[12]".

O PPBiodata pode ser acessado através do link https://ppbiodata.inpa.gov.br/metacatui/. Ele faz parte do PPBio (Programa de Pesquisa em Biodiversidade). PPBio foi: criado em 2004 com o objetivo de intensificar estudos sobre biodiversidade no Brasil, descentralizar a produção científica dos centros desenvolvidos academicamente integrar atividades de pesquisa e divulgar os resultados para diferentes finalidades, como gestão ambiental e educação (PPBio, 2018, online).

Ainda, com relação ao PPBiodata, é importante mencionar que o uso faz uso do metacat. Este software é um "repositório de dados e metadados (documentação sobre dados), que ajuda os cientistas a encontrar, entender e usar efetivamente os conjuntos de dados que gerenciam ou que foram criados por outros[13]" (KNB, 2018, online, tradução nossa).

Costa (2017) menciona o Portal GEOINFO de infraestrutura de dados espaciais da EMBRAPA e o Portal da Biodiversidade. Peixoto (2012) indica o repositório SinBiota (Sistema de Informação Ambiental do Programa Biota/Fapesp.

Conforme Pampel et al. (2013) e Sales (2014), respectivamente, os repositórios encontrados estão de acordo com a tipologia repositórios de dados de pesquisa institucional e repositórios de dados. Verifica-se uma consonância entre a fundamentação teoria e a investigação realizada.

11 Fonte original em língua inglesa: is an open source web application to share, preserve, cite, explore, and analyze research data. (DATAVERSE, 2018, online).

12 Fonte original em língua inglesa: DSpace is the software of choice for academic, non-profit, and commercial organizations building open digital repositories (DSpace, 2018, online).

13 Fonte original em língua inglesa: is a repository for data and metadata (documentation about data), that helps scientists find, understand and effectively use the data sets they manage or that have been created by others (KNB, 2018, online).

5 Considerações Finais

A partir da pesquisa realizada, concluímos que o número de repositórios de dados em instituições de pesquisa brasileira ainda é incipiente. Concordamos com Sales (2014, p.62) sobre este contexto quando afirma que: "este tipo de repositório é mais raro no contexto brasileiro". Contudo, a partir do crescimento exponencial na geração de dados e considerando o valor deste recurso no fazer científico, acreditamos que esta situação poderá modificar-se. Novos repositórios de dados de pesquisa poderão surgir, sejam a partir de iniciativas isoladas das instituições ou mesmo através da geração de consórcios.

Referências

COSTA, M.M. **Diretrizes para uma política de gestão de dados científicos no Brasil**. Brasília: 2017.288p. Tese (Doutorado em Ciências da Informação). Faculdade de Ciência da Informação. Universidade de Brasília. Disponível em:<http://repositorio.unb.br/handle/10482/24895>Acesso em: 24 abr. 2018.

DATAVERSE. **About**. Disponível em:< https://dataverse.org/about> Acesso em: 03 jun. 2018.

IBICT . **IBICT lança Manifesto de Acesso Aberto a Dados da Pesquisa Brasileira para Ciência Cidadã**. Disponível em:<http://www.ibict.br/Sala-de-Imprensa/noticias/2016/ibict-lanca-manifesto-de-acesso-aberto-a-dados-da-pesquisa-brasileira-para-ciencia-cidada> Acesso em: 29 jun. 2018.

KNB. **The Knowledge Network for Biocomplexity**. Disponível em: <https://knb.ecoinformatics.org/knb/docs/intro.html#what-s-in-this-guide >. Acesso em: 08 out. 2018.

LEITE, F. et al. **Repositórios Institucionais**: boas práticas para a construção de repositórios institucionais da produção científica. Brasília: IBICT, 2012. Disponível em:< http://livroaberto.ibict.br/bitstream/1/703/1/Boas%20pr%C3%A1ticas%20para%20a%20constru%C3%A7%C3%A3o%20 de%20reposit%C3%B3rios%20institucionais%20da%20produ%C3%A7%C3%A3o%20cient%C3%Adfica.pdf> Acesso em: 10 jun. 2018.

OLIVEIRA, A. C. S. **Desvendando a autoralidade colaborativa na *e-Science* sob a ótica dos direitos da propriedade intelectual**. João Pessoa: 2016. 297p. Tese (Doutorado em Ciências da Informação). Centro de Ciências Sociais Aplicadas. Universidade Federal da Paraíba. Disponível em:<http://tede.biblioteca.ufpb.br/handle/tede/8849 > Acesso em: 7 jun 2018.

PAMPEL, H. et al. **Making research data repositories visible**: the re3data.orgRegistry. PLoSOne, San Francisco, v. 8, n.11, 2013. Disponível em:<http://journals.plos.org/plosone/article?id=10.1371journal.pone.0078080 >. Acesso em: 19 maio. 2018.

PEIXOTO, N.M. **Arquitetura de informação em repositório de dados científicos**: análise da interface do repositório do PELD: Programa de Pesquisa Ecológicas de Longa Duração. 2012.

Porto Alegre: 2012. 78p. Trabalho de Conclusão de Curso (Graduação) Universidade Federal do Rio Grande do Sul. Faculdade de Biblioteconomia e Comunicação. Curso de Biblioteconomia. Disponível em:< https://lume.ufrgs.br/handle/10183/69727 > Acesso em: 29 jul. 2018.

SALES, L.F. **Integração semântica de publicações científicas e dados de pesquisa**: proposta de modelo de publicação ampliada para a área de Ciências Nucleares. Rio de Janeiro: 2014. 265p. Tese apresentada ao Programa de Pós-graduação em Ciência da Informação da Universidade Federal do Rio de Janeiro/. Disponível em:<http://repositorio.ibict.br/bitstream/123456789/874/1/LUANA%20SALES%20D.pdf > Acesso em: 05 dez. 2017.

SAYÃO, L. F; SALES, L. F. **Algumas considerações sobre os repositórios digitais de dados de pesquisa**. **Inf. Inf.**, Londrina, v. 21, n. 2, p. 90 – 115, maio/ago 2016. Disponível em:<http://www.uel.br/revistas/uel/index.php/informacao/article/view/27939/20122>Aceso em: 18 abr. 2018.

Vídeo da apresentação

Título: Repositórios de dados de pesquisa: investigando sua adoção nos institutos brasileiros de pesquisa.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=3

Transcrição da apresentação

Saudações, meu nome é André Luiz de França Madero, sou estudante do curso de graduação em arquivologia da Universidade Federal da Paraíba (UFPB). Sou pesquisador PIBIC e apresento agora de forma breve meu artigo intitulado "Repositórios de dados de pesquisa: investigando sua adoção nos institutos brasileiros de pesquisa".

A ciência atual é baseada no uso e compartilhamento de dados de pesquisa por meio de tecnologias da informação e comunicação, o acesso a tais dados em bancos online são conhecidos como repositórios digitais, dentre os repositórios existentes, existem os repositórios de dados e eles estão associados às instituições de pesquisa.

O objetivo geral do trabalho foi de pesquisar repositórios de dados de instituições brasileiras de pesquisa no que diz respeito à gestão de dados. O trabalho Apresentou um percurso metodológico bibliográfico exploratório de cunho quanti-qualitativo.

De acordo com o resultado teve uma incipiência presença de repositórios de dados no contexto das instituições brasileiras de pesquisa, estima-se que este contexto a de mudar devido à grande necessidade global de gerenciar novos dados de pesquisa que crescem progressivamente e também a importância da comunidade de pesquisadores e instituições terem a ciência dos benefícios que eles proporcionam e que esse tema possa contribuir para novas investigações científicas.

Para conhecer mais informações deste trabalho tem-se o contato, o e-mail é andreluizfmadero@gmail.com.

Muito obrigado.

Slides da Apresentação

Título: Repositórios de dados de pesquisa: investigando sua adoção nos institutos brasileiros de pesquisa.

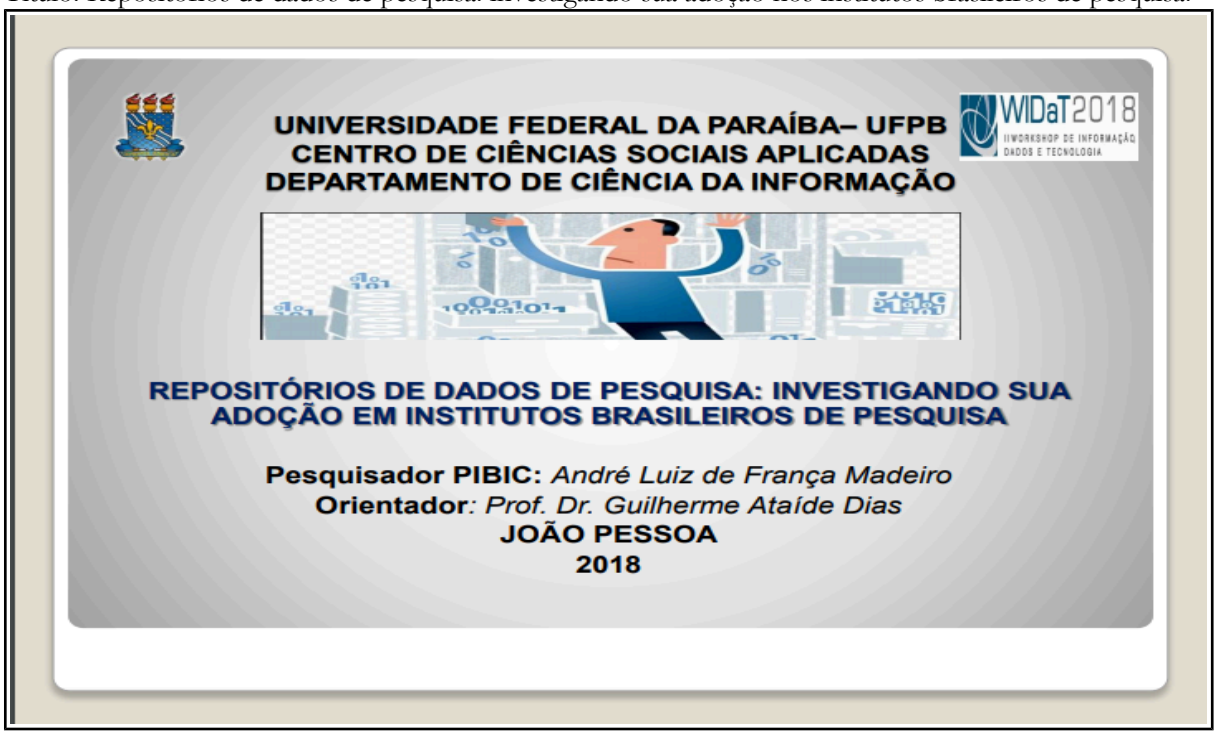

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=3

Reconhecimento de entidades nomeadas em relatórios de inteligência financeira

Jairo Santana[a], Diefferson K. Moro[b], Rogério de Aquino Silva[c], Vinicius Faria Culmant Ramos[d] e Gustavo Medeiros de Araujo[e]

Resumo: O reconhecimento de entidades nomeadas é uma das subáreas do processamento de linguagem natural, mineração de textos e aprendizado de máquinas. Todas essas áreas fazem parte da grande área da inteligência artificial, muito utilizada em diversos problemas práticos do nosso dia a dia. Uma das competências da Polícia Federal é a investigação de crimes financeiros, em especial, a lavagem de dinheiro. Dentre os problemas encontrados na investigação policial, destacamos a análise dos Relatórios de Inteligência Financeira (RIF), escritos em português do Brasil, que são gerados pelo Conselho de Controle de Atividades Financeiras. O objetivo desta análise é identificar os atores envolvidos em esquemas de lavagem de dinheiro, mas, dependendo da complexidade do esquema, a identificação, por exemplo, desses atores e suas relações (sociedades, parentescos, "laranjas", empresas "fantasmas", etc) em um relatório, pode demandar um tempo significativo do policial envolvido na investigação. Este trabalho, portanto, visa apresentar resultados iniciais da automatização do reconhecimento de entidades nomeadas, importantes para a investigação policial, em RIFs. Identificamos, na literatura, uma grande lacuna para esse tipo de solução em textos em português. Os nossos resultados, ainda preliminares, demonstram que as ferramentas e os dados utilizados para o treinamento ainda precisam ser melhores trabalhados para que estes sejam mais significativos. Pudemos perceber que com poucos dados de treinamento conseguimos aumentar a precisão do reconhecimento de entidades de 14 para 27% e, em um teste com o framework RASA NLU, aumentamos a precisão para 60,98% de entidades reconhecidas corretamente, muito aquém dos 90% encontrados na literatura para outros idiomas.

Palavras-chave: Reconhecimento de Entidades Nomeadas. Mineração de Texto. Relatório de Inteligência Financeira. Processamento de Linguagem Natural.

Entity named recognition in financial intelligence report

Abstract: The named entity recognition is a subarea of natural language processing, text mining, and machine learning. These areas are part of the artificial intelligence area, very used in different kind of daily practical problems. One of the competencies of the Brazilian Federal Police is to investigate financial crimes, especially money laundering. Among the problems encountered in the police investigation, we highlight the analysis of the Financial Intelligence Reports, written in Brazilian Portuguese, which are generated by the Financial Activities Control Council. The aim of this analysis is to identify the actors involved in money laundering schemes, but depending on the complexity of the scheme, the identification, for example, of these actors and their relationships (societies, kinship, "oranges", "ghost" companies, etc.) in a report, may require significant time from the police man involved in the investigation. The main objective of this paper is to present initial results of the automation of named entity recognition, important for the police investigation, in Financial Intelligence Reports. We identified, in the literature, a large gap for this type of solution in Portuguese texts. Our preliminary results

a Universidade Federal de Santa Catarina (UFSC). E-mail: jairo.santana@gmail.com
b Universidade Federal de Santa Catarina (UFSC). E-mail: differson.moro@gmail.com
c Universidade Federal de Santa Catarina (UFSC). E-mail: rogerriomp@gmail.com
d Universidade Federal de Santa Catarina (UFSC). E-mail: v.ramos@ufsc.br. ORCID: https://orcid.org/0000-0002-8319-743X. Currículo: http://lattes.cnpq.br/0442142220296336
e Universidade Federal de Santa Catarina (UFSC). E-mail: gustavo.araujo@ufsc.br. ORCID: https://orcid.org/0000-0003-0572-6997. Currículo: http://lattes.cnpq.br/2609254559240670

demonstrate that the tools and data used for training still need to be better explored to make them more meaningful. We could see that, with a few training dataset, we were able to increase the accuracy of the recognition of entities from 14 to 27% and, using the Rasa NLU framework, we got a 60.98% precision, very below the 90% found in the literature for other languages.

Keyword: Named Entity Recognition. Text Mining. Financial Intelligence Report. Natural Processing Language.

1 Introdução

Entre as diversas atribuições da Polícia Federal, encontra-se a investigação de crimes de lavagem de dinheiro (BRASIL, 1998), que pode ser definido como "a atividade de investir, ocultar, substituir ou transformar e restituir o dinheiro de origem ilícita aos circuitos econômico-financeiros legais, incorporando-o a qualquer tipo de negócio como se fosse obtido de forma lícita" (CALLEGARI, 2001 apud LUSTOSA, 2009). Lustosa (2009) refere-se a esse crime como uma maneira genérica de ocultação da origem de dinheiro ou bens advindos de atividades delitivas, seja por um processo ou um conjunto de operações, e a sua respectiva integração ao sistema financeiro por meio de operações capazes de converter o dinheiro sujo em dinheiro limpo.

Esse complexo esquema de lavagem de dinheiro pode ser dividido em três fases: ocultação, dissimulação e integração. A ocultação consiste basicamente em esconder e afastar o ativo da origem ilícita, para que se possa evitar que seja rastreado. Uma das maneiras de fazê-la é realizar diversas transações com valores fracionados, que desobriga a sua comunicação às autoridades financeiras (MENDRONI, 2015). A próxima etapa é a dissimulação, que tem, por fim, disfarçar a origem criminosa dos valores, camuflando evidências através de uma série de complexas transações financeiras internacionais em países que não cooperam com o combate à lavagem de dinheiro, os chamados paraísos fiscais (BRAGA, 2010). Por fim, a fase de integração é onde se tem os benefícios dos ativos como se fossem lícitos, seja através da compra de bens ou no investimento em empresas comerciais criadas e operando de forma legal.

O Conselho de Controle de Atividade Financeiras (COAF) é o responsável pela análise das evidências de crime de lavagem de dinheiro ao ser comunicado de operações suspeitas. Confirmadas as evidências, haverá uma troca de informações com as autoridades competentes (MARQUES, 2014), da forma que está descrito no artigo 15 da Lei nº 9.613/1998.

A Polícia Federal, o Ministério Público Federal, as polícias civis e os ministérios públicos estaduais são consideradas as autoridades competentes para receberem os informes do COAF, conforme o contexto da operação. Esses órgãos poderão bloquear a operação financeira suspeita, iniciar uma investigação criminal e, até mesmo, propor a ação penal (ARAS, 2007). O meio pelo qual o COAF disponibilizará seus informes às autoridades competentes é através do Relatório de Inteligência Financeira (RIF).

Os RIFs enviados para Polícia Federal são recebidos pela área de repressão a crimes financeiro e inicialmente avaliados, detectando qual será a delegacia responsável pela análise do relatório. O RIF será analisado detalhadamente de forma a identificar se realmente possuem indícios suficientes que retratam uma ação criminosa e, por fim, a instauração de um procedimento investigativo formal (POLÍCIA FEDERAL, 2013). O RIF é um documento escrito em linguagem natural, sem um padrão de estrutura e apresenta um relato conforme a compreensão do analista do COAF no formato digital PDF – Portable Document Format.

Atualmente, as áreas de inteligência da PF analisam o RIF de modo manual, identificando entidades, valores, operações realizadas e possíveis vínculos entre as entidades (POLÍCIA FEDERAL, 2013). Conforme a complexidade do relato no RIF, apenas uma leitura é feita para se realizar a análise ou, nos casos mais complexos, suas informações deverão ser tabuladas,

armazenadas em planilhas eletrônicas ou em banco de dados, possibilitando sua leitura por softwares analíticos que permitem gerar diagramas de relacionamentos entre as entidades, para, finalmente, facilitar a detecção de Organizações Criminosas. É primordial que a detecção e tabulação de entidades e outras informações aconteça com a máxima acurácia possível para não haver a possibilidade de se comprometer uma correta análise na fase posterior.

Nesse contexto, esse estudo tem como objetivo automatizar o processo de reconhecimento de entidade nomeada (REN), em especial, a identificação dos atores envolvidos nos RIFs utilizando ferramentas e técnicas de Processamento de Linguagem Natural (PLN), mineração de textos e aprendizado de máquina.

2 Trabalhos Relacionados

Pires (2017) apresenta em sua dissertação de mestrado alguns resultados sobre abordagens e configurações de ferramentas e corpus anotados em língua portuguesa para a pesquisa em um sistema de busca de notícias, da Universidade do Porto. O sistema de notícias chama-se SIGARRA. Segundo o autor, a ferramenta CoreNLP utilizada com o corpus HAREM obteve o melhor resultado para o Reconhecimento de Entidades Nomeadas (REN), chegando a 56% de precisão. Após essa identificação, o autor criou um conjunto de testes com 905 notícias anotadas e 12644 entidades anotadas. Nesse caso, o sistema implementado atingiu 86,86% em relação à f-measure.

Fonseca et al (2017) apresentam uma ferramenta para o REN baseada no NameFinder, uma das classes da ferramenta OpenNLP. Os autores utilizam o Corpus Amazônia para treinar o modelo e o Corpus HAREM para validar o modelo. Os resultados apontam para uma precisão de 58,65%, com recall de 56,60% e f-measure de 57,61% para as entidades do tipo Pessoa. Os autores ainda mostram resultados de diversas outras ferramentas de NER para o português e concluem que esses resultados são compatíveis com essas ferramentas, mas ainda aquém dos resultados encontrados em outros idiomas.

O diferencial do nosso trabalho é o uso de um contexto determinado, reconhecimento de entidades nomeadas em relatórios de inteligência financeira, o que poderá nos auxiliar na identificação dessas entidades. Além disso, propomos a comparação de outros modelos para o treinamento que não os apontados na literatura.

3 Procedimentos Metodológicos

O reconhecimento de entidades nomeadas (REN) é um dos principais elementos do PLN. Ele é essencial para várias etapas do PLN, dentre elas a classificação de uma frase ou a checagem de vínculos entre as entidades.

Neste contexto, este trabalho fez uma análise de algumas ferramentas e técnicas utilizadas para a REN em textos de inteligência financeira (RIF) escritos em português e compartilhados pelo COAF.

A primeira etapa do nosso processo é a identificação das ferramentas e técnicas utilizadas, através de uma pesquisa exaustiva na literatura, para o REN em língua portuguesa.

A segunda etapa visa a escolha e posterior utilização das técnicas e ferramentas identificadas na primeira etapa para o REN em relatórios de inteligência financeira (RIF). É importante

ressaltar que as entidades mais importantes a serem identificadas no RIF são: pessoas (físicas e jurídicas), valores e datas.

As etapas do processo de REN seguem os algoritmos e técnicas utilizadas para tal finalidade, sendo as mais utilizadas as técnicas de aprendizado de máquinas supervisionadas, dentre elas citamos o SVM, Redes Bayesianas e redes neurais. Uma das etapas é o treinamento realizados pelos algoritmos, para tanto, é necessário utilizar bases de dados com marcações de entidades para ajudar na identificação automática dessas entidades. Portanto, é fundamental encontrarmos, na literatura, as principais bases de dados anotadas em português.

Será necessária uma etapa intermediária para a conversão dos textos em PDF em texto puro para facilitar a manipulação dos dados.

As métricas utilizadas e que devem aparecer nos resultados são: i) a quantidade de palavras marcadas corretamente como entidade, ii) a quantidade de palavras marcadas indevidamente como entidade e iii) a quantidade de entidades omitidas.

4 Resultados

Abordamos a primeira etapa do nosso processo de revisão da literatura com uma revisão sistemática com o objetivo principal de identificação das principais ferramentas, técnicas e algoritmos utilizados para o reconhecimento de entidades nomeadas em textos em português. Esta etapa está em processo de publicação.

Identificamos na literatura 4 principais ferramentas de análise de textos que fazem o REN para o português, são elas: Stanford CoreNLP[14], OpenNLP[15], spaCy[16] e NLTK[17]. Além disso, identificamos, também, na literatura as principais bases de dados anotadas em português, que são: HAREM[18], BOSQUE[19], FLORESTA[20] e AMAZÔNIA[21].

Identificadas as principais bases de dados anotadas em português e as principais ferramentas utilizadas para o REN em português, procuramos por dados na literatura que nos permitisse escolher qual ferramenta e qual base de dados utilizar para o nosso objetivo final: o reconhecimento de entidades nomeadas em relatórios de inteligência financeira. Optamos, portanto, por utilizar a ferramenta spaCy e a base de dados HAREM por dois motivos principais: os resultados na literatura mostram o spaCy como uma boa ferramenta de REN e o HAREM é uma das bases de dados mais completas e anotadas para o português.

Alguns problemas foram superados e os relatamos para fins de pesquisa: a última versão do HAREM não é compatível com a última versão do spaCy (2.0.12), isto nos levou a desenvolver um script para a conversão dos dados para o spaCy (disponível após o blind review). O spaCy

14 Encontrada em https://nlp.stanford.edu/software/ acesso em 29 de setembro de 2018.
15 Encontrada em http://opennlp.apache.org /acesso em 29 de setembro de 2018.
16 Encontrada em https://spacy.io/ acesso em 29 de setembro de 2018.
17 Encontrada em https://www.nltk.org/ acesso em 29 de setembro de 2018.
18 Encontrada em http://www.linguateca.pt/HAREM/PacoteRecursosSegundoHAREM.zip acesso em 25 de setembro de 2018.
19 Encontrado em https://www.linguateca.pt/Floresta/ficheiros/Bosque_CP_7.5_cgde_22032016.conll.gz acesso em 29 de setembro de 2018.
20 Encontrado em https://www.linguateca.pt/Floresta/ficheiros/FlorestaVirgem_CP.conll.gz acesso em 29 de setembro de 2018.
21 Encontrado em https://www.linguateca.pt/Floresta/ficheiros/amazonia.conll.gz acesso em 29 de setembro de 2018.

tem as entidades/categorias anotadas em inglês e o HAREM está anotado em português, portanto, fizemos a conversão das categorias no HAREM.

Para a conversão dos RIF do formato PDF para texto, utilizamos a biblioteca Pdfminer.

Os nossos testes foram baseados nos seguintes modelos de treinamentos:

- Modelo 1 – modelo original disponibilizado no SpaCy, versão utilizada 2.0.0;
- Modelo 2 – modelo gerado com base no original, acrescido do treino de 500 iterações dos 'dados de treino' e 20 iterações nos dados dos arquivos de Localidades;
- Modelo 3 – modelo gerado com base no original, acrescido do treino de 20 iterações dos 'dados de treino';
- Modelo 4 – modelo em branco, acrescido do treino de 20 iterações dos 'dados de treino';
- Modelo 5 – novo modelo do HAREM, acrescido de 2 iterações com os dados de treinamento;
- Modelo 6 – novo modelo do HAREM, acrescido de 110 iteraçõs com os dados de treino.
- Modelo 7 – modelo do spaCy com o treinamento junto ao framework Rasa MLU[22]

Segundo Pires (2017), os melhores resultados com o spaCy e o HAREM, para a classificação de entidades nomeadas como notícias em uma base de dados chamada SIGARRA, foram obtidos com 110 iterações de treinamento. Repetimos os mesmos treinamentos, entretanto, é importante ressaltar que as versões, da ferramenta e da base anotada, usadas no trabalho são diferentes.

Todos os RIF usados no treinamento tinham apenas 182 entidades marcadas, sendo 80 do tipo Pessoa (física ou jurídica), 38 do tipo Moeda, 14 do tipo Localidade, 38 do tipo Documento e apenas 12 do tipo Data.

Mostramos os resultados na Tabela 1, após os treinamentos, aplicamos o REN para um dos RIF.

Tabela 1: Resultados da Identificação.

Modelo	**Precisão**	**Recall**	**f-score**
1	1.041	1.587	1.257
2	0	0	0
3	27.586	38.095	32.000
4	14.754	28.571	19.459
5	8.641	11.111	9.722
6	27.272	33.333	30

Fonte: Elaborado pelos autores.

O modelo 7 foi testado em separado, pois não tínhamos total domínio do framework Rasa NLU, pois ele é utilizado em Chatbot para REN. O teste foi realizado a partir do modelo do spaCy e o Rasa NLU como treinamento em cima dos dados do RIF. Neste treinamento, conseguimos identificar 162 entidades, com uma precisão de 60,98%.

A precisão de todos os testes é muito baixa, entretanto, o Modelo 7 chega muito próximo aos valores encontrados por Fonseca et al (2017).

22 Encontrado em: https://rasa.com/docs/nlu/. Acessado em 01 de outubro de 2018.

Sabemos que estes primeiros testes são importantes para reconhecermos o nosso corpus e, também, para entendermos os pontos de melhoria dos modelos e dos treinos. Esses resultados estão muito aquém dos resultados encontrados na literatura, seja para a língua portuguesa, seja para a língua inglesa. Cabe ressaltar que o Modelo 3 utilizou os mesmos dados usados para treinamento e validação dos resultados, por isso ele chegou a um resultado próximo ao Modelo 6.

5 Conclusão ou Considerações Finais

Compreendemos que a proposta de automatização de detecção de entidades nomeadas e seus vínculos em RIF é viável utilizando-se as ferramentas e bases de dados existentes. Entretanto, ainda não temos bons resultados com eles, visto que a identificação correta dessas entidades ainda não superou os 90% de acurácia, o que é um grande problema para a análise dos RIF por parte das instituições envolvidas, como é o caso da Polícia Federal. Os modelos treinados, apesar de um melhor desempenho, também não são satisfatórios. Sabemos que é necessário identificar mais entidades em outros RIF para aumentar a qualidade do treinamento. Isto deve levar ao REN com maior precisão, em especial as entidades do tipo Pessoa.

Uma outra proposta para aumentar a assertividade é a criação de expressões regulares e heurísticas que envolvam a identificação de entidades do tipo moeda, localização, data, CPF e CNPJ. Desta maneira, poderemos focar no reconhecimento de entidades do tipo pessoa física e jurídica, para, em um segundo momento estudarmos as correferências entre essas entidades.

Com trabalhos futuros, sugerimos a adaptação das outras bases de dados anotadas (FLORESTA, AMAZÔNIA e BOSQUE) para serem utilizadas como treinamento das principais ferramentas de NER: Stanford CoreNLP, OpenNLP, spaCy e NLTK. Após os testes com todas as bases e ferramentas, buscaremos melhorias nos algoritmos para conseguirmos uma acurácia acima dos 95%, conforme já é apresentado na literatura para o idioma inglês.

Referências

ARAS, V. Sistema nacional de combate à lavagem de dinheiro e de recuperação de ativos. **Revista Jus Navigandi**, no 1411, Teresina, 2007.

BRASIL. **Lei da Lavagem de Dinheiro**, 1998. Disponível em: <http://www.planalto.gov.br/ccivil_03/Leis/L9613.htm. Acesso em jun 2018.

CALLEGARI, A. L. **Imputação Objetiva**. Lavagem de dinheiro e outros temas do Direito Penal. Porto Alegre: Livraria do Advogado, 2001.

COAF. **Relatório de Inteligência Financeira** – RIF. Disponível em: <http://coaf.fazenda.gov.br/menu/a-inteligencia-financeira/relatorio-de-inteligencia-financeira-rif>. Acesso em: 1 jul. 2018.

FONSECA, Evandro B., CHIELE, Gabriel C., Vieira, Renata e VANIN, Aline A. Reconhecimento de Entidades Nomeadas para o Português Usando o OpenNLP. **Anais** do

Encontro Nacional de Inteligência Artificial e Computacional (ENIAC 2015), s. pp. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/eniac/2015/011.pdf>. Acesso em: 01 out. 2018.

LUSTOSA, D. S. de M. **Aspectos gerais do crime de lavagem de dinheiro (Lei 9.613/98).** Âmbito Jurídico, Rio Grande, XII, n. 70, 2009. MARQUES, N. J. F. O papel do COAF no combate ao crime de lavagem de dinheiro. Conteudo Juridico, Brasilia-DF, 2014.

POLÍCIA FEDERAL. **Manual Prático de Combate à Lavagem de Dinheiro e aos Crimes Financeiros (reservado) Brasília** – DF, 2013.

PIRES, André R. O. **Named entity extraction from Portuguese web text**. Faculdade de Engenharia da Universidade do Porto, 2017.

Vídeo da apresentação

Título: Reconhecimento de entidades nomeadas em relatórios de inteligência financeira.

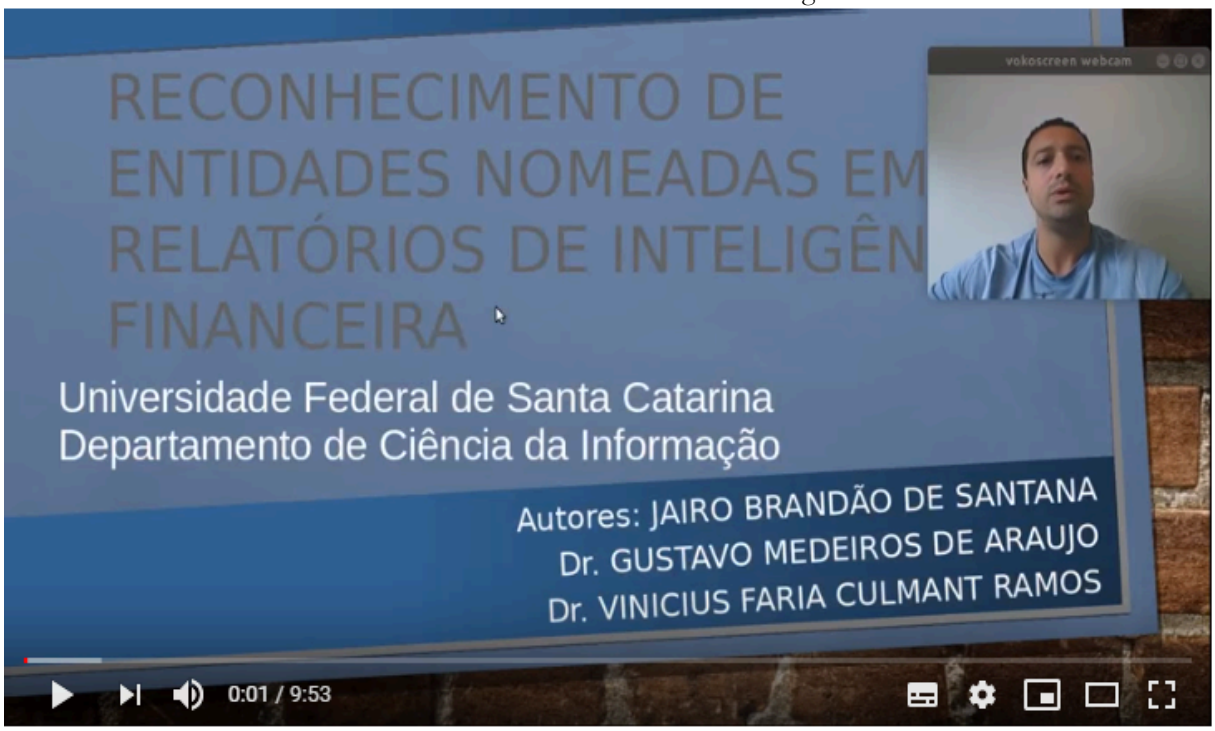

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=4

Transcrição da apresentação

Bom, esse trabalho "Reconhecimento de entidades nomeadas em relatório de inteligência financeira", foi realizado na Universidade Federal de Santa Catarina no departamento de ciência da informação. Os autores são: Jairo Brandão de Santana, Prof. Dr. Gustavo Medeiros de Araujo e Prof. Dr. Vinicius Faria Culmant Ramos. Trabalho aceito pelo WIDAT 2018 – Workshop de Informação Dados e Tecnologia.

Trabalho motivado pela questão de lavagem de dinheiro, no qual a origem da lavagem de dinheiro começou pelas máfias e organizações criminosas do início do século 20, aumentou com o surgimento dos países fiscais com dinheiros ilícito tinha o seu destino, aumentou bastante com a questão do narcotráfico que o volume de dinheiro gerado é muito grande, dinheiro que precisava ser espalhado em um lugar. Então "É uma forma genérica de referir-se ao processo ou conjunto de operações de ocultar a origem de dinheiro ou dos bens resultantes das atividades delitivas e integrá-los no sistema econômico ou financeiro, em operações capazes de converter o dinheiro sujo em dinheiro limpo" (Lustosa, 2009, p.1).

Lavagem de dinheiro em algumas etapas apresentadas, ocultação de dinheiro no recebimento de dinheiro é colocado em instituições financeiras e a dissimulação a distribuição entre as instituições financeiras, empresas e offshore; depois a integração com a utilização desse dinheiro ilícito em ativos listados para caracterizar com a atitude do dinheiro.

A Convenção de Viena aconteceu em 1988, criada pela ONU para poder tentar mitigar esse problema de lavagem de dinheiro, financiamento de terrorismo; foram feitas várias atribuições como identificar os riscos de desenvolver políticas e combater a lavagem de dinheiro e o financiamento do terrorismo e a proliferação, aplicar medidas preventivas no setor financeiro, estabelecer poderes, aumentar a transparência e melhorar a cooperação internacional.

No Brasil surgiu em 1998 a lei de lavagem de dinheiro, a criação da COAF – Conselho de Controle de Atividades Financeiras, no caso aqui a nossa entidade que examina todas as atividades que são suspeitas para poder fazer uma investigação. Eles fazem uma investigação preliminar e dependendo das atividades suspeitas eles enviam esses relatórios das atividades suspeitas para as autoridades competentes.

Há uma comunicação entre o setor financeiro e a COAF no qual acima de qualquer operação acima de 150 mil, ela deve ser registrada e deve ser enviada para o COAF com, pelo menos, três dias de antecedência. A partir de uma análise prévia das instituições financeiras sobre as operações suspeitas essas instituições enviam para o COAF essas operações a qual ela faz uma pré análise dessas operações e gera um relatório, vantagem desse relatório que é o relatório de inteligência financeira que comunica as autoridades com essas informações.

Estão na polícia federal existe uma área de repressão aos crimes financeiros que recebe os RIF's que são relatório de inteligência financeira e faz uma análise, tabula o resultado do RIF's e também uma análise de diagramação. Então esse é o formato do relatório recebido pelo agente financeiro com várias informações além de empresas e o montante de dinheiro operacionalizado e as empresas que estão recebendo. É uma dependência muito grande para o desempenho da análise do RIF's de uma dependência do agente, ele tem que ser experiente e tem que também lembrar se aquela operação é parecido com outra operação que ele viu em outro RIF's, há um

descasamento de informações entre RIF's e a própria análise que pode ser bastante custosa dependendo do tamanho.

Após análise inicial o agente realiza uma tabulação dos RIF's colocando ali a origem de quem depositou, o depositante, a pessoa que vai receber o valor, o tipo de operação e um período, então ele faz manualmente essa análise e assim esse preenchimento.

A proposta é fazer o reconhecimento de entidades, eventos através de mineração de texto e armazenar em uma base de dados estruturados. Um processo de mineração de texto ele envolve três etapas principais: o pré-processamento de documentos, extração de padrões e agrupamentos de texto e avaliação do conhecimento.

Utilizamos as três métricas mais conhecidas para avaliar a mineração de textos, a precisão, Recall, F-Score. A precisão mede habilidades do sistema em manter os documentos relevantes, fora o resultado da consulta, ou seja, fórmula dos documentos recuperados relevantes do número total do curso recuperado, então a precisão é capaz de indicar o esforço que o usuário teria para analisar uma busca, isso significa que se em 60% dos itens retornados fossem relevante o usuário teria teoricamente desperdiçado 40% do seu esforço analisando os itens relevantes.

O Recall (abrangência ou revocação) mede a habilidade do sistema composto documentos mais relevante para o usuário com base em algumas expressões de busca utilizando a formação de busca, ou seja, seria os itens recuperados relevantes com os possíveis itens recuperadas, esses possíveis itens como não são conhecidos é uma medida estatística.

F-Score é um balanceamento uma média harmônica entre a precisão e o Recall que ele dá o quanto que essa medida de precisão e esforço foi feito pra poder fazer o reconhecimento das entidades.

A metodologia utilizamos a ferramentas spaCy e a base de dados HAREM e fizemos alguns testes utilizando o spaCy impuro na sua versão 2.0 no primeiro modelo, segundo modelo a gente usou o modelo original com 500 internações e 20 interações de dados de localidade, o terceiro modelo gerado com base no original acrescido com 20 interações de dados de treino, o modelo em branco acrescido com 20 iterações de dados de treino, um novo modelo HAREM com as interações de 2 a 110 e o spaCy com framework Rasa MLU.

Os resultados do REN para o RIF reconhecimento de entidades é de 1 a 6 esses modelos, a gente conseguiu esse quadro de resultados com F-Score até 30, o Recall até 38 no modelo 3 e uma precisão até 27.5 com um modelo 3, então o modelo 3, se a gente retornar para ver seria o modelo gerado com base na pesquisa acrescido com 20 iterações de treinamento, foi o modelo que melhor teve resultado, entretanto ainda é um estudo no qual a gente percebeu que realmente nós precisamos de mais dados e testar outros corpus para poder melhorar a precisão e chegar em uma precisão de 60% que é o que tem na literatura.

Então a gente realizou alguns testes com Rasa MLU, e a gente teve ali é uma identificação de 162 entidades com uma precisão de 60,98%, essa precisão é uma precisão que está de acordo com que se alcança para a literatura em português ao reconhecimento da entidade em português, então nosso trabalho está de acordo com que se tem ainda na literatura.

Bom para qualquer dúvida podem entrar em contato diretamente comigo, esse é o meu e-mail gustavo.araujo@ufsc.br.

Slides da apresentação

Título: Reconhecimento de entidades nomeadas em relatórios de inteligência financeira.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=4

Padrões de metadados para descrição de dados: panorama dos repositórios de dados na América Latina

Felipe Augusto Arakaki[a], Ana Carolina Simionato[b], Paula Regina Ventura Amorim Gonçalez[c] e Plácida Leopoldina Ventura Amorim da Costa Santos[d]

Resumo: Os repositórios de dados de pesquisa são ambientes que oportunizam aos dados, produtos de pesquisa, serem acessados, compartilhados, utilizados e reusados, visto que, tais ambientes possibilitam a organização, o armazenamento e o acesso aos dados em diferentes formatos. A preocupação com a representação e recuperação dos conjuntos de dados é recorrente entre profissionais que tem a informação como objeto de trabalho e pesquisa. Assim, questiona-se quais são os padrões de metadados utilizados na representação dos dados científicos disponibilizados nos repositórios de dados na América Latina? Nesse contexto, o trabalho possui como objetivo analisar a formalização dos padrões de metadados utilizados para a descrição do conjunto de dados de pesquisa no âmbito dos repositórios de dados da América Latina, registrados no Registry of Research Data Repositories (re3data). A pesquisa é de natureza teórico aplicada, com uma abordagem qualitativa no que se refere a representação da informação nos repositórios digitais de dados, para tanto optou-se pela pesquisa exploratória. Como resultado foi feito o mapeamento dos metadados dos 29 repositórios de dados científicos identificados no re3data. Ressalta-se que o reconhecimento para dados científicos e seu compartilhamento tem potencializado a criação de novas plataformas, softwares de gerenciamento e diferentes possibilidades para a descrição dos conjuntos de dados.

Palavras-chave: Descrição de conjuntos de dados. Metadados. Repositório de dados.

Metadata standards for data description: overview of data repositories in Latin America

Abstract: Research data repositories are environments that provide data, research products, are accessed, shared, used and reused, since such environments enable the organization, storage and access to data in different formats. The concern with the representation and retrieval of datasets is recurrent among professionals who have information as object of work and research. Thus, it is questioned what metadata patterns are used in the representation of the scientific data available in the data repositories in Latin America? In this context, the work aims to analyze the formalization of the metadata standards used to describe the set of research data within the Latin American data repositories registered in the Registry of Research Data Repositories (re3data). The research is of an applied theoretical nature, with a qualitative approach regarding the representation of the information in the digital repositories of data, for which we have opted for the exploratory research. As a result, the mapping of the metadata of the 29 research data repositories identified in the survey was done. It should be emphasized that the recognition of scientific data and their sharing has made possible the creation of new platforms, management software and different possibilities for the description of datasets.

Keyword: Description of datasets. Metadata. Data repository.

a Instituto Federal de São Paulo (IFSP). E-mail: fe.arakaki@gmail.com.. ORCID: https://orcid.org/0000-0002-3983-2563. Currículo: http://lattes.cnpq.br/5324289839207169

b Universidade Federal de São Carlos (UFSCar). E-mail: acsimionato@ufscar.br. ORCID: https://orcid.org/0000-0002-0140-9110. Currículo: http://lattes.cnpq.br/9896600626524397

c Universidade Federal do Espírito Santa (UFES). E-mail: paula.goncalez@ufes.br. ORCID: https://orcid.org/0000-0002-5480-4106. Currículo: http://lattes.cnpq.br/1072374287964657

d Universidade Estadual Paulista (UNESP). E-mail: placida@marilia.unesp.br. Currículo: http://lattes.cnpq.br/7408791408049766

1 Introdução

A preocupação para o efetivo gerenciamento de dados oriundos de pesquisas está sendo amplamente discutido pelas principais agências de fomento à pesquisa, visando o progresso científico além da contemporização de uma Ciência Aberta a todos os campos do conhecimento.

Esse movimento, torna-se salutar na concepção dos Repositórios de Dados. Os Repositórios de Dados de Pesquisa, se configuram como ambientes no auxílio a pesquisadores no que diz respeito à gerência, à disponibilização e ao acesso aos dados científicos, ações fundamentais, quando este ambiente permite e assegura o compartilhamento, o acesso e a reutilização dos dados, ações que reduzem sobremaneira o tempo e os gastos com nova coleta, como lhes chancelar validade diante a reprodução e replicação da pesquisa.

Vale destacar que os dados de pesquisa são definidos como:

> "[…] dados digitais são uma parte (descritiva) ou o resultado de um processo de pesquisa. Este processo abrange todas as etapas da pesquisa, que vão desde a geração de dados de pesquisa, que podem ser em um experimento nas ciências, um estudo empírico nas ciências sociais ou observações de fenômenos culturais, até a publicação dos resultados da pesquisa." (PAMPEL et al., 2013, p. 1, tradução nossa).

A disponibilização dos dados científicos para o acesso, usos e reúso, objetivo primeiro dos repositórios de dados, requer um planejamento e gerenciamento eficiente, segundo Simionato (2017) essas ações devem ser iniciadas desde a confecção do Data Management Plan (DMP) pelo pesquisador no depósito dos dados durante toda sua execução até sua finalização.

Para que os dados possam ser disponibilizados à comunidade científica se faz necessário apresentar requisitos padronizados e validados segundo normas internacionais e assegurar uma infraestrutura adequada para preservação digital.

Nesse sentido, parte desta infraestrutura equivale a composição dos metadados por meio de seus padrões. Assim, a representação e o armazenamento dos dados é uma preocupação recorrente do profissional que tem a informação como seu objeto de trabalho.

Há grande relação entre dados e metadados. Suas definições podem ser tratadas como muito similares. Jeffery et al. (2014, não paginado, tradução nossa) explicam que a percepção pode variar a partir do contexto da análise. Por exemplo, para uma pesquisa que faz uma busca em uma base de dados, ele utiliza metadados para descobrir um livro ou artigo, já para quem gerencia o sistema, a base de dados pode ser utilizada como dados para analisar as coleções por assunto, por editora, por ano etc.

Entre os principais padrões de metadados para descrição de objetos digitais está o Dublin Core (DC). O DC surgiu em 1995, com uma proposta de a partir de um núcleo reduzido, representar qualquer documento na Web. (ARAKAKI, ALVES, SANTOS, 2018).

Nesse contexto, o armazenamento, representação são fundamentais para recuperação e acesso à informação. Rodrigues et al. (2010) aponta que os repositórios de dados proveem serviços dirigidos à quem deposita e aos provedores do sistema que são como uma extensão dos repositórios digitais, porém afirma que: "Nos repositórios de dados pode-se ir além desta visão de repositórios de objetos, uma vez que cada conjunto de dados possui características próprias e por isso pode requerer um tratamento diferenciado" (RODRIGUES et al., 2010, p. 23).

Foram criados diversos tipos de repositórios de dados, como os repositórios temáticos que buscam reunir dados de uma área do conhecimento. Há uma tendência ainda, para os repositórios de dados institucionais, quando as Instituições de Ensino disponibilizam os dados oriundos de pesquisa para comunidade e ainda há possibilidade de repositórios relacionados a grupos de pesquisa conforme explorado por Vidotti et al. (2017).

Sales e Sayão (2015, p. 28) ao discorrerem sobre a implantação de repositórios de dados e curadoria digital de dados pontuam que "[…] as exigências sobre o nível de descrição e de atribuição de metadados deve ser identificadas desde o começo de seu projeto e revistas ao longo de vida dos seus dados". Os autores ainda complementam afirmando que essa é a essência da curadoria dos dados, ou seja, os metadados deverão assegurar a disponibilização dos dados para seu uso e reúso.

Nesse cenário, o crescimento do número de repositórios de dados nos leva a seguinte indagação: quais são os padrões de metadados utilizados na representação dos dados científicos disponibilizados nos repositórios de dados na América Latina?

Santos e Alves (2013) ao discorrerem sobre os padrões de metadados apontam que suas estruturas padronizadas representam um conteúdo informacional intencionam sua recuperação e acesso, ou seja, os padrões de metadados são "[...] um conjunto estruturado, padronizado, codificado e pré-determinado de elementos de metadados que serão utilizados na representação descritiva dos recursos informacionais, aplicações e ou compartilhamento de dados entre sistemas (ALVES; SANTOS, 2013, p. 13).

Nesse cenário, esse trabalho tem como objetivo analisar a formalização dos padrões de metadados utilizados para a descrição do conjunto de dados de pesquisa no âmbito dos repositórios de dados da América Latina, registrados no Registry of Research Data Repositories (re3data).

2 Procedimentos Metodológicos

O trabalho apresenta os resultados de uma abordagem qualitativa, referente à representação da informação nos repositórios de dados científicos. Para isso, optou-se pela realização de uma pesquisa exploratória e documental da literatura, nacional e internacional, sobre a temática e da descrição de conjunto de dados em repositórios de dados.

Durante a fase de identificação e verificação dos resultados, optou-se pela cobertura geográfica da América Latina. A base escolhida para a busca dos repositórios foi a re3data.org (disponível em: https://www.re3data.org/) sendo os resultados recuperados até o dia 04 de agosto de 2018.

A re3data.org configura-se como um registro global de repositórios de dados de pesquisa que abrange repositórios de dados de pesquisa de diferentes disciplinas acadêmicas. O filtro utilizado foi a cobertura geográfica, no caso a América Latina, e os resultados apresentaram 29 repositórios de dados, que serão abordados no próximo tópico.

3 Resultados

Dos 29 repositórios identificados, foram localizados onze (11) repositórios no México, oito (8) repositórios no Brasil, Argentina, Colômbia e Panamá foram localizados dois

(2) repositórios cada e Chile, El Salvador e Peru foi localizado um (1) repositório cada. Importante relatar que até o dia 4 de agosto de 2018, nos países: Bolívia, Costa Rica, Cuba, Equador, Guatemala, Haiti, Honduras, Nicarágua, Paraguai, República Dominicana, Uruguai e Venezuela não foram encontrados nenhum repositório cadastrado na re3data.org.

Durante o levantamento, foi observado que cinco (5) repositórios utilizam o software Dspace, três (3) repositórios utilizam software DataVerse, dois (2) repositórios utilizam Drupal, um (1) repositório utiliza o Metacat, e um repositório informou que usa a denominação de "outro", mas não especificou o software utilizado. Entre os repositórios analisados, um considerou o MySQL como sistema utilizado e 16 repositórios apontaram que o sistema é desconhecido no contexto do re3data ou não informaram. O uso de um software adequado para organização e tratamento dos dados influencia diretamente nas possibilidades de recuperação, armazenamento, representação da informação e o estabelecimento de padrões de metadados.

Nesse contexto os repositórios da América Latina, os repositórios: Repositorio Institucional USIL (Peru), Repositorio Institucional UCASAL (Argentina), Base de Dados Científicos da Universidade Federal do Paraná (Brasil), CEDAP Research Data Repository – research data (Brasil) adotam o Dublin Core. Destaca-se que sua composição básica possui 15 elementos que são opcionais e repetíveis, além da possibilidade de expandir a quantidade de elementos e refinamentos.

Em contrapartida, há diversos outros padrões específicos para descrição de dados no contexto dos repositórios de dados. Conforme o levantamento realizado, três (3) repositórios (CIAT Dataverse – Colômbia; IBICT Dataverse Network – Brasil; e CIMMYT Research Data & Software Repository Network – Mexico) utilizam um padrão internacional para descrição de dados científicos, o Data Documentation Initiative (DDI). Os metadados do DDI permite representar o conjunto de dados e gerenciar diferentes estágios no ciclo de vida dos dados de pesquisa, como conceituação, coleta, processamento, distribuição, descoberta e arquivamento. (DATA DOCUMENTATION INITIATIVE, 2018).

O padrão Darwin Core é utilizado no Portal de datos de Biodiversidad (Argentina). O Darwin Core está estruturado com base no Dublin Core, XML e RDF Schema e inclui um glossário de termos tendo como objetivo facilitar o compartilhamento de informações sobre diversidade biológica. (DARWIN CORE TASK GROUP, 2014).

No contexto dos dados ecológicos, o PPBio Data Repository (Brasil) adotou o Ecological Metadata Language (EML), que é uma especificação de metadados que está na versão 2.1.1, implementado como uma série de tipos de documentos XML que podem ser usados de maneira modular e extensível. (KNOWLEDGE NETWORK FOR BIOCOMPLEXITY, 2015).

Para descrição de dados geoespaciais, o repositório Integrated Taxonomic Information System (ITIS) do México optou por utilizar o Federal Geographic Data Committee Content Standard for Digital Geospatial Metadata (FGDC/CSDGM) que estabelece e implementa orientações para descrição do conteúdo, da qualidade e da transferência de dados geoespaciais. Entre os tipos de materiais estão mapas, arquivos de Sistemas de Informações Geográficas (GIS), imagens e outros recursos. (FEDERAL GEOGRAPHIC DATA COMMITTEE, 2014).

Para o intercâmbio de dados no âmbito da área da astronomia o Flexible Image Transport System (FITS) foi adotado pelo repositório Gran Telescopio CANARIAS Public Archive, do México. O FITS é um padrão recomendado pela NASA e pela International Astronomical Union e usado para o transporte, análise e armazenamento de arquivos de conjuntos de dados científicos, pode apresentar matrizes multidimensionais como espectros 1D, imagens 2D, 3D e mais os cubos de dados. (NASA, 2017).

Entre os repositórios analisados, a ISO 19115 que define o esquema para descrever informações e serviços geográficos por meio de metadados é utilizado no International Ocean Discovery Program (Brasil). O padrão da ISO fornece informações sobre a identificação, a extensão, a qualidade, os aspectos espaciais e temporais, o conteúdo, a referência espacial, a representação, a distribuição e outras propriedades dos dados e serviços geográficos digitais. (INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, 2014).

O Access to Biological Collection Data (ABCD) é utilizado pelo repositório internacional GLOBE, com abrangência no Brasil. O ABCD é um padrão que abrange a descrição de dados de espécimes de coleções de história natural e de espécies em geral. (BOTANIC GARDEN AND BOTANICAL MUSEUM BERLIN-DAHLEM, 2016).

Diante o levantamento, foi observado que mais da metade dos repositórios analisados, dezesseis (16), não informaram se utilizam algum padrão de metadados ou se optaram pelos metadados já identificados como descritores do software aderido.

4 Considerações Finais

Durante o levantamento realizado, constatou-se que grande parte dos repositórios da América Latina não utilizam ou não informaram os padrões de metadados adotados, isto é, como já apresentado nos resultados 16 repositórios não referenciam à padrões.

O padrão de metadados mais adotado entre os 29 repositórios de dados é o Dublin Core, em razão da utilização do software Dspace que já faz parte da instalação da plataforma.

Em compensação, alguns repositórios utilizam metadados específicos da área do repositório, possibilitando uma descrição mais exaustiva das informações além de permitir a interoperabilidade entre sistemas.

Outro ponto de destaque, é que os princípios de descrição dos conjuntos de dados são fundamentados nos mesmos princípios de descrição de outros tipos de recursos informacionais, sendo que propriedades de clareza, precisão, lógica e integridade devem ser equalizadas para todos os tipos de recursos, diferenciando-se apenas, em especificidades relativas à forma e formato.

O reconhecimento para a importância dos dados científicos, bem como o seu compartilhamento em repositórios vêm se potencializando com a criação de novas plataformas, softwares para o gerenciamento e outras possibilidades para a descrição de conjuntos de dados, entretanto, ainda carece de pesquisas e desenvolvimento.

Referências

ALVES, R. C. V.; SANTOS, P. L. V. A. C. **Metadados no domínio bibliográfico**. Rio de Janeiro: Intertexto, 2013.

ARAKAKI, F. A.; ALVES, R.C.V.; SANTOS, P.L.V.A. da C. Dublin Core: state of art (1995 to 2015). **Informação & Sociedade**: Est., João Pessoa, v. 28, n. 2, p. 7-20, maio/ago. 2018. Disponível em:<http://www.periodicos.ufpb.br/ojs2/index.php/ies/article/view/38012/pdf >. Acesso em: 19 nov. 2018.

BOTANIC GARDEN AND BOTANICAL MUSEUM BERLIN-DAHLEM. **Access to Biological Collection Data schema**. 2016. Disponível em: <http://www.biocase.org/products/schema_repository/>. Acesso em: 6 ago. 2018.

DARWIN CORE TASK GROUP. **Darwin Core**. 2014. Disponível em:<http://rs.tdwg.org/dwc/index.htm >. Acesso em: 6 ago. 2018.

DATA DOCUMENTATION INITIATIVE. **Welcome to the Data Documentation Initiative**. 2018. Disponível em: <http://www.ddialliance.org/ >. Acesso em: 6 ago. 2018.

FEDERAL GEOGRAPHIC DATA COMMITTEE. **Geospatial Metadata**. 2014. Disponível em: <https://www.fgdc.gov/metadata >. Acesso em: 6 ago. 2018.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 19115-1:2014 –** Geographic information – Metadata – Part 1: Fundamentals. Disponível em: <https://www.iso.org/standard/53798.html >. Acesso em: 6 ago. 2018.

JEFFERY, K. et al. A 3-Layer Model for Metadata. INTERNATIONAL CONFERENCE ON DUBLIN CORE AND METADATA APPLICATION, 13., Portugal, **Anais**… DCMI, EUA. 2014. Disponível em: <http://dcevents.dublincore.org/IntConf/dc-2013/paper/view/199/199 >. Acesso em: 17 out. 2015.

KNOWLEDGE NETWORK FOR BIOCOMPLEXITY. **Ecological Metadata Language (EML)**. 2015. Disponível em: <https://knb.ecoinformatics.org/#external//emlparser/docs/index.html>. Acesso em: 6 ago. 2018.

NASA. **FITS Support Office**. 2017. Disponível em: <https://fits.gsfc.nasa.gov/ >. Acesso em: 6 ago. 2018.

PAMPEL, H. et al. Making research data repositories visible: The re3data. org registry. **PloS one**, v. 8, n. 11, p. e78080, 2013. Disponível em: <http://bit.ly/2vHTqGA>. Acesso em: 07 out. 2018.

RODRIGUES, E. et al. **Os repositórios de dados científicos:** estado da arte. 2010. Disponível em: <http://projeto.rcaap.pt/index.php?option=com_remository&Itemid=2&func=startdown&id=271&lang=pt>. Acesso em: 15 set. 2018.

SAYÃO L. F.; SALES, L. F. Guia de gestão de dados de pesquisa para bibliotecários e pesquisadore. Rio de Janeiro : CNEN/IEN, 2015. Disponível em:<http://carpedien.ien.gov.br/bitstream/ien/1624/1/GUIA_DE_DADOS_DE_PESQUISA.pdf>. Acesso em: 08 mar. 2017.

SIMIONATO, A. C. Mapeamento dos metadados para dados científicos. In: ENCONTRO NACIONAL DE PESQUISA EM CIÊNCIA DA INFORMAÇÃO, 18. 2017, Marília. **Anais…**: Marília: UNESP, 2015. Disponível em: <http://enancib.marilia.unesp.br/index.php/xviiienancib/ENANCIB/paper/view/563>. Acesso em: 02 de out. 2018.

VIDOTTI, S. A. B. G. et al. Repositório de dados de pesquisa para grupo de pesquisa: um projeto piloto. In: ENCONTRO NACIONAL DE PESQUISA EM CIÊNCIA DA INFORMAÇÃO, 18, 2017, Marília. **Anais…** Marília: UNESP, 2017.Disponível em: <http://enancib.marilia.unesp.br/index.php/xviiienancib/ENANCIB/paper/viewFile/388/932>. Acesso em: 17 set. 2018.

Vídeo da apresentação

Título: Padrões de metadados para descrição de dados: panorama dos repositórios de dados na América Latina.

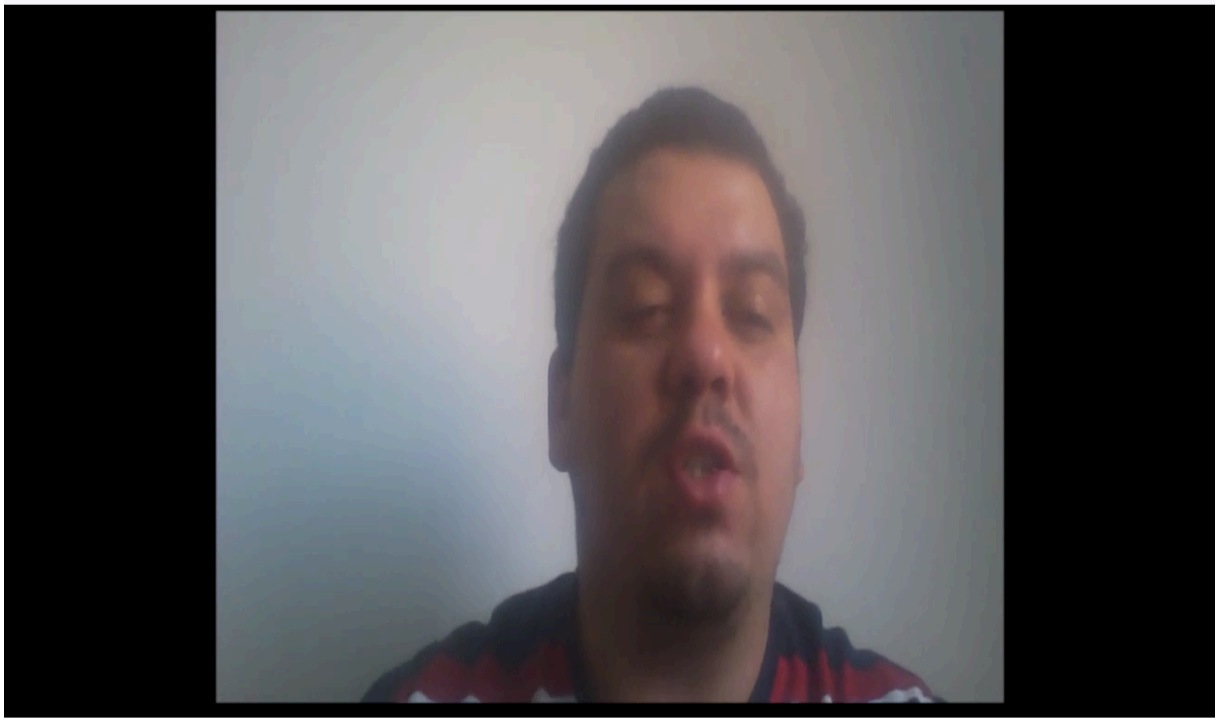

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=5

Transcrição da apresentação

Olá eu sou Felipe Augusto Arakaki, bibliotecário do Instituto Federal de São Paulo e vou apresentar o trabalho que abrange metadados para a descrição de dados e o panorama nos repositórios da América Latina. Trabalho aprovado no 2º Workshop de Informação Dados e Tecnologia 2018.

Esse trabalho é fruto de uma parceria com a Profª Ana Carolina Simionato da UFSCAR; Paula Regina Ventura Amorim Gonçalez da UFES e Plácida Leopoldina Ventura Amorim da Costa Santos da UNESP.

A preocupação para o efetivo gerenciamento de dados oriundos de pesquisas está sendo amplamente discutido pelas principais agências de fomento à pesquisa, visando o progresso científico além da contemporização de uma ciência aberta a todos os campos do conhecimento, esse movimento torna-se salutar na concepção dos repositórios de dados que são ambientes no auxílio a pesquisadores para a gerência disponibilização e acesso aos dados científicos.

A disponibilização de dados científicos para o acesso uso e reúso requer um planejamento e gerenciamento eficiente que devem ser iniciado desde a confecção do Data Management Plan ou plano de gerenciamento de dados pelo pesquisador no depósito dos dados durante toda a sua execução até a sua finalização para que os dados possam ser disponibilizados à comunidade científica se faz necessário apresentar requisitos padronizados e validadas segundo normas internacionais e assegurar uma infraestrutura adequada para a preservação digital.

Nesse sentido parte dessa infraestrutura equivale a composição dos metadados por meio dos seus padrões, assim a representação e o armazenamento dos dados é uma preocupação recorrente do profissional que tenha informação como seu objeto de trabalho.

Nesse contexto o crescimento do número de repositório de dados nos leva a seguinte indagação: quais são os padrões de metadados utilizado na representação dos dados científicos disponibilizado no repositório de dados na América Latina?

O objetivo desse trabalho é analisar a formalização dos padrões de metadados utilizados para descrição dos conjuntos de dados de pesquisa no âmbito dos repositórios de dados da América Latina, registrados no Registry of Research Data Repositories.

O trabalho apresenta os resultados de uma abordagem qualitativa referente à representação da informação dos repositórios de dados científicos, para isso optou-se pela realização de uma pesquisa exploratória documental na literatura nacional e internacional sobre a temática e da descrição de conjuntos de dados em repositórios de dados.

Durante a fase de identificação e verificação dos resultados optou-se pela cobertura geográfica da América Latina. A base escolhida para a busca dos repositórios foi o re3data.org, sendo os resultados recuperados até o dia 4 de agosto de 2018. A base de dados re3data.org configura-se registo global dos repositórios de dados de pesquisa que abrange repositório de dados pesquisa de diferentes disciplinas acadêmicas, o filtro utilizado foi a cobertura geográfica no caso da América Latina e os resultados apresentaram, 29 repositórios cadastrados. Dos 29 repositórios identificados foram localizados 11 repositórios do México, oito repositórios do Brasil, dois repositórios na Argentina, dois na Colômbia e dois no Panamá; Chile, El Salvador e Peru, foram localizados um repositório em cada um dos países; Bolívia, Costa Rica, Cuba,

Equador, Guatemala, Haiti, Honduras, Nicarágua, Paraguai, República Dominicana, Uruguai e Venezuela não foram localizados nenhum repositório cadastrado.

Durante o levantamento foi observado que cinco repositórios utilizam o software DSpace, três repositórios utiliza o software Dataverse e dois repositórios utilizam o Drupal, um repositório utiliza o MetaCAP, um informou que usa a denominação "outro" mas não especificou o software utilizado. Entre os repositórios analisados ainda um considerou My-SQL como sistema de gerenciamento, os outros 16 repositórios apontaram que o sistema é desconhecido no contexto da plataforma re3data ou não informaram qual é o repositório ou sistema utilizado.

O uso de um software adequado para organizações de tratamento de dados influenciam diretamente nas possibilidades de recuperação, armazenamento, representação, acesso e uso das informações e também os padrões de metadados que vão suportar toda a representação da informação.

Dos 29 repositórios analisados quatro informaram que utilizam o padrão Dublin Core para representação da informação. O Dublin Core é um padrão geral de uso da web e possui basicamente 15 elementos, não foi possível observar nessa fase da pesquisa se esses repositórios utilizam perfis de aplicação ou utilizam o Dublin Core qualificado para descrição das informações, em contrapartida, diversos outros repositórios utilizam padrões específicos da área de conhecimento em que o repositório está relacionado. Três repositórios utilizam a data documento iniciativa, um repositório informou que utilizam o padrão Darwin Core para representação dos documentos, ele é um padrão específico para área da biodiversidade, um repositório informou que usa o Ecological Metadata Language (EML) que está dentro do contexto de metadados da ecologia, um repositório informou que utiliza o Federal Geographic Data com Content Standard for Digital Geospatial Metadata que está relacionado a dados geoespaciais, um repositório que está no âmbito da astronomia informou que usa o Flexible Image Transport System, outro repositório informou que utiliza a ISO 19115 que e para dados geográficos também, um repositório informou que utiliza o ABCD que é o Access to Biological Collection Data, os demais repositórios não informaram o padrão de metadados que é utilizado para descrição das informações.

Durante o levantamento realizado constatou-se que grande parte dos repositórios da América Latina não utiliza ou não informaram os padrões de metadados adotados. Entre os 29 repositórios analisados o padrão que mais se destacou foi o Dublin Core. Em compensação alguns repositórios utilizam metadados específicos da área do repositório, possibilitando uma descrição exaustiva das informações, além de permitir a interoperabilidade entre esses sistemas, outro ponto de destaque é que os princípios de descrição dos conjuntos de dados são fundamentados nos mesmos princípios de descrição de outros tipos de recursos internacionais, sendo que as propriedades de clareza, precisão, lógica e integridade devem ser equalizadas para todos os tipos de recursos diferenciando se apenas em especificidade relativa na forma e formato.

O reconhecimento para a importância dos dados científicos bem como o seu comportamento em compartilhamento de repositórios vem se potencializando com a criação de

novas plataformas software sistemas para gerenciamento e outras possibilidades descrição de conjunto de dados entretanto essas pesquisas ainda carecem de desenvolvimento.

Obrigado.

O termo Big Data: quebra de paradigma dos n-V's

Marcos de Souza[a], Fernanda Gomes Almeida[b] e Renato Rocha Souza[c]

Resumo: Os dados são considerados o novo petróleo da era digital. O crescimento e integração de grandes volumes de dados digitais – Big Data – têm sido utilizados para tomada de decisão em diferentes áreas. Entretanto, percebe-se que não existe uma universalização do conceito de Big Data, sobretudo, no meio acadêmico por se tratar de um termo relativamente novo. A pesquisa tem como objetivo identificar os conceitos relacionados ao termo Big Data e; identificar as características que compõem o conceito. A pesquisa foi elaborada com base em artigos científicos e livros digitais e impressos publicados entre os anos de 2011 e 2018. Como resultado percebe-se que a literatura apresenta tradicionalmente 5V's como características de um Big Data, sendo volume, variedade, velocidade, veracidade e viabilidade. Contudo, a pesquisa permitiu identificar mais 2V's e diversos conceitos para o termo, o que não permite assim uma consolidação do termo. Com o avanço tecnológico, novas possibilidades têm surgido e colocado as características em cheque. Sugere-se como pesquisas futuras uma caracterização real do termo de forma que o mesmo não esteja atrelado a determinada letra alfabética.

Palavras-chave: Big Data. Conceito. Viabilidade. Venalidade. n-V's.

The term Big Data: paradigm break of n-V's

Abstract: Data is considered the new oil of the digital era. The growth and integration of large volumes of digital data – Big Data – have been used for decision making in several areas. However, this is not an international model of big data. A research aims to identify the data related to the term Big Data and; identify as characteristics that make up the concept. The research was based on scientific and printed data between the years 2011 and 2018. As a result it realizes that a literature is traditionally produced as a large volume of data, being volume, variety, speed, veracity and feasibility. In this article, you may have more information about the concepts of a term that is not mandatory. With technological technology, new features have emerged and placed as features in check. It is suggested as a new form of characterization of the term so that it is not tied to an alphabetic letter.

Keyword: Keywords: Big data. Concept. Viability. Venality. N-V's.

a Universidade Federal de Minas Gerais (UFMG). E-mail: marcosdesouza82@gmail.com. ORCID: https://orcid.org/0000-0002-9829-7249. Currículo: http://lattes.cnpq.br/3958131052236839

b Universidade Federal de Minas Gerais (UFMG). E-mail: usernanda@gmail.com. ORCID: https://orcid.org/0000-0001-7913-827X. Currículo: http://lattes.cnpq.br/5601300780102290

c Fundação Getúlio Vargas (FGV). E-mail: rsouza.fgv@gmail.com. ORCID: https://orcid.org/0000-0002-1895-3905. Currículo: http://lattes.cnpq.br/4726949697973381

1 Introdução

Os dados são considerados o novo petróleo na era digital, possuindo um valor altamente estratégico. Tão importante quanto o petróleo, os dados são a arma mais poderosa da sociedade. Grandes empresas tecnológicas como Amazon, Apple, Facebook, Google e Microsoft apresentaram um faturamento maior que 25 bilhões de dólares apenas no primeiro semestre de 2017, demonstrando que as organizações que detêm os dados também detêm o poder (ECONOMIST, 2017).

A produção e armazenamento de dados têm passado por um processo evolutivo desde a popularização dos computadores e a difusão da internet, dessa forma, tem ganhando destaque a partir de uma produção massiva de dados realizada por meio de sites, redes sociais digitais, smartphones, sistemas informatizados, satélites, sensores de carros, aviões e trens, câmeras de segurança entre outros tipos de serviços como streaming (AMARAL, 2016). Além da evolução referente a capacidade de armazenamento de dados, faz necessário destacar também o quantitativo de vezes que os dados são compartilhados pelos usuários (MARQUESONE, 2016).

O conceito de Big Data foi cunhado a partir do crescimento e integração de grandes volumes de dados digitais produzidos por diversos meios e tecnologias, bem como pelo uso de ferramentas que perpassam as etapas de produção, compartilhamento, curadoria e análise de maneira eficiente dessa gigantesca quantidade de dados, resultando em informações de valia e permitindo descobrir novos padrões significativos de conhecimentos (SAKR, 2016; ELSHAWI; SAKR, 2018).

Buscas realizadas utilizando o termo Big Data nas ferramentas de pesquisa acadêmica Google Scholar e o Portal de Periódicos da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) apresentou como resultado, respectivamente, 4.820.000 e 1.739.128 documentos que abordam de alguma forma a temática Big Data. Já a pesquisa realizada no buscador Google apresentou aproximadamente 4.170.000.000 resultados. Assim, trata-se de um quantitativo bastante representativo, uma vez que se refere a um termo que foi cunhado há poucos anos.

A definição de Big Data é considerada pobre (BOYD; CRAWFORD, 2012), equivocada e genérica, pois refere-se apenas ao tamanho (DAVENPORT, 2017). Contudo, este trabalho parte do princípio que o Big Data é um termo em fase de amadurecimento e que ainda está em processo de consolidação de conceitos.

Justifica-se a importância desse trabalho pela notoriedade do termo Big Data nos últimos anos, tanto no meio acadêmico quanto empresarial e pela discrepância entre os conceitos encontrados na literatura. Como hipótese, acredita-se que, por se tratar de um termo relativamente novo e principalmente por estar atrelado aos meios e avanços tecnológicos, possam surgir cotidianamente novas características que contribuem para essa diversidade de conceitos.

2 Objetivos

O trabalho tem como objetivo identificar os conceitos relacionados ao termo Big Data e, identificar as características que compõem o conceito.

3 Procedimentos Metodológicos

Esta é uma pesquisa de natureza básica, abordando o problema de forma qualitativa. Do ponto de vista dos seus objetivos, é classificada como exploratória e descritiva. Da perspectiva dos procedimentos técnicos, identifica-se como pesquisa bibliográfica (GIL, 2010; Gil, 2016).

A pesquisa consiste em um levantamento, análise e seleção de trabalhos que trazem uma conceituação do termo Big Data, bem como suas características, publicados entre os anos de 2011 e 2018.

Os trabalhos foram identificados a partir de pesquisas realizadas no Portal de Periódicos da CAPES e no Google Scholar. Além desses, foram utilizados artigos científicos, livros digitais e impressos da área de domínio.

As publicações selecionadas serviram como base para a identificação dos conceitos relacionados ao termo Big Data, bem como a identificação das características que compõem o seu conceito.

4 Resultados

Um número expressivo de documentos acadêmicos apresenta uma série de conceitos sobre o termo Big Data. Esses conceitos são apresentados no Apêndice A. Verifica-se dessa forma, uma diversidade de conceitos o que pode contribuir para a não consolidação do termo.

A consultoria Gartner desenvolveu um estudo no ano de 2001 no qual apresentou o volume, a variedade e a velocidade – conhecidos como 3V's – como um dos maiores desafios para a manipulação e a gestão de dados. Esse viés tem sido discutido com maior relevância no meio acadêmico (Laney, 2001). Posteriormente, a veracidade (qualidade) valor (relevância) foram incorporadas aos 3V's e constituíram assim o 5V's. Essas características têm ganhado destaque nas investigações relacionadas ao meio empresarial (Assunção et al., 2015). Tais características são utilizadas para definir o termo Big Data.

Contudo, além dos 5V's, outras características podem surgir, formando assim os n-V's, uma vez que o conceito de Big Data está atrelado aos avanços tecnológicos.

4.1 Big Data e suas características

O Big Data é um fenômeno tecnológico e humano no qual são produzidos dados em diversos formatos e que são armazenados em grandes quantidades de dispositivos de armazenamento. Refere-se às características inerentes de um Big Data os n-V's, sendo eles:

- Volume – relaciona-se ao quantitativo de informações armazenadas em dispositivos físicos ou virtualizados. No atual cenário, os armazenamentos de dados perpassam por um crescimento exponencial mediante a tecnologia de computação nas nuvens. Os dados têm sido criados em escala de zetabytes por meio de diversas fontes e aplicações por atividades cotidianas (VASCONCELOS; BARÃO, 2017). Considerando que bilhões de pessoas geram informações diariamente por meio da internet, estima-se que o volume de informações produzidas possa dobrar a cada 18 meses. O atributo volume é considerado a característica mais importante no conceito de Big Data e faz dimensão sem precedentes do volume de dados (MACHADO, 2018);

- Variedade – define a diversidade de informações e dados produzidos e que possuem formatos heterogênicos, podendo ser dados estruturados, não estruturados ou semiestruturados que são criados, compartilhados e consumidos em diferentes formatos e uma variedade de fontes de dados, como, por exemplo, upload de fotos, transmissão de vídeos em tempo real, textos publicados em redes sociais (MACHADO, 2018). A variedade também indica a variação das áreas de aplicações de um Big Data, tais como as áreas governamentais, financeiras, transportes e automação, varejistas, seguros e outras possibilidades (VASCONCELOS; BARÃO, 2017);
- Velocidade – além dos desafios referentes ao volume e variedade de dados, o Big Data faz referência a agilidade em que os dados são coletados, processados, analisados e utilizados (MARQUESONE, 2016; VASCONCELOS; BARÃO, 2017; MACHADO, 2018). Um fator que contribuiu positivamente para a característica da velocidade está na evolução das telecomunicações, tais como largura de banda e infraestrutura física, possibilitando assim que os dados sejam transportados com uma maior velocidade por meio da internet (VASCONCELOS; BARÃO, 2017);
- Veracidade – diz respeito a qualidade dos dados e a confiabilidade sobre as fontes dos dados. O Big Data está inserido em um contexto de variedade e volume de dados, sendo comum a existência de dados inconsistentes. Dessa forma, torna-se necessário garantir a autenticidade das fontes e dos dados coletados de forma que sejam confiáveis para uma determinada solução (MARQUESONE, 2016; VASCONCELOS; BARÃO, 2017; MACHADO, 2018);
- Valor – caracteriza-se pelo quão valioso e significativo um dado pode ser para uma determinada solução em um Big Data, obtendo assim valor qualitativo a partir do volume, variedade e velocidade de dados (MARQUESONE, 2016). Torna-se importante ressaltar que se trata da relevância dos dados após o processamento. Os dados brutos perpassam por análise e processamento onde poderão ser acrescidos de valor, transformando-se em vantagem competitiva para negócios. (VASCONCELOS; BARÃO, 2017; MACHADO, 2018).
- Viabilidade – destina-se a identificar o relacionamento entre variáveis e padrões latentes de dados (BIEHN, 2013). Esse conceito pode ser discutido, por exemplo, em modelagem de tópicos que faz uso de machine learning e processamento de linguagem natural em grandes corpora textuais para identificar a emersão dos tópicos latentes.
- Venalidade – projetado futuramente em formatos que possam ser vendidos (DAVENPORT, 2017). A questão da venda de dados já ocorre por meio de empresas prestadoras de serviços online, entretanto, o autor discute a questão de um formato específico para o conceito de grandes volumes de dados.

5 Considerações Finais

O termo Big Data, novo se comparado a outros conceitos científicos consolidados na literatura, apresenta uma diversidade de conceitos, contribuindo para a não consolidação do termo. Esse fato pode ser observado no Apêndice A que mostra uma não uniformidade entre as

definições elaboradas pelos diversos autores, inclusive com críticas, disparidades, simplicidade e homogeneidade.

Outro fator que contribui para falta de consolidação do termo Big Data está nas suas características. Inicialmente conhecidas por 3V's – volume, variedade e velocidade; mais tarde com o acréscimo de veracidade e viabilidade tornando-se 5V's; porém, as características que compõem o conceito de Big Data ultrapassam esse quantitativo, podendo ser acrescentado também viabilidade e venalidade, tornando-se assim 7V's. Essa evolução de características de palavras iniciadas com a letra "V" tem acontecido mediante ao surgimento de novas necessidades que aparecem ao se realizar algum tipo de processamento com Big Data e também por conta do avanço tecnológico. Entretanto, acredita-se que as tecnologias estejam longe de serem estabilizadas. Com isso, novas possibilidades ou novos "V's" poderão surgir nos próximos anos, como por exemplo, a Variabilidade – capacidade de submeter-se a variações de mudanças; e Visualização de dados associados ao Big Data. Percebe-se que as características associadas ao conceito de um Big Data no que diz respeito aos 5V's tem se apresentado de forma sólida na literatura, entretanto, com o avanço tecnológico, novas possibilidades têm surgido e colocado as características em cheque. Dessa maneira, surge o que podemos chamar de n-V's, um paradigma ainda em construção, aberto para as novas características ou representações do termo Big Data.

Ressalta-se que, em busca realizada no Portal de Periódicos da CAPES utilizando os termos "n-V's Big Data", "nV's Big Data", "n- Vs Big Data" e "nVs Big Data", apesar da quantidade elevada de resultados que tratam do Big Data, não foram encontrados resultados que abordem os n-V's da forma que foi proposta neste trabalho – o paradigma dos n- V's.

Sugere-se como pesquisas futuras uma quebra de paradigmas com relação à caracterização real do termo de forma que o mesmo não esteja atrelado à determinada letra alfabética, e sim ao que de fato representa um Big Data. Além disso, perspectivas futuras sobre o Big Data e tecnologias podem contribuir para a formação de um conceito consolidado, embora acredita-se que possa levar anos para realização de uma definição universalizada do conceito.

Referências

AMARAL, F. **Introdução à ciência de dados**: mineração de dados e big data. Rio de Janeiro: Alta Books, 2016.

ASSUNÇÃO, M. D. et al. Big Data computing and clouds: trends and future directions. **Journal of Parallel and Distributed Computing**, v. 79, p. 3-15, 2015.

BIEHN, N. The missing V's in big data: viability and value. **Wired**, New York, 2013. Disponível em: <https://www.wired.com/insights/2013/05/the-missing-vs-in-big-data-viability-and-value>. Acesso em: 10 set. 2018.

BOYD, D.; CRAWFORD, K. Critical questions for big data. Provocations for a cultural, technological, and scholarly phenomenon. **Information, Communication & Society**, v. 15, n. 5, p. 663, 2012.

COORDENAÇÃO DE APERFEIÇOAMENTO DE PESSOAL DE NÍVEL SUPERIOR. **Portal de Periódicos**. Disponível em: <http://www.periodicos.capes.gov.br/>. Acesso em: 05 set. 2018.

CRAWFORD, K.; SCHULTZ, J. Big Data and Due Process: toward a Framework to Redress Predictive Privacy Harms. **Boston College Law Review**, v. 55, n. 1, p. 93-128, 2014. Disponível em: <http://lawdigitalcommons.bc.edu/bclr/vol55/iss1/4 >. Acesso em: 11 set. 2018.

DAVENPORT, T. H. **Big Data no trabalho**: derrubando mitos e descobrindo oportunidades. Rio de Janeiro: Alta Books, 2017.

ECONOMIST. **The world's most valuable resource**: data and the new rules of competition. London, v. 423, n. 9039, 2017.

ELSHAWI, R.; SAKR, S. Big Data Systems Meet Machine Learning Challenges: towards Big Data Science as a Service. **Big Data Research**, v. 5, n. 10, p. 7, 2018. Disponível em: <https://arxiv.org/pdf/1709.07493.pdf>. Acesso em: 5 set. 2018.

FRICKÉ, M. Big data and its epistemology. **Journal of the Association for Information Science and Technology**, v. 66, n. 4, p. 651-661, 2015.

GANTZ, J.; REINSEL, D. Extracting value from chaos. **IDC Review**, v. 1142, n. 2011, p. 1-12, 2011. Disponível em: <https://www.emc.com/collateral/analyst-reports/idc-extracting-value-from-chaos-ar.pdf>. Acesso em: 09 set. 2018.

BIG DATA. In: IT GLOSSARY. Stamford: Gartner Group, 2012. Disponível em: <https://www.gartner.com/it-glossary/big-data/ >. Acesso em: Acesso em 09 set. 2018.

GEORGE, G.; HAAS, M. R.; PENTLAND, A. Big Data and Management. **Academy of Management Journal**, 2014, Vol. 57, No. 2, 321–326. Disponível em:<http://dx.doi.org/10.5465/amj.2014.4002>. Acesso em: 07 set. 2018.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010.

____. **Métodos e técnicas de Pesquisa Social**. 6. ed. São Paulo: Atlas, 2016.

GOMES, R. D. P. **Big Data: desafios à tutela da pessoa humana na sociedade da informação**. Rio de Janeiro: Lumen Juris, 2017.

GOOGLE. Disponível em: <http://www.google.com/>. Acesso em: 05 set. 2018.

GOOGLE SCHOLAR. Disponível em: <https://scholar.google.com.br/>. Acesso em: 05 set. 2018.

HIJMANS, H. **The european union as guardian of internet privacy**. Brussels: Springer International Publishing, 2016.

INTERNATIONAL BUSINESS MACHINES (IBM). O que é Big Data, 2014. Disponível em: <https://i.pinimg.com/originals/f6/5c/fd/f65cfdfe4813b82155e9a35eacf590f4.jpg >. Acesso em: 10 set. 2018.

INSTITUTO DE TECNOLOGIA & SOCIEDADE DO RIO (ITSRio). Big Data no projeto Sul Global: relatório sobre estudos de caso. Rio de Janeiro: p.26, 2016. Disponível em: <https://itsrio.org/wp-content/uploads/2016/03/ITS_Relatorio_Big-Data_PT-BR_v2.pdf>. Acesso em: 9 set. 2018.

LANEY, D. 3D data management: controlling data volume, velocity and variety. **META Delta, Stamford**, 6 fev. 2001. Application Delivery Strategies. Disponível em: <https://blogs.gartner.com/doug-laney/files/2012/01/ad949-3D-Data-Management-Controlling-Data-Volume-Velocity-and-Variety.pdf>. Acesso em 9 set. 2018.

MACHADO, F. N. R. **Big Data**: o futuro dos dados e aplicações. São Paulo: Érica, 2018.

MAYER-SCHÖNBERGER, V.; CUKIER, K. **Big Data**: como extrair volume, variedade, velocidade e valor da avalanche de informação cotidiana. Rio de Janeiro: Elsevier, 2013.

MARQUESONE, R. **Big Data**: técnicas e tecnologias para extração de valor dos dados. São Paulo: Casa do Código, 2016.

PROVOST, F.; FAWCETT, T. **Data Science para negócio**s: o que você precisa saber sobre mineração de dados e pensamento analítico de dados. Rio de Janeiro: Alta Books, 2016.

SAKR, S. **Big data 2.0 processing systems**: a survey. Springer International Publishing, 2016.

TAURION, C. **Big data**. Brasport, 2013.

VASCONCELOS, J. B.; BARÃO, A. **Ciência dos dados nas organizações:** aplicações em python. Lisboa: FCA, 2017.

VOLPATO, T; RUFINO, R. R.; DIAS, J. W. **Big data – transformando dados em decisões**. 2014. Disponível em: <http://web.unipar.br/~seinpar/2014/artigos/graduacao/Tiago_Volpato.pdf>; Acesso em: 9 set. 2018.

Apêndice A – Conceitos de Big Data

Referência	Conceitos
(GANTZ; REINSEL, 2011)	"[…] as tecnologias de Big Data descrevem uma nova geração de tecnologias e arquiteturas projetadas para extrair economicamente o valor de volumes muito grandes e uma variedade de dados, permitindo alta velocidade de captura, descoberta, e/ou análise."
(BOYD; CRAWFORD, 2012)	"Big Data é, em vários sentidos, um termo pobre." "Definimos big data como um fenômeno cultural, tecnológico e acadêmico." "Big Data é menos sobre dados qu
(GARTNER GROUP, 2012)	"Big Data são ativos de informações de grande volume, alta velocidade e / ou de alta variedade que exigem formas inovadoras e econômicas de processamento de informações que permitem uma melhor percepção, tomada de decisões e automação de processos."
(EUROPEAN COMMSION, 2013)	"Big Data se refere ao crescimento exponencial tanto da disponibilidade quanto no uso automatizado de informação: refere-se a conjuntos de dados digitais gigantescos detidos por empresas, governos e outras organizações de grande porte, que são amplamente analisados (daí o nome: analytics) usando algoritmos de computador. Big Data pode ser usado para identificar tendências mais gerais e correlações, mas também pode ser processado, de modo a afetar diretamente os indivíduos."
(MAYER-SCHÖNBERGER; CUKIER, 2013)	"Big Data refere-se a coisas que se podem fazer em grande escala, que não podem ser feitas em escala menor, de forma a extrair novas ideias ou criar novas formas de valor, de maneira que acabam mudando mercados, organizações, a relação entre cidadãos e os governos, dentre outros."
(TAURION, 2013)	"Big Data = volume + variedade + velocidade."
(CRAWFORD; SCHULTZ, 2014)	"Big Data é um termo generalizado e impreciso, que se refere ao uso de grandes conjuntos de dados na ciência de dados e análise preditiva."
(GEORGE et. al.2014)	"O Big data é formado por uma crescente pluralidade de fontes de informação, entre eles cliques na web, transações em dispositivos moveis, conteúdo gerado por usuários, mídias sociais, bem como conteúdo gerado intencionalmente através de redes de sensores ou transações comerciais, tais como consultas de vendas e transações de compra."
(IBM, 2014)	"Big Data é um termo utilizado para descrever grandes volumes de informações de dados e que ganha cada vez mais relevância à medida que a sociedade se depara com o aumento sem precedentes no número de informações."
(FRICKÉ (2015)	"Big Data não é incompatível com a experimentação. Mas é o amigo da observação passiva: encoraja a observação passiva. Realizar pesquisas e fazer observações é uma observação passiva." "Big Data deve ser capaz de nos fornecer melhores evidências para nossas teorias."
(AMARAL, 2016)	"Big Data é o fenômeno em que dados são produzidos em vários formatos e armazenados por uma grande quantidade de dispositivos e equipamentos."
(HIJMANS, 2016)	"A evolução da era big data implica, por sua própria natureza, em falta de controle, uma vez que o volume de dados é sem precedentes, diverso em variedade e movendo-se com uma velocidade que se aproxima cada vez mais do tempo real."
(ITSRio, 2016)	"[…] o conjunto de dados cuja existência só é possível em consequência da coleta massiva de dados que se tornou possível nos últimos anos, graças à onipresença de aparelhos e sensores na vida cotidiana e do número crescente de pessoas conectadas a tais tecnologias por meio de redes digitais e também de sensores."
(PROVOST; FAWCETT, 2016)	"[…] o termo big data significa conjunto de dados que são grandes demais para os sistemas tradicionais de processamento e, portanto, exigem novas tecnologias para processá-los"
(DAVENPORT, 2017)	"O big data é inegavelmente grande, mas o termo é um tanto ou quanto equivocado."
(MACHADO, 2018)	"Este grande volume de dados, esta explosão de dados gerados universalmente a cada instante, é chamado de Big Data, que está expondo uma nova onda de tecnologia e arquitetura destinada a extrair valor de uma imensa variedade de dados, o que permite alta velocidade com o objetivo de capturar, descobrir e analisar estas informações importantes e valiosas no âmbito de gestão de negócios."

Fonte: elaborado pelo autor com base em: (VOLPATO; RUFINO; DIAS, 2014; GOMES, 2017).

Vídeo da apresentação

Título: O termo Big Data: quebra de paradigma dos n-V's.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=6

Transcrição da apresentação

Olá essa é uma apresentação referente ao trabalho aprovado junto ao 2º Workshop de Informação Dados e Tecnologia – WIDAT, que nessa edição de 2018 acontece na Universidade Federal da Paraíba. É uma pesquisa realizada com contribuição dos pesquisadores Fernando Gomes Almeida da Universidade Federal de Minas Gerais, Renato Rocha Souza também da UFMG e da Fundação Getúlio Vargas do Rio de Janeiro e por mim Marcos de Souza da Universidade Federal de Minas Gerais. O título da pesquisa é "O TERMO BIG DATA: quebra de paradigma dos n-V's".

Trata-se de uma pesquisa de referencial teórico, mas como muita contribuição no que diz respeito especificamente dos conceitos e das características de um Big Data. Pois bem para a gente poder falar de Big Data a gente tem que falar de dados, uma matéria que saiu no ano de 2017 no "The Economist" diz que os dados são considerados um novo petróleo na era digital, possuindo um valor altamente estratégico, nessa matéria destacam por exemplo as organizações que detém os dados também detém todo o poder. Ainda mais falando na questão econômica, alguns exemplos, Apple, facebook, Google e a Microsoft tiveram um faturamento de 25 bilhões de dólares apenas no primeiro semestre de 2017. Quer dizer, no ano passado é um faturamento consideravelmente muito alto, empresas que trabalham com dados.

Toda essa questão de produção e armazenamento de dados tem passado por um processo evolutivo desde a popularização dos computadores e da difusão da internet, desta forma pegar destaque a partir de uma produção massiva de dados realizada, por exemplo, por sites, por redes sociais digitais, por smartphones, sistemas informatizados, satélites, sensores de carros, aviões e trens, câmeras de segurança entre outros tipos de serviços como, por exemplo, stream que é esse agora que vocês estão vendo neste momento.

Além da evolução referente à capacidade de armazenamento de dados a autora Rosângela Marquesone, ela destaca que faz necessário ressaltar a quantidade de vezes que esses mesmos dados são compartilhados pelos próprios usuários. Partindo deste princípio de dados a gente consegue chegar ao conceito de Big Data cunhado a partir do crescimento e integração do grande volume de dados digitais como esses excitados agora há pouco, por exemplos diversos meios de tecnologias bem como o uso de ferramentas que perpassa pela por algumas etapas sendo elas produção, compartilhamento, curadoria e análise de uma maneira eficiente nessa gigantesca quantidade de dados.

Como resultado nessas informações elas geram, por exemplo, padrões significativo de novos conhecimentos. A Gartner desenvolveu um estudo no ano de 2001 no qual apresentou três características de um Big Data, sendo elas volume, variedade e velocidade, conhecido na literatura como 3-v's, como um dos maiores desafios da manipulação e gestão de dados, esse viés tem sido discutido massivamente com muita relevância no meio acadêmico. Posteriormente surgiram mais dois v's que é a "veracidade" relacionada à qualidade e o "valor" relacionado à relevância, formando assim ou incorporando assim os 5 v's também na literatura, só que com a veracidade e com valor está voltado mais para um viés empresarial. Então essas cinco características, elas contribuem para uma definição de Big Data.

Justifica-se a importância desse trabalho pela notoriedade do termo de Big Data nos últimos anos, tanto no meio acadêmico quanto no meio empresarial e a discrepância no qual você encontra os conceitos na literatura, não existe uma homogeneidade de um conceito de Big Data e como hipótese acredita-se que por se tratar de um termo relativamente novo, principalmente por estar atrelado aos meios e avanços tecnológicos, pode surgir forma cotidianas novas características que contribuem com a diversidade desse conceito.

O objetivo dessa pesquisa está em identificar os conceitos relacionados ao termo Big Data e as características que compunham este conceito, então a definição de Big Data por exemplo por alguns autores é muito criticado, então por exemplo Boyd e Crawford falam que o tema Big Data é considerado muito pop, é equivocado e genérico por Davenport em um livro de 2017 recém-lançado. O conteúdo desse trabalho ele parte do princípio que Big Data é um termo em fase de amadurecimento e que ainda está em processo de consolidação do seu conceito.

Trata-se de uma pesquisa de natureza básica abordando o problema de forma qualitativa do ponto de vista dos seus objetivos a pesquisa se classifica como exploratória e descritiva, da perspectiva dos procedimentos técnicos identifica-se como pesquisa bibliográfica, lógico que estamos nos apoiando em nomes de autores como Gil por exemplo. A pesquisa consiste em um levantamento de análise e seleção de trabalhos que faz a conceituação de Big Data, bem como suas características publicadas entre o período de 2011 e 2018, esse período temporal nós encontramos diversos conceitos que de fato não existe uma homogeneidade do conceito em cima e sim uma discrepância, hoje apresentado no apêndice desta pesquisa.

Os trabalhos foram identificados através de pesquisas realizadas no portal de periódicos da CAPES, no Google Acadêmico além de livros que foram utilizados e artigos científicos, livros digitais, impressos na área de domínio de Big Data. As publicações selecionadas serviram como base para a identificação dos conceitos relacionados ao termo Big Data e com a identificação das características que compõem este conceito.

As características já encontrada massivamente na literatura, nós temos o volume, variedade, velocidade nos três v's, focado na área acadêmica a veracidade e valor voltado para o meio empresarial, entretanto essa pesquisa trouxe alguns resultados muito interessantes, por exemplo mais dois v's que a viabilidade e a venalidade. Além disso outro diferencial dessa pesquisa é que o termo que nós utilizamos para o título "n-v's" não foi encontrada na base de periódicos da CAPES, algumas variações mesmo assim foram zero resultados encontrados.

Do conceito de Big Data, a gente pode falar que é um fenômeno tecnológico e humano no qual são formados dados em diversos formatos que são armazenadas em grande quantidade de dados em dispositivos de armazenamento, refere-se assim as características inerentes de Big Data os n-v's, em que a literatura hoje fala em 5-v's, nós já estamos identificando sete e possam surgir novos v's, novas características que serão apresentados.

Desses novos 2-v's nós vamos destacar aqui a "viabilidade" que destina-se a investigar um relacionamento entre as variáveis e padrões latente de dados, é uma citação de Biehn de 2013, o que seria isso é padrões latentes de dados na viabilidade pode ser utilizado, por exemplo, há um conceito de modelagem de tópicos, faz uso de machine learning, por exemplo, em cima de processamento de linguagem natural, por exemplo eu tenho grandes corpora de dados e aí eu

quero identificar a viabilidade por exemplo da imersão desses tópicos, qual é a freqüência desses tópicos, a relação desses tópicos, em cima de um grande Big Data? Então eu trato com relação a isso essa parte latente que é de viabilidade.

Davenport em 2017 a questão da legalidade, projeção futuramente de formatos de Big Data que possam ser vendidos. A gente pode falar assim: ah mas hoje dados são vendidos, por exemplo se eu adquirir um número novo de uma linha telefônica no outro dia já tem alguém oferecendo algum determinado tipo de produto, a venda de fato realmente acontece, mas o que Davenport trabalha, que ele está pleiteando futuramente ou almejando é a questão de um formato de venda de dados.

Considerações finais o termo Big Data comparado a outros conceitos científicos já consolidados na literatura apresenta uma diversidade de conceitos e contribui para uma não consolidação do termo, este fato pode ser observado junto da pesquisa certamente terão acesso aos anais, no apêndice dela nós construímos uma linha temporal de 2011 até 2018 onde vocês poderão observar, por exemplo, uma não uniformidade entre as definições elaboradas pelos autores, inclusive com críticas, com disparidade de conceito e a não homogeneidade das características do conceito.

Essa evolução de características de palavras iniciadas com a letra "v" tem acontecido mediante o surgimento de novas necessidades que aparece para realizar o processamento do Big Data, também por conta dos avanços tecnológicos, isso que as tecnologias estejam longe de serem estabilizadas e com isso novas possibilidades de novas "v's" poderão surgir nos próximos anos, como por exemplo a variabilidade que diz respeito à capacidade de submeter-se a variações mudança e a própria visualização de dados que já existem mas que pode ser conceituada, associada a um Big Data, então a gente está falando e 9-v's, n-v's de acordo com as necessidades de processamento e avanços tecnológicos vão surgir "n" características para tentar formar um conceito sólido de Big Data.

Sugere-se como pesquisas futuras, quebra de paradigmas com a caracterização real do termo. Por fim só mais 2-v's que são apresentados potencializando mais 2-v's chegando assim a 9-v's, para poder caracterizar Big Data, são características que acabam sendo descaracterizados, não sei, seria uma questão mais de discussão. Fica a mesma dica para pesquisas futuras, tenhamos de fato um conceito real, quanto tempo isso vai levar eu não sei responder, mas de toda forma nós agradecemos a contribuição realizada para o evento e todas as críticas, sugestões vocês podem entrar em contato conosco.

Obrigado.

O ensino da e-Science no âmbito dos Programas Brasileiros de Pós-Graduação em Ciência da Informação

Renata Lemos dos Anjos[a] *e Débora Gomes de Araújo*[b]

Resumo: O constante avanço das Tecnologias Digitais de Informação e Comunicação provocou mudanças no cenário científico, alterando o modo de pensar e fazer ciência. O quarto paradigma da ciência, denominado como e-Science, pode ser definido de forma resumida como uma ciência amplamente orientada a dados oriundos de investigações científicas. Esta realidade mostra ser um amplo campo de atuação para os profissionais da Ciência da Informação. A partir de uma pesquisa exploratória e documental, com análise quantitativa e qualitativa, investigamos se as disciplinas componentes das grades curriculares dos Programas de Pós-Graduação em Ciência da Informação, avaliados e reconhecidos pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, abordam sobre a ampla realidade da e-Science, suas variações e práticas. Diante dos resultados obtidos com a pesquisa, obtivemos que dentre os vinte e três Programas de Pós-Graduação na área da Ciência da Informação, onze, representando 47,82% dos programas oferecem disciplinas que versam sobre o fenômeno da e-Science, suas relações, suas variações e suas práticas. Percebeu-se que os Programas de Pós – Graduação em Ciência da Informação, analisados estão se adequando, bem como, apresentando cursos pioneiros nesta realidade da e-Science, como o curso de mestrado profissional em Gestão de Dados de Pesquisa oferecido pela Universidade Federal do Estado do Rio de Janeiro.

Palavras-chave: e-Science. Ciência da Informação. Pós-Graduação em Ciência da Informação.

The teaching of e-Science in the context of Brazilian graduate programs in information science

Abstract: The constant advance of the Digital Information and Communication Technologies caused changes in the scientific scene, transforming the way of thinking and doing science. The fourth paradigm of science, called e-Science, can be briefly defined as a science largely geared to data from scientific research. This reality shows to be a broad field of action for the Information Science Professionals. From an exploratory and documentary research, with quantitative and qualitative analysis, we investigated whether the disciplines that are part of the curricula of the Graduate Programs in Information Science evaluated and recognized by the Coordination of Improvement of Higher Education Personnel, are within the reality of e-Science, its variations and practices. Considering the results obtained with the research, we found that among the twenty-three Graduate Programs in the area of Information Science, eleven, representing 47.82% of the programs offer subjects that deal with the phenomenon of e-Science, its relations, its variations and its practices. It was noticed that the Graduate Programs in Information Science analyzed are adequate, as well as presenting pioneering courses in the context of e-Science, such as the professional master's degree in Data Management Research offered by the Federal University of the Rio de Janeiro state.

Keyword: e-Science. Information Science. Graduates studies in Information Science.

a Universidade Federal da Paraíba (UFPB). E-mail: renatalemosdosanjos@gmail.com. ORCID: https://orcid.org/0000-0002-4599-3494. Currículo: http://lattes.cnpq.br/8287662863078416

b Universidade Federal da Paraiba (UFPB). E-mail: debora.g.de.araujo@gmail.com. ORCID: https://orcid.org/0000-0003-2283-0833. Currículo: http://lattes.cnpq.br/5802239149965368

1 Introdução

O constante avanço das Tecnologias Digitais de Informação e Comunicação – TDIC provocou mudanças no modo de pensar e fazer ciência, causando rupturas e alterações de paradigmas seguidos em todo o domínio do fazer científico. Shuttleworth (2008, online, tradução nossa) afirma que "uma mudança de paradigma não é uma ameaça à ciência, mas sim a própria maneira pela qual ela progride[23]". Desta forma, paralelamente ao desenvolver da tecnologia, o modo de pensar e fazer ciência foi sofrendo alterações, até que estes momentos de rupturas foram tidos como paradigmas da ciência, configurando-se como uma evolução da mesma.

De acordo com Gray (2007), os paradigmas da ciência correspondem a fases, momentos do empreendimento científico e notoriamente às fases da sociedade de uma maneira geral. Inicialmente, há mil anos, o primeiro paradigma da ciência, nomeado como "Ciência Experimental" (HEY et al., 2009), a ciência acontecia de forma exclusivamente experimental, empírica, por meio da observação e descrição das leis naturais.

No que concerne ao segundo paradigma da ciência, o da "Ciência Teórica", por volta do século XVII, ela passa a basear-se em modelos teóricos, como as Leis de Kepler, Leis de Newton, Equações de Maxwell, assumindo um ramo teórico (GRAY, 2007; HEY et al., 2009).

Mais recentemente, na segunda metade do século XX, esses modelos teóricos tornaram-se complicados em sua resolução, dando início a simulações e ao uso de recursos computacionais, reconhecido como o terceiro paradigma da ciência, a "Ciência Computacional" (HEY et al., 2009). Esta abordagem faz uso da computação tanto para a simulação de fenômenos complexos, quanto para solucionar equações demandavam um árduo trabalho pesquisadores anterior ao uso computadores (GRAY, 2007).

Em seu terceiro paradigma, a ciência passou a produzir uma quantidade massiva de dados, por meio do uso intensivo da infraestrutura computacional disponível, progredindo para o mais atual paradigma da ciência, o quarto paradigma.

No quarto paradigma da ciência, esses dados passam a ser explorados e considerados "produtos valiosos do empreendimento científico[24]" (STRASSER et al, 2012, p. 2, tradução nossa). Desta forma passam a ser considerados como dados científicos primários que acabam por serem utilizados como matéria-prima para futuras investigações científicas. Com base nesta realidade, Tenopir (2011, p. 1, tradução nossa) afirma que "seguindo os paradigmas de investigações anteriores, esta nova era tem sido chamada de 'o quarto paradigma: descoberta científica do uso intensivo dos dados[25]'", também definido como e-Science.

A e-Science pode ser definida de forma resumida por Gray (2005, apud Sales et al., 2013) como uma "ciência produzida a partir do uso, processamento, análise e compartilhamento de dados de pesquisa". Ou seja, uma ciência amplamente cumprida e realizada nas bases do quarto paradigma científico, o qual valoriza abundantemente os dados oriundos de investigações científicas.

23 A paradigm shift is not a threat to science, but rather the very manner in which it progresses.
24 Research data are valuable products of the scientific enterprise (…).
25 Following the previous research paradigms, this new era has been called "the fourth paradigm: data-intensive scientific discovery.

Nesta perspectiva, percebe-se que a e-Science configura-se por ser uma ciência baseada sob a construção de uma infraestrutura informática computacional de uso distribuído, a qual permite e incentiva a colaboração à distância entre os pares, entre equipes de pesquisa, envolvendo a todo instante o uso intensivo e o constante compartilhamento de dados e recursos computacionais (ALBAGLI et al., 2013).

Desta forma, a Ciência da Informação depara-se com o fenômeno da e-Science, para com o qual, pode e deve contribuir para que se desenvolva da melhor maneira. Ao identificar e estudar fatores e características que vão propiciar o equilíbrio entre os atores envolvidos no processo e a máxima otimização do uso e reúso dos dados (SANT'ANA, 2016), além de revelar-se como um amplo campo de atuação para os profissionais da informação.

Diante da perspectiva de que, está diretamente associado aos processos de coleta, curadoria, processamento, armazenamento, análise e visualização dos dados, e que as tendências das pesquisas na CI, neste contexto, versam sobre a "proveniência, as melhores práticas, o planejamento, a curadoria entre outras atividades científicas relacionadas à teoria e à práxis com dados de pesquisa" (SEMELER, 2017, p. 137). Percebe-se deste modo, que a CI está amplamente inserida no âmbito do quarto paradigma científico, tanto em questões de investigações científicas, quando na atuação dos profissionais da informação.

Neste contexto, com base no fenômeno emergente da e-Science, indagamos se a realidade da e-Science é abordada nos componentes curriculares dos Programas de Pós-Graduação em Ciência da Informação, avaliados e reconhecidos pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)?

2 Objetivo

A pesquisa em tela busca desvendar o ensino da e-Science no âmbito dos programas brasileiros de Pós-Graduação em Ciência da Informação, avaliados e reconhecidos pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

3 Procedimentos Metodológicos

O presente estudo caracteriza-se como uma pesquisa exploratória e documental, com análise quantitativa e qualitativa.

Inicialmente, foram identificados vinte e três Programas de Pós-Graduação em Ciência da Informação, avaliados e reconhecidos pela CAPES na Plataforma Sucupira, bem como, os programas que ofereciam cursos em nível de mestrado acadêmico, mestrado profissional, e doutorado. Ressalta-se que foram contabilizados os programas indexados pela CAPES na área de avaliação "Comunicação e Informação" e posteriormente aqueles da área do conhecimento "Ciência da Informação", totalizando em vinte e três programas.

Após a identificação dos Programas de Pós-Graduação em Ciência da Informação, partimos para uma visita aos sites/portais buscando as disciplinas, obrigatórias e optativas, componentes curriculares de cada programa. Ressaltamos que ao não encontrarmos as grades curriculares dos programas, buscamos pela oferta de disciplinas relativas aos semestres 2018.1 e 2018.2, e também na própria plataforma Sucupira, na qual os programas devem informar à plataforma as disciplinas que são oferecidas.

Ao dar seguimento a pesquisa, percebeu-se que algumas das disciplinas identificadas abordam temas ligados a e-Science, tais como, big data, humanidades digitais (digital humanities), tratamento de dados em geral, bem como, Data Science, uma outra nomenclatura para um fenômeno que pode estar classificado no contexto investigado, as quais foram contabilizadas para esta pesquisa.

Ressalta-se que, também foram avaliadas as ementas das disciplinas, quando disponíveis, em virtude de identificação de relações com o tema proposto.

Contabilizamos que dentre os vinte e três Programas de Pós-Graduação em Ciência da Informação identificados, onze dispõem em suas componentes curriculares de disciplinas que versam e preparam seu corpo discente para a realidade do quarto paradigma científico.

4 Resultados

Após realizada a busca pelos componentes curriculares em cada site/portal dos programas selecionados, e também na Plataforma Sucupira, obtivemos que onze programas oferecem disciplinas com conteúdos aderentes ao contexto da e-Science. O Quadro 1 apresenta estas disciplinas.

Com base no exposto, verificou-se que aproximadamente 47,82% (onze) dos programas dispõem de disciplinas que versam sobre a realidade da e-Science, suas relações e variações.

O Programa de Pós-Graduação em Ciência da Informação da Universidade Estadual de São Paulo (PPGCI/UNESP), foi identificado como o programa mais atualizado em questões que permeiam a e-Science. Oferecendo tanto disciplinas teóricas quanto disciplinas práticas sobre essa realidade.

Após o PPGCI/UNESP, obtivemos uma situação de equivalência entre os Programas de Pós-Graduação em Ciência da Informação da Universidade Federal de Santa Catarina (PPGCI/UFSC), e o da Universidade Federal da Paraíba (PPGCI/UFPB) os quais oferecem três disciplinas nesta seara, ambientando seus discentes no contexto da e-Science. O PPGCI/UFSC, aborda a e-Science de uma forma geral por meio de três disciplinas que versam sobre temas que relacionam-se com a mesma, conforme apresentado no Quaro 1.

No que tange ao PPGCI/UFPB, identificamos que o mesmo oferece disciplinas que versam sobre o Big Data e a Sociedade da Informação – relacionados com a e-Science; além de também oferecer uma disciplina que aborda o fenômeno da e-Science no âmbito da CI; e uma outra que trata sobre a gestão dos dados científicos, revelando a afinidade entre o quarto paradigma científico e a CI.

Obtivemos uma outra situação de equivalência entre o Programas de Pós-Graduação em Gestão & Organização do Conhecimento da Universidade Federal de Minas Gerais (PPGGOC/UFMG) e o Programa de Pós-Graduação em Ciência da Informação da Universidade de Brasília (PPGCI/UNB), os quais oferecem duas disciplinas nesta vertente conforme mostrado no Quadro 1. O PPGGOC/UFMG, oferece disciplinas de cunho aplicado, como o uso dos metadados para descrição acurada dos conjuntos de dados provenientes das pesquisas, como também, práticas de mineração e modelagem de dados utilizadas no tratamento dos dados científicos. E o PPGCI/UNB oferece duas disciplinas na vertente da e-Science, sendo por muitos definida como a Ciência de dados, por ser toda orientada a dados.

A Escola de Comunicações e Artes da Universidade de São Paulo, oferece a Pós-Graduação em Ciência da Informação (PPGCI/ECA-USP), a qual oferece a disciplina "Humanidades Digitais" que refere-se a uma área de pesquisa e ensino que versa sobre a intersecção das tecnologias para com as ciências humanas, baseando-se nas práticas de mineração de dados, recuperação da informação, e visualização digital dos produtos gerados pelas ciências, o que a e-Science também orienta (SEGUNDO, 2015).

Quadro 1: A e-Science nos Programas de Pós-Graduação em Ciência da Informação. PROGRAMA DISCIPLINAS

Programa	Disciplinas
PPGCI – UNESP	– A Ciência da Informação e o ciclo de vida dos dados: fronteiras de pesquisa; - Aspectos tecnológicos de acesso a dados abertos para Ciência da Informação; - Conceitos e tecnologias para publicação de dados abertos e semânticos seguindo as melhores práticas do Linked Data; - Design da informação e curadoria digital; - Fundamentos tecnológicos de representação de dados e informações; - Web semântica: conceitos e tecnologias. – A Ciência da Informação e o ciclo de vida dos dados: fronteiras de pesquisa; - Aspectos tecnológicos de acesso a dados abertos para Ciência da Informação; - Conceitos e tecnologias para publicação de dados abertos e semânticos seguindo as melhores práticas do Linked Data; - Design da informação e curadoria digital; - Fundamentos tecnológicos de representação de dados e informações; - Web semântica: conceitos e tecnologias. – A Ciência da Informação e o ciclo de vida dos dados: fronteiras de pesquisa; - Aspectos tecnológicos de acesso a dados abertos para Ciência da Informação; - Conceitos e tecnologias para publicação de dados abertos e semânticos seguindo as melhores práticas do Linked Data; - Design da informação e curadoria digital; - Fundamentos tecnológicos de representação de dados e informações; - Web semântica: conceitos e tecnologias.
PPGCIN – UFSC	– Big Data e Web Semântica. - Humanidades digitais e Ciência da Informação; - Tendências tecnológicas aplicadas a dados. – Big Data e Web Semântica. - Humanidades digitais e Ciência da Informação; - Tendências tecnológicas aplicadas a dados.
PPGCI – UFPB	– Big Data e a Sociedade da Informação; - e-Science no âmbito da Ciência da Informação; - Gestão de Dados Científicos na Perspectiva da e-Science. – Big Data e a Sociedade da Informação; - e-Science no âmbito da Ciência da Informação; - Gestão de Dados Científicos na Perspectiva da e-Science.
PPGGOC – UFMG	– Metadado: formatos e modelos; - Mineração e modelagem de dados.
PPGCINF – UNB	– Ciência de dados aplicada a curadoria de dados científicos; - Ciência de dados aplicada – modelos de análise.
PPGCI – ECA/USP	– Humanidades digitais.
PPGCI – UEL	– A mineração de dados aplicada à pesquisa social.
PPGCI – UFPE	– Curadoria digital.
PPGCI – UFSCar	– Representação e metadados em ambientes digitais.
PPGCI – UFF	– Acesso aberto à informação científica
PPGB – UNIRIO	– Gestão de dados de pesquisa (MP).

Fonte: Dados da Pesquisa, 2018.

Já o Programa de Pós-Graduação em Ciência da Informação da Universidade de Londrina (PPGCI/UEL), oferece a disciplina "Mineração de dados aplicada à pesquisa social"

apresentando-se como uma disciplina que capacita os profissionais da informação no trabalho da mineração de dados, tão utilizado neste momento do quarto paradigma científico.

O Programa de Pós-Graduação em Ciência da Informação da Universidade Federal de Pernambuco (PPGCI/UFPE), oferece a disciplina de Curadoria Digital a qual versa sobre determinados subtemas: ciclos de curadoria digital; preservação da informação em ambientes digitais; metadados de preservação digital; modelos e estratégias de preservação digital; gestão de riscos em preservação digital; e-Science. Desta forma, além de abordar de forma geral a prática da curadoria digital, que "são procedimentos práticos e teóricos" (SAYÃO; SALES, 2016, p. 68), também versa sobre a realidade da e-Science.

A Universidade Federal de São Carlos em seu Programa de Pós-Graduação em Ciência da Informação (PPGCI/UFSCar), oferece uma disciplina prática de representação e metadados em ambientes digitais, a qual pode ser utilizada no contexto da e-Science.

No Rio de Janeiro, a Universidade Federal Fluminense, oferece o Programa de Pós-Graduação em Ciência da Informação (PPGCI/UFF), que versa sobre uma das vertentes da e-Science, que é o acesso aberto a informações/dados científicos, uma prática amplamente incentivada em tempos do quarto paradigma científico.

Ainda no Rio de Janeiro, e apresentando novidades na área, a Universidade Federal do Estado do Rio de Janeiro (UNIRIO), lançou recentemente, o edital de seleção para um mestrado profissional, o qual terá como temática "Gestão de Dados de Pesquisa[26]", tornando-se uma iniciativa pioneira no oferecimento de curso em pós-graduação que aborda amplamente as práticas incentivadas pela e-Science, por meio das três disciplinas, que foram divulgadas até o momento.

A disciplina aspectos contemporâneos da comunicação científica, versará sobre o movimento do acesso aberto, ciência aberta, dados abertos, inovações na comunicação científica, entre outros temas, os quais estão diretamente relacionados à realidade da e-Science.

Uma outra disciplina é a de inovação aberta e ciência aberta, que discorrerá sobre as definições e conceitos de invenção, design, pesquisa, desenvolvimento tecnológico e inovação; sobre as dimensões da inovação tecnológica, humana, econômica, organizacional, social e outras; inovação aberta: conceito, métodos e práticas; apresentará a relação entre inovação aberta e ciência aberta; gestão, plataformas abertas e ecossistema de inovação.

Por fim, a disciplina gestão de dados de pesquisa, a qual abordará os plano de gestão de dados; os benefícios e desafios no compartilhamento dos dados; as práticas de citação dos dados, de proteção e confidencialidade dos dados; sobre propriedade intelectual, autenticidade e integridade dos dados; curadoria de dados e boas práticas como armazenamento, backup, segurança, arquivamento e preservação dos dados; também abordará os princípios FAIR e como executá-los por meio da estrutura GOFAIR, além do papel e responsabilidade dos bibliotecários na gestão de dados de pesquisa. Estando expressamente relacionada à realidade e emergência do quarto paradigma científico.

26 http://www.unirio.br/ppgb/arquivo/editais-de-selecao/edital-tematico-2018-gestao-de-dados-de-pesquisa

4 Conclusão ou Considerações Finais

Ressalta-se que o PPGCI/UNESP foi identificado como o programa que mais adequa-se a esta realidade. Também verificou-se indícios de que tanto a CI quanto os profissionais da informação relacionam-se diretamente com a e-Science, ciência dos dados. Nesta perspectiva, a UNIRIO abriu seleção para um novo curso de pós-graduação, o mestrado profissional em Gestão de Dados de Pesquisa. O que nos possibilita observar que os programas estão se atualizando no que concerne a oferta de disciplinas, e começam a ter iniciativas pioneiras nesta realidade do quarto paradigma científico.

Referências

ALBAGLI, S. *et al.* Ciência Aberta: correntes interpretativas e tipos de ação. **Liinc em Revista**, v. 10, n. 2, p. 434 – 450, 2014. Disponível em: <http://revista.ibict.br/liinc/article/view/3593 >. Acesso em: 24 set. 2018.

GRAY, J. **eScience**: a transformed scientific method. Palestra apresentada no Conselho Nacional de Pesquisa dos Estados Unidos (NRC-CSTB). Mountain View, Califórnia, 2007.

HEY, T. *et al.* **The fourth paradigm: data-intensive scientific discovery**. Redmond, WA: Microsoft Research, 2009.

SALES, L. F. *et al.* Publicações ampliadas: um novo modelo de publicação acadêmica para o ambiente de e-Science. In: XIV Encontro Nacional de Pesquisa em Ciência da Informação, 2013, Florianópolis. **Anais...** Florianópolis: XIV ENANCIB, 2013. Disponível em: <http://eprints.rclis.org/20666/1/APRESENTAÇÃO%20-%20ENANCIB%202013.pdf>. Acesso em: 24 set. 2018.

SANT'ANA, R. C. G. Ciclo de vida dos dados: uma perspectiva a partir da ciência da informação. **Informação & Informação**, v. 21, n. 2, p. 116–142, dez. 2016. Disponível em: <http://www.uel.br/revistas/uel/index.php/informacao/article/view/27940/20124>. Acesso em: 31 jul. 2018.

SAYÃO, L. F.; SALES, L. F. Curadoria digital e dados de pesquisa. **AtoZ**: novas práticas em informação e conhecimento, v. 5, n. 2, p. 67-71, dez. 2016. ISSN 2237-826X. Disponível em: <https://revistas.ufpr.br/atoz/article/view/49708/30179>. Acesso em: 25 set. 2018.

SEGUNDO, J. E. S. Web semântica, dados ligados e dados abertos: uma visão dos desafios do Brasil frente às iniciativas internacionais. **Encontro Nacional de Pesquisa em Ciência da Informação**, v. 16, 2015. Disponível em: <http://www.brapci.inf.br/index.php/article/download/43838>. Acesso em: 25 set. 2018.

SEMELER, A. R. **Ciência da informação em contextos de e-science**: bibliotecários de dados em tempos de Data Science. 2017. 164f. Tese (Doutorado) - Programa de Pós-Graduação em Ciência da Informação, Universidade Federal de Santa Catarina, Florianópolis, 2017. Disponível em: <https://repositorio.ufsc.br/handle/123456789/185593>. Acesso em: 26 set. 2018.

SHUTTLEWORTH, M. What Is a Paradigm? **Philosophy of Science, Explorabe.com**, Oct. 24, 2008. Disponível em: <https://explorable.com/what-is-a-paradigm>. Acesso em: 26 set. 2018.

STRASSER, C. *et al.* **Primer on data management**: what you always wanted to know. 2012. Disponível em: <https://www.dataone.org/sites/all/documents/DataONE_BP_Primer_020212.pdf>. Acesso em: 27 set. 2018.

TENOPIR, C. *et al.* Data Sharing by Scientists: Practices and Perceptions. **Plos One**, v. 6, n.6, p. 1-21, 2011. Disponível em: <http://journals.plos.org/plosone/articleid=10.1371/journal.pone.0021101>. Acesso em: 27 jul. 2018.

Vídeo da apresentação

Título: O ensino da E-Science no âmbito dos Programas Brasileiros de Pós-Graduação em Ciência da Informação.

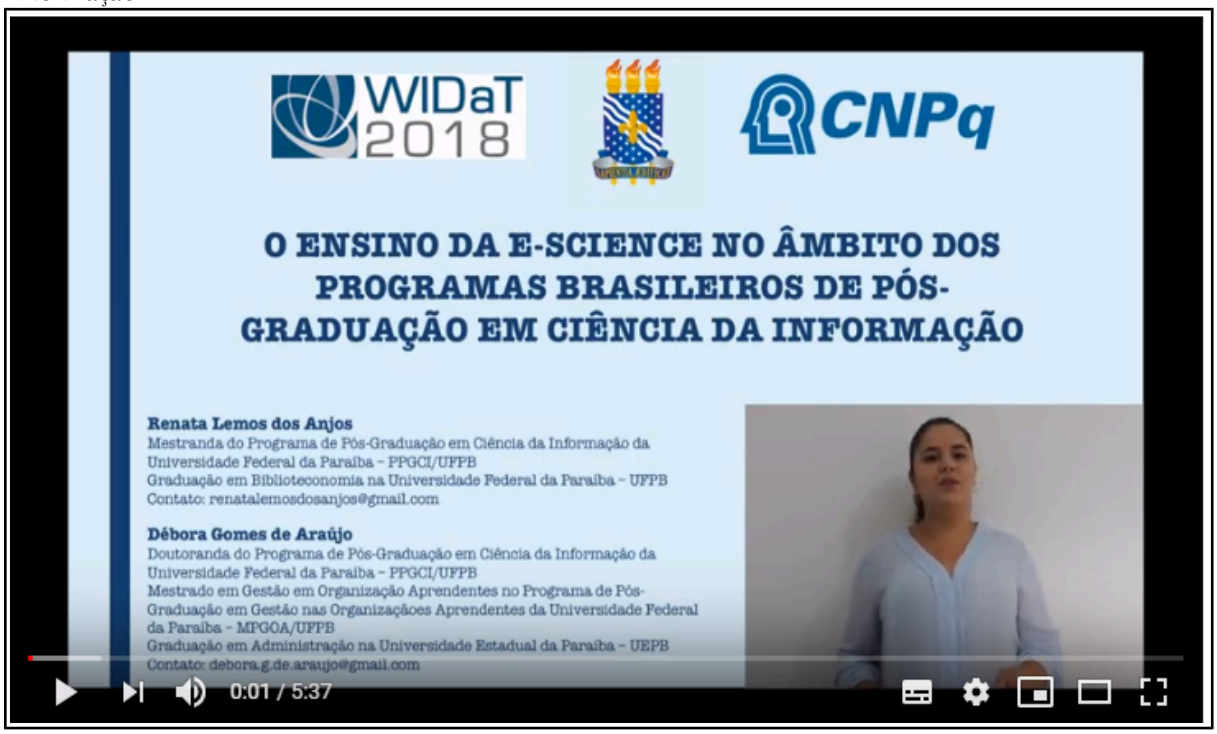

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=7

Transcrição da apresentação

Olá participantes do WIDAT 2018. Eu vou apresentar agora o artigo intitulado "O ensino da e-Science no âmbito dos Programas Brasileiros de Pós-Graduação em Ciência da Informação", realizado por mim Renata Lemos, atualmente mestranda do Programa de Pós-graduação em Ciência da Informação da Universidade Federal da Paraíba e Débora Gomes de Araújo, doutoranda também do mesmo programa.

Inicialmente nós sabemos que o constante avanço das tecnologias digitais de informação e comunicação vêm provocando mudanças no modo de pensar e fazer a ciência, causando alterações de paradigmas seguidos em todo o domínio do fazer científico.

Esses momentos de ruptura foram tidos como paradigma da ciência configurando-se também como a evolução da mesma, ou seja, uma mudança de paradigma não é uma ameaça à ciência mas sim a própria maneira pela qual ela progride.

Então inicialmente a mil anos atrás nós tínhamos a ciência experimental, onde a ciência acontecida de forma exclusivamente experimental e empírica por meio da observação e descrição das leis naturais. Posteriormente por volta do século 17 nós tivemos a ciência teórica onde a ciência passa a basear-se em modelos teóricos como por exemplo as Leis de Newton, Equações de Maxwell, assumindo no ramo mais teórico. Depois essas teorias é causavam enormes equações matemáticas fazendo necessário o uso de computadores, que é quando a gente passa para a ciência computacional na segunda metade do século 20 onde aqueles modelos teóricos tornaram-se resoluções complicadas dando início a simulações e uso de recursos computacionais, todos esses recursos computacionais, todo esse uso intensivo do computador foram gerando cada vez mais dados que é a ciência atual quarto paradigma científico que é o e-Science, ou seja, que segue os paradigmas de investigação anteriores esta nova área tem sido chamada de um quarto paradigma, descoberta científica do uso intensivo dos dados.

Então dessa forma a ciência da informação está diretamente associada ao quarto paradigma científico, com a informação é nada mais do que um dado dotado de sentido capazes de lidar com a informação que a gente tem capacidade de lidar com dado. Então a ciência da informação participaria dos processos de coleta, curadoria, processamento, armazenamento, análise e visualização dos dados de modo que a ciência da informação está amplamente inserida no âmbito do quarto paradigma científico tanto em caixões de investigações científicas quanto também da atuação do profissional da informação.

Nessa perspectiva nós buscamos investigar se a realidade da e-Science é abordada nos componentes curriculares dos programas de pós-graduação em ciência da Informação, avaliados e reconhecidos pela CAPES. Objetivou também desvendar o ensino da e-Science no âmbito dos programas brasileiros de Pós-graduação em Ciência da Informação, avaliados e reconhecidos pela CAPES.

A pesquisa caracteriza-se como pesquisa exploratória e documental com análise quantitativa e qualitativa. Inicialmente nós acessamos a plataforma Sucupira, fomos nos programas indexados na área de avaliação de "comunicação e informação" e posteriormente na área de "ciência da informação" que totalizou em 23 programas. Após a identificação dos 23 programas nós fomos nos sites e portais de cada um deles buscando as disciplinas obrigatórias, optativas que são

componentes curriculares de cada um dos programas. Depois dessas visitas percebeu-se que algumas das disciplinas versavam sobre temas que estão ali é circulando que tenha a ver que estão ligados com a e-Science, com o quarto paradigma científico, e que também contabilizamos para o efeito da pesquisa.

Foram contabilizados que dentre os 23 programas de pós-graduação em Ciência da Informação, inicialmente identificados, 11 dispõem os componentes curriculares disciplinas que versam e preparam o seu corpo discente para a realidade do quarto paradigma científico.

Programa de Pós-graduação em Ciência da Informação da UNESP, foi o programa que mais se mostrou adequado a essa realidade oferecendo seis disciplinas do eixo vertente, depois nós tivemos o Programa de Pós-graduação em Ciência da Informação da Universidade Federal de Santa Catarina e o da UFPB que disponibilizam três disciplinas que versam sobre essas vertentes, depois nós tivemos a Universidade de Minas Gerais e a Universidade de Brasília que também têm disciplinas que versam sobre essas vertentes e posteriormente a Universidade de São Paulo, Universidade Estadual de Londrina, Universidade Federal do Pernambuco, Universidade Federal de São Carlos, Universidade Federal Fluminense e a UNIRIO, também disponibilizam disciplinas sobre a vertente que tenha a ver, que estão ligados ao quarto paradigma científico.

Ressalta-se que a UNIRIO recentemente lançou o edital de um mestrado profissionalizante em gestão de dados de pesquisa.

Nós podemos concluir que o PPGCI da UNESP, ele foi identificado como um programa que mais adequa-se a essa realidade e que a UNIRIO abriu seleção para o novo curso de pós-graduação que é a Gestão de Dados de Pesquisa, o que possibilitou observar que os programas estão cada vez mais se atualizando no que concede à oferta de disciplinas e começam a ter iniciativas pioneiras, como este da UNIRIO, na realidade do quadro paradigma científico.

Agradeço a visualização de todos e qualquer contato para dúvidas, esclarecimentos, podem entrar em contato pelos dois e-mails abaixo.

Obrigada.

Narrativas de visualizações guiadas por dados: Big Data e inovação

Adriana Alves Rodrigues[a]

Resumo: Analisa as narrativas de visualização de dados do prêmio Data Journalism Awards 2018, bem como seus processos de inovação a partir do cenário de Big Data. A metodologia, de caráter exploratório, compreende um Estudo de Caso e discussão teórico-conceituais e empíricas dessas narrativas e suas dimensões no uso de dados a partir de revisão de literatura e aplicação de Ficha de Observação na coleta de dados e análise quali-quantitativa. Os resultados, que fazem parte de uma pesquisa maior em andamento na tese doutoral, demonstram que as narrativas guiadas por dados se constituem em uma forma diferenciada de contar histórias no jornalismo em interface interdisciplinar com a Computação, Design e Ciência da Informação. Conclui-se que a emergência do Big Data e da Visualização de Dados aponta para novo formato de narrativa em que os dados exercem função central.

Palavras-chave: Visualização de dados. Narrativas. Dados. Big Data.

Data-driven visualizations narratives: Big Data and innovation

Abstract: This paper presents an analysis of data visualization narratives from the 2018 Data Journalism Awards, as well as their innovation processes from the Big Data scenario. The exploratory methodology comprises a case-study and theoretical-conceptual and empirical discussion of these narratives and their dimensions in the use of data from a literature review and the application of an observation sheet in the data collection and qualitative-quantitative analysis. The results, which are part of a larger research project underway in the doctoral thesis, show that data-driven narratives constitute a new way of telling stories in journalism in an interdisciplinary interface with Computing, Design and Information Science. The research finds out that the emergence of Big Data and Data Visualization points to a new narrative format in which the data play a central role.

Keyword: Data Visualization. Narratives. Data. Big Data.

a Universidade Federal da Paraíba (UFPB). E-mail: adrianacontemporanea@gmail.com. ORCID: https://orcid.org/0000-0003-2378-6934. Currículo: http://lattes.cnpq.br/7244223683025080

1 Introdução

Em um contexto permeado por grandes volumes de dados, identificados pelo conceito de Big Data, as produções de visualizações de dados incorporaram novas linguagens e formatos, tendo como desdobramento a emergência de um novo fenômeno de natureza interdisciplinar. Para Lagoze (2014), o fenômeno do Big Data não se restringe a grandes volumes de dados, mas sim, a resultado da mescla de dimensões e características diferenciadas cujos efeitos podem ser revolucionários na produção de conhecimento. Neste sentido, a visualização de dados é uma área que cada vez mais ganha espaço nos debates profissionais e acadêmicos nos mais distintos campos do saber. Para além dos fatores tecnológicos que estão presentes, muitas das visualizações de dados se pautavam, até então, a apenas "mostrar os dados" (TUFTE, 2001), ou seja, eram produções que se limitavam em explorar aqueles dados por si só. No entanto, a agregação de novas tecnologias e estratégias de estruturação de dados e, principalmente, do Big Data, alguns trabalhos vêm apontando como aspecto inovador o fato desses dados conterem elementos de uma narrativa (SEGEL; HEER, 2010; CAIRO, 2011; VIÉGAS, 2013; KOSARA; MACKINLAY, 2013; FIGUEIRAS, 2013) e níveis de complexidade (com os cruzamentos de dados e volume) e deste modo se apresentarem de uma forma mais dinâmica. Viégas (2013) afirma que as visualizações têm a capacidade de captura de um determinado fato da realidade com profundidade através dos aspectos gráficos e diferentes cruzamentos de dados. Essa exploração do formato de visualização de dados tem ocorrido no campo científico e em organizações jornalísticas como The New York Times (EUA), The Guardian (Reino Unido), El País (Espanha), Estadão (Brasil), entre outros.

Em uma investigação com um conjunto de visualizações, Segel e Heer (2010) definiram alguns aspectos que podem subsidiar na composição de narrativa com dados, como por exemplo, apresentação de slides em movimento e histórias com detalhamento, isto é, com profundidade informativa, cujo foco maior, foi equilibrar os dados com os aspectos interativos. Neste contexto de narrativas e propriedades de dados em sua construção, a investigação de Nora Paul (2012) estabelece tipologias para as narrativas digitais, a saber: 1) Mídia: suporte da narrativa que combina recursos digitais como texto, fotos, gráficos, animação); 2) Ação: refere-se a dois aspectos distintos das narrativas digitais: o movimento do próprio conteúdo e a ação requerida pelo usuário para acessar o conteúdo; 3) Relacionamento: está ligado ao relacionamento entre o usuário do conteúdo e o próprio conteúdo. 4) Contexto: Capacidade de ofertar dados extras, remetendo a outros materiais, a exemplo dos links. e 5) Comunicação: Capacidade de conectar com outros tipos de mídias.

A pesquisa partiu da questão: Como as narrativas guiadas por dados endereçam formatos inovadores para a visualização de dados? Portanto, pretendemos observar e caracterizar esses elementos agregados às visualizações de dados e Big data visando compreender a perspectiva no contexto aqui explorado.

2 Objetivos

Esta investigação tem como objetivo compreender o processo de utilização dos elementos narrativos que estão presentes nas visualizações de dados, realizando um estudo exploratório, a

partir das categorias de análise: Elementos gráficos, interação, Dados estruturados, Proveniência dos dados, Tecnologias usadas e Inovação.

3 Procedimentos Metodológicos

Para atender o objetivo deste estudo, procedemos com um Estudo de Caso e nos baseamos na literatura específica além do aspecto empírico da observação e análise dos recursos narrativos nas visualizações de dados vencedoras do Data Journalism Awards 2018[27], evento que acontece anualmente desde 2012, e esse ano foi em Lisboa, Portugal, e premia os melhores trabalhos com dados em jornais, revistas e agências de notícias mundiais[28]. Em 2018, foram 630 trabalhos submetidos ao prêmio de 58 países. Integralizando um total de 86 finalistas, com 13 trabalhos vencedores. Partimos para nossa pesquisa dessa amostra de 13 trabalhos e delimitamos um corpus de 8 visualizações que atendiam ao recorte ou escopo de jornalismo de dados. Descartamos do nosso estudo as produções que não se adéquam à nossa amostra, como startup, app, sites e portfólios. O procedimento envolveu revisão de literatura, monitoramento e aplicação de Ficha de Observação[29] submetidas para essas visualizações no período de 17 a 26 de setembro de 2018.

Consideramos as seguintes categorias de observação, quais sejam: Elementos gráficos de visualização de dados para Averiguar a presença de ilustrações, vídeos, gráficos estáticos, gráficos dinâmicos, áudios, textos curtos, fotos estáticas, fotos em movimentos, imagens em 3D, mapas dinâmicos ou estáticos, dentre outros, de modo que facilitem a narrativa; Interação: Aspecto fundamental nas visualizações, Cairo (2008) define três aspectos: Instrução (nível básico, quando a narrativa é linear e apresenta botões de avançar e retroceder); Manipulação (Poder mudar os objetos na visualização); e Exploração (Tipo de interação por imersão, ex. imagens de 360, com navegação hipertextual); Dados Estruturados (ou semânticos): A partir dos estudos de Cairo (2011), essa categoria se refere em apresentar os dados de modo compreensível e com sentido a esse conjunto de dados, se está estruturado de modo compreensível a partir dos formatos (verticalizados, horizontalizados). "Também criamos informação estruturada quando desenhamos gráficos que codificam os números, o que de outra maneira seria impossível extrair algo útil" (CAIRO, 2011, p. 31, tradução nossa)[30]; Proveniência dos dados: Identificar a origem dos dados que foram explorados na visualização, se foram dados públicos, privados, de empresas, agências de notícias, etc. A ideia é identificar como esses dados estão sendo explorados; Tecnologias usadas: Identificar quais foram as tecnologias e linguagens mais utilizadas para a execução das produções de visualização de dados: E inovação como construto dessas narrativas em base de dados com estratégias de uso de novos recursos.

4 Resultados

A partir dos dados coletados[31] da observação e do procedimento da análise dos mesmos, foi possível identificar que a utilização de elementos gráficos nas visualizações fazendo composição

27 Disponível em: https://goo.gl/TeKwkw Acesso em: 14 set 2018.
28 A competição é organizada pelo Global Editors Network e tem apoio do Google News Initiative e Knight Foundation.
29 Disponível em https://goo.gl/CBFr1w acesso em 3 out.2018
30 No original: "También creamos información estructurada cuando dibujamos gráficos que codifican los números, lo que de otra manera sería imposible extraer algo útil".
31 Disponível em https://goo.gl/HoVvAu acesso em 3 out. 2018.

com os dados (exemplo de mapas, infografias, fotos e interações) para dar vazão a camada de dados e de construção de visualizações atrativas que possam dar sentido a dados complexos e cruzamento de dados. Nos 8 casos analisados (Apêndice A), os mapas estáticos predominam com 87,5% como lugar para receber dados, com exceção do PostMedia, que não trouxe nem mapas estáticos e nem dinâmicos. Em seguida, o uso de vídeos enquanto recurso das narrativas com 75% de uso. Em compensação, tivemos 4 gráficos interativos em detrimento de 3 gráficos estáticos. Gráficos guiados por dados são 2 (Infotimes e RunRun), em outros momentos os dados vêm incorporados em outros elementos.

No aspecto interação, como recurso que permite maior participação do usuário no manejo desses dados e de toda a narrativa, identificamos produções mais avançadas e com uso mais intenso de características de interação com o predomínio do tipo de interação por Exploração, total de 100% dos casos analisados (8 de 8), além de 2 casos de Manipulação (PostMedia e Infotimes, que também concomitantemente apresentaram o grau de exploração, totalizando 25% para esse item). Nenhum caso foi registrado do nível mais básico, o de Instrução. Essa possibilidade de interação é um aspecto pertinente para o formato de visualização de dados porque quanto maior o grau de interação, mas aumenta a possibilidade de cruzamento de dados em nível de personalização pelo usuário. Logo, constitui-se de um recurso fundamental na construção atual dessas visualizações.

Em relação aos dados estruturados (Apêndice C), as narrativas de visualização de dados têm se sofisticado e utilizado novas possibilidades de apresentação. Identificamos a tendência de verticalização, totalizando 87,5% da amostra (7 casos) contra 2 casos (25%) horizontais. O modelo vertical se tornou tendência a partir do SnowFall do The New York Times, que a partir de 2012[32] iniciou o fenômeno da verticalização como formato para reportagens com dados permitindo aprofundamento para uso de recursos diversos como mapas, vídeos, mapas guiados por dados e outros recursos multimídia que dialogam diretamente com os dados em grande volume. A partir de então, os demais jornais mundiais começaram a aderir a esse formato, cuja "abundância do texto verbal sinaliza um resgate da qualidade, apuração e contextualização" (LONGHI; WINQUES, 2015, p. 8).

Além das narrativas verticais, os resultados apontaram para 75% (6 dos 8 casos analisados) das produções baseadas em mapas guiados por dados, cujos dados ficaram visíveis, seguidos de 25% do formato horizontalizados. Essas construções podem apontar tendência no jornalismo e na Ciência da Informação como formatos de apresentação. Esse tipo de formato também é denominado de narrativa longform, "um nível mais aprofundado de relato, que vai além do padrão cotidiano da produção e narrativas atraentes, frequentemente com elementos multimídia, que realçam o artigo" (LONGHI; WINQUES, 2015, p. 3).

As narrativas de visualização guiadas por dados se caracterizam, na origem das fontes, pelo uso de dados abertos (gráfico 1). Dos 8 casos analisados de visualização de dados, a maioria (7, ou seja, 87,5%) utilizam dados abertos. Igualmente o uso de dados governamentais (87,5%) e 3 casos de uso de dados de ONGs e similares (37,5%)[33]. Dados fechados apenas no caso da agência Reuters (12,7%), que concomitantemente também utiliza dados abertos e governamentais nas

32 Disponível em: https://goo.gl/zUufx2 Acesso em: 18 set 2018.

33 Neste levantamento, os resultados somam mais de 100% porque era possível selecionar mais de um elemento por caso.

suas produções. Portanto, nesse quesito os dados abertos são predominantes nos projetos de visualização de dados apresentados demonstrando avanço nesta política. Buscamos, nesse caso, compreender o avanço do uso de dados abertos e governamentais e sua abundância para construção de narrativas ou projetos.

Sobre as tecnologias utilizadas (gráfico 2), esse item é mais complexo de analisar tendo em vista que as tecnologias e linguagens dependem do tipo de projeto e da complexidade do mesmo e, ao mesmo tempo, do tamanho e da especialidade da equipe envolvida em tais projetos. O predomínio na nossa observação foi de tecnologias fora do escopo do nosso levantamento prévio e enquadrando-se em "outros". Dos 8 casos, 5 utilizaram tecnologias distintas e novas (65,5%). Há uma variedade de tecnologias e linguagens observada na análise, a exemplo da linguagem R e Python com 12,5% do total. Outros como JavaScript, CSS, por exemplo, totalizaram 25%.

Gráfico 1: Proveniência dos dados.

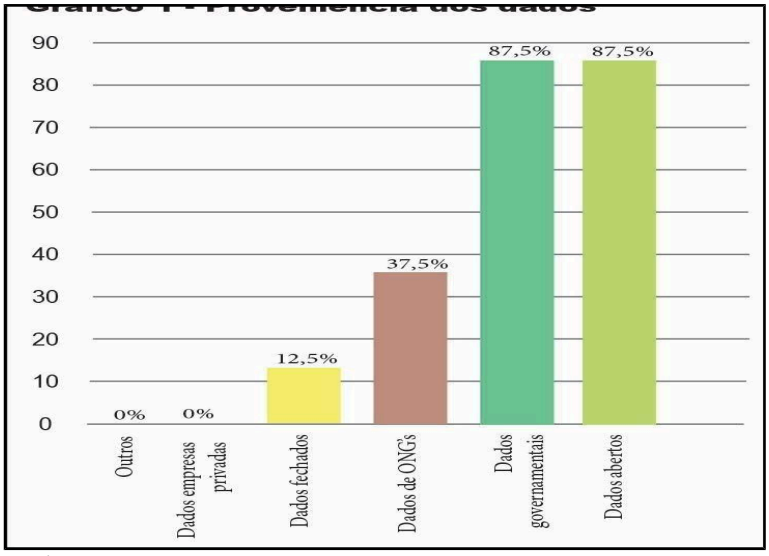

Fonte: Dados da Pesquisa, 2018.

Especificamos apenas as linguagens e tecnologias mencionadas no resumo executivo (apresentação) dos projetos vencedores sem exploração interna dos projetos para tentar identificar pelo código fonte ou outro meio tendo em vista que isso exigiria um trabalho de "bastidores" dos projetos de difícil caracterização visando a precisão. Logo, partimos para o próprio resumo em que cada projeto indicava essas tecnologias utilizadas, de modo a termos um recorte mais coerente. Essa exploração nos fornece um panorama e aponta para o uso crescente de tecnologias específicas de visualização de dados como o Tableau Public[34].

Na nossa observação, exploramos o conceito de inovação, partimos da observação de cada caso e dos próprios apontamentos no resumo executivo dos projetos para poder apontar os avanços em termos de inovação nessas narrativas baseadas em visualização guiada por dados. Nesta direção, identificou-se que todas, em algum aspecto, inclusive pela natureza do prêmio, apresentam alguns elementos de inovação e de avanço quanto ao estado das produções do

34 Software livre que permite criar visualizações de dados na Web. Disponível em: https://public.tableau.com/pt-br/s/ Acesso em: 1 out 2018.

momento, apresentando inovações disruptivas para os formatos de visualização de dados. De um modo geral, podemos apontar alguns aspectos inovadores como: 1) Dados Geolocalizados por satélite e atualizáveis em tempo real; 2) Mapas guiados por dados como bússola para as informações; 3) Imagens em 360 graus conferindo imersão na narrativa e 4) Machine Learning e Inteligência Artificial como potencializadores dessas narrativas.

Gráfico 2: Tecnologias usadas.

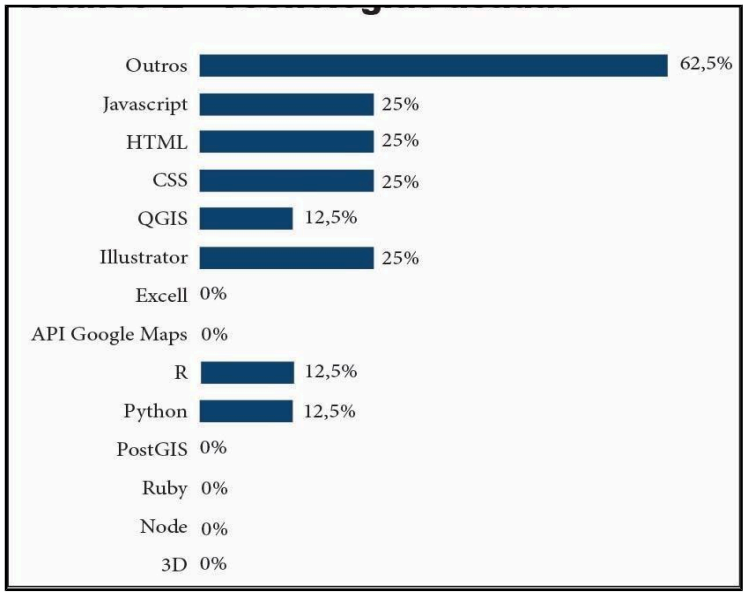

Fonte: Dados da Pesquisa, 2018.

5 Considerações Finais

As narrativas em ambientes digitais criaram novos paradigmas em relação às narrativas tradicionais, tendo em vista o potencial da ambiência digital para a construção das mesmas. Nesta direção, esse estudo tentou compreender os processos de construção das narrativas com dados nestas visualizações e demarcar as estratégias utilizadas como forma de compreensão dos dados. Observamos alguns aspectos que servem para reflexão: 1) Formato Longform segue como uma prática que vem sendo cada vez mais explorado nas narrativas com dados; 2) Mapas guiados por dados como estrutura principal de apresentação dos dados, o que confere um aspecto de inovação dos dados; 3) Narrativas com dados em profundidade, o que quebra com o paradigma de somente mostrar, mas contextualizar, dar sentido àqueles dados visualmente.

Os textos curtos e blocados ao lado das imagens foram bem recorrentes, assim como o uso dos hiperlinks. 4) Dados abertos cada vez mais sendo explorados nestas produções, o que pode transparecer uma certa ética ao creditar nas narrativas, muito embora não se sabe se todos os dados brutos foram trabalhos massivamente. Vale destacar a imagem em satélite como elemento diferencial produzindo um ambiente de imersão naquela estrutura de dados, ainda que só a Reuters tenha utilizado o recurso timidamente. As narrativas seguem as estratégias de tendências de mercado que estão postas, como formatos Longform e imagens de satélite de modo imersivo, para que se sinta dentro da narrativa, muito embora apenas a Agência Reuters utilizou, mas segue sendo um indício promissor desse recurso. A opção pela interação por exploração, cuja

navegação se deu mais pela força do link, condiz com a proposta da narrativa, de contextualizar os dados, contar a história dos acontecimentos, o que pode parecer pouco dinâmico à primeira vista. Em nossa análise, alguns veículos analisados poderiam explorar mais imagens em 360 graus, por exemplo, como ferramenta imersiva das narrativas, o que inovaria no manejo com os dados.

É válido ressaltar que não há modelos fechados para realizar análises e estudos, mas as existências de vários ângulos de abordagens em diversas áreas, tendo em vista que "a narrativa é capaz de corresponder a uma cronologia cronológica e não cronológica, extraindo uma sucessão de eventos" (BOASE, 2013, p. 5)[35]. Assim sendo, a pesquisa avança no sentido de demarcação de como esses elementos narrativos estão sendo explorados e seus potenciais na era do Big Data, de modo em o processo analítico-visual seja um dos expoentes, e ainda que resguardando as limitações do estudo. Para trabalhos futuros, busca-se realizar um estudo de recepção a fim de averiguar como os usuários recebem e compreendem esses dados a partir dessas visualizações, bem como a exploração mais detalhada das tecnologias utilizadas pelos profissionais.

Referências

BOASE, C. **Digital Storytelling for Reflection and Engagement: a study of the uses and potential of digital storytelling**. Centre for Active Learning & Department of Education, University of Gloucestershire. (2013). Disponível em: https://goo.gl/MNJg9H Acesso em 3 set 2018.

CAIRO, A. **El arte funcional: infografía y visualización de la información**. Madrid: Alamut, 2011.. (2008) Infografía 2.0: visualización interactiva de información en prensa. Alamut, Madrid.

FIGUEIRAS, A. A typology for data visualization on the web. In Information Visualisation (IV), 2013. **17th International Conference**, pages 351–358, July 2013. Disponível em: https://goo.gl/TNhtEm Acesso em: 18 mai 2018.

KOSARA, R; MACKLINLAY, J. Storytelling: The next step for visualization. **Computer, 46(5):44–50, 2013.**

LAGOZE, C. Big Data, data integraty, and the fracturing of the zone control. **Big Data & Society**. jul./dec. 2014. Disponível em: https://goo.gl/TcsW1r Acesso em: 10 abr. 2018.

LONGHI, R.; WINQUES, K. O lugar do longform no jornalismo online: qualidade versus quantidade e algumas considerações sobre o consumo. Brasília. 24º Compós2015, - **Anais..** Brasília: Universidade de Brasília, 2015. v. 1. p. 1-19.

PAUL, N. Elementos das narrativas digitais. In P. Ferrari (Org). **Hipertexto e hipermídia**: as novas ferramentas da Comunicação digital. São Paulo: Contexto, 2012.

35 No original: "Narrative is able to combine both a chronological and non-chronological dimension into a meaningful whole by extracting a configuration from a followable succession of events".

SEGEL, E; HEER, J. Narrative visualization: Telling stories with data. **Visualization and Computer Graphics**, IEEE Transactions on, 16(6):1139–1148, 2010. Disponível em: https://goo.gl/TmNgFu Acesso em: 3 set 2018.

TUFTE, E. **The visual display of quantitative information**. Cheshire, Connecticut: Graphic Press, 2001.

VIÉGAS, F. **Designer explica como a visualização de dados pode ser atraente**. Rio de Janeiro, TV Globo, 20 jun. 2013. Entrevista a Globo Universidade. Disponível em: http://goo.gl/c35Ztn Acesso: 4 jul 2017.

Apêndice A – Elementos gráficos nas visualizações

TIPO	Agência Reuters	La Nación	PostMedia	Infotimes	Caixin Media	RunRun	BuzzFeed	G1	TOTAL
Gráficos interativos	X		X	X	X				4 (50%)
Gráficos guiados por dados				X		X			2 (25%)
Gráficos estáticos	X				X	X			3 (37,5)
Mapas interativos	X			X	X	X			4 (50%)
Mapas estáticos	X	X		X	X	X	X	X	7 (87,5%)
Foto interativa	X								1 (12,5%)
Foto estática	X			X		X	X		4 (50%)
Imagem em 360	X								1 (12,5%)
Ilustrações	X		X	X	X		X		5 (62,5%)
Vídeo		X		X	X	X	X	X	6 (75%)
Imagem de satélite	X								1 (12,5%)
Infográficos estáticos								X	1 (12,5%)
Infográficos interativos									0 (0%)
Outros			X						1 (12,5%)

Fonte: Dados da Pesquisa, 2018.

Apêndice B – Interação

TIPO	Agência Reuters	La Nación	PostMedia	Infotimes	Caixin Media	RunRun	BuzzFeed	G1	TOTAL
Instrução (linear e apareenta botões de avançar e retroceder)									0 (0%)
Manipulação (quando é possível mudar os objetos dentro da visualização)			X	X					2 (25%)
Exploração (tipo de interação com navegação hipertextual, explorando dados e/ou por imersão)	X	X	X	X	X	X	X	X	8 (100%)

Fonte: Dados da Pesquisa, 2018.

Apêndice C – Dados estruturados

TIPO	Agência Reuters	La Nación	PostMedia	Infotimes	Caixin Media	RunRun	BuzzFeed	G1	TOTAL
Verticalizados	X	X	X	X	X		X	X	7 (87,5%)
Horizontalizados						X	X		2 (25%)
Mapas guiados por dados	X	X		X	X	X		X	6 (75%)
Outro									0 (0%)

Fonte: Dados da Pesquisa, 2018.

Vídeo da apresentação

Título: Narrativas de visualizações guiadas por dados: Big Data e inovação.

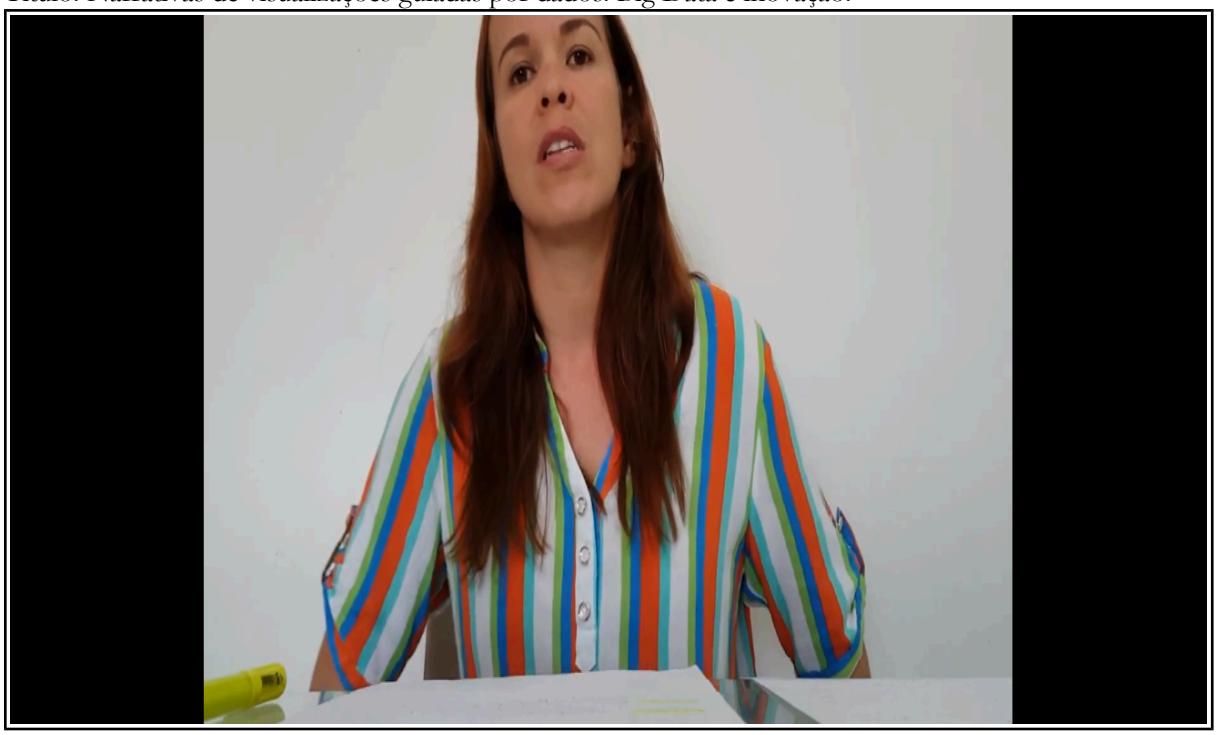

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=8

Transcrição da apresentação

Esse vídeo é para o WIDAT – Workshop de Dados e Informação e Tecnologia de 2018, que acontecem na UFPB no período de 27 a 29 de novembro. O meu artigo trata-se de um desmembramento da minha tese de doutorado sobre visualização de dados nos laboratórios guiados por dados e nesse sentido esse artigo vai tratar um pouco dessas narrativas de visualização que há com os dados, fazendo uma ponte com Big Data e inovação.

Para isso qual é o objetivo do artigo? O artigo com o nome "Narrativas de visualizações guiadas por dados: Big Data e inovação", o objetivo maior dele é analisar como essas narrativas de visualização de dados é do prêmio Data Journalism Awards 2018, desse ano, é uma premiação na área de jornalismo que acontece todos os anos e que visa premiar os melhores trabalhos com dados. Neste evento são vários formatos: portfólios, sites, gestão de dados, mas eu foquei nas visualizações, nas importações que sai dos grandes jornais como forma de analisar como essas narrativas guiadas por dados interessam formatos inovadores para as visualizações de dados, essa é a grande questão do artigo que tenta entender como essas narrativas são construídas nos jornais.

Como metodologia, fiz um estudo de caso e aplicação de ficha de observação, além disso criei seis categorias que são os elementos gráficos e quero entender: como, quais são os elementos gráficos que estão presentes nessas narrativas? Qual é a maior incidência deles? A interação, quais são os tipos de interação por manipulação? Por exploração? Por um grau de instrução que é um grau mais básico da área da internação? Também quero saber como os dados estruturados, como é que os dados estão formados, se estão na vertical, se estão na horizontal. A proveniência dos dados de onde vem estes dados? São das bases internas? Se são dados abertos? São de ONGs? Empresas privadas? Enfim, as tecnologias utilizadas? Como eles estão fazendo essas narrativas de modo em que esse aspecto inovador seja realmente o grande diferenciador dessas narrativas de visualização de dados e o aspecto de inovação, o que é que tem de inovação para que as narrativas ganhassem esse prêmio que fizesse também todo o diferencial na hora de compreender as informações.

Nesse sentido a introdução discute um pouco essa questão do Big Data e inovação, ou seja, tentando localizar assim que o Big Data traz muitos desafios como gerenciar esses grandes volumes de dados, mas também traz um campo fértil de inovação, um campo que você pode inovar e no nosso caso, traz também as emergências de formatos diferenciados nas visualizações, a gente teve a visualização era o último aspecto multimídia, e que há muito midiatizada era a grande característica, passou um tempo mais assim mas também já vieram outros aspectos como as bases de dados, a inserção dos próprios dados nessas narrativas, a questão da imagem 360 graus, realidade aumentada, entanto são vários formatos inovadores que estão aí para serem aproveitadas da melhor forma.

Nesse sentido nós fizemos essa aplicação desse questionário, os resultados foram: no que se refere aos elementos gráficos houve uma incidência dos mapas 85% dos mapas interativos começa é grandioso nas visualizações, seguido de vídeos 75% também usar pequenos vídeos e gráficos interativos 50%.

Observa que o mapa como plataforma de principal geolocalização, ela vem aqui com grande incidência, no grande predominância das visualizações que pode denotar que era um para essas visualizações seria a melhor forma de localizar o leitor, o usuário, dessa informação que desejam ser passada.

A interação 100% de exploração, ou seja, o usuário explorar a narrativa, não aquela visualização que você tenha um começo, meio e fim, como no caso do infográfico, mas é uma visualização em que você explora esses dados. Então temos um leitor, ele vai, ele percorre, ele traça a trajetória do caminho desses dados, em segundo a manipulação que você pode manipular pequenos objetos na visualização que também foi um grande diferenciador em alguns anos atrás, continua em 25% não tanto quanto essa exploração realmente é bem característico dessas visualizações.

Os dados estruturados então, ou seja, 87,5% são dados formato verticalizado, porque temos as visualizações do modo horizontal mas também temos as visualizações do formato mais verticalizado que é uma tendência do mercado, já vem se praticando os jornais principalmente o The New York Times que foi o jornal americano que digamos lançou esse formato e que vem sendo bastante utilizado com certa predominância. A proveniência dos dados seja 87% dados abertos, e, outros dados fechados de umas e outras empresas privadas 12,7% demonstra que essa política dos dados abertos tem melhorado consideravelmente para que essas visualizações sejam feitas com os dados públicos. As tecnologias utilizadas são em torno de 65% novas, então são tecnologias bem inovadoras em que eles mesmos foram se adaptando, vem adaptando vários outros softwares e com a as imagens dos jogos escolhidos, as imagens em HTML, bem mais usuais também tem uma certa incidência, linguagem Python, linguagem R, JavaScript, entre outras.

Aspectos de inovação que a gente que o meu artigo apontou que são dados geolocalizados por satélites e atualizados em tempo real, isso é um grande fator inovador nessas visualizações, mapas guiados por dados como bússola para as informações, então esses dados que tem o mapa customizado com esses dados e imagens em 360 graus, ou seja, uma imagem de imersão embora só a Agência Reuters tem utilizado, mas já denota um ponto desses processos inovadores de visualização, já existe em outros ambientes em outras plataformas nas visualizações apontadas como uma ponta de iceberg de aspectos inovadores, Machine Learning e Inteligência Artificial como potencializadores dessas narrativas. Então foram esses os aspectos inovadores que constatamos.

E nas conclusões, a gente pode concluir desse nosso estudo, quem tem esse formato Longform que é mais verticalizada, é pulverizado, por exemplo, pelo The New York Times como já falei, então é uma tendência no mercado nas agências sistemática, já é feita de forma mais intensa nos grandes jornais, nas grandes produções, mapas guiados por dados cada vez mais interativo, então assim a interação sempre foi um diferencial nas visualizações, mas nesse formato aqui com formato Longform com os mapas guiados por dados mais essas narrativas de dados em profundidade, é realmente um aspecto que diferencia, que potencializa suas narrativas e visualizações de dados, porque tem sempre alguém, alguns especialistas então as narrativas elas

são mais exploração mas podem os dados para se aprofundar com essa questão dos dados abertos.

E como trabalhos futuros a gente pode sugerir um estudo de recepção para saber lidar como os leitores recebem esta narrativa, como os leitores compreendem essas narrativas ou em outros estudos também explorar mais essas tecnologias utilizadas por esses jornais, pelos designers, pelos especialistas, como fazer essas narrativas mais inovadoras.

Letreiros e amores: uma estratégia informacional para existir no Instagram

Tassyara Onofre de Oliveira[a] *e Matheus José Pessoa de Andrade*[b]

Resumo: O presente trabalho tem como objetivo pensar a função informacional dos letreiros de cidade. Acreditamos, a priori, ser uma estratégia de existência para a internet, atendendo as necessidades e valores contidos nas informações das redes sociais digitais. Desta maneira, partimos do pressuposto que o Instagram modificou os ambientes sociais pelas formas e fluxos de compartilhamento das práticas fotográficas, fazendo com que as coisas se tornem instagramáveis, sobretudo no universo dos viajantes fotógrafos. Para atender a esse regime informacional, proliferam-se os letreiros turísticos nas cidades. No caso específico do letreiro da cidade de João Pessoa, o qual nós abordamos, foi realizada uma análise de dados para averiguar o número de postagens e acessos baseado na hastag #euamojampa para, juntamente com nossas reflexões teóricas, atestar a função informacional dos letreiros de cidade em tempos de vida online.

Palavras-chave: Letreiros de cidade. Informação. Instagram. Fotografia.

Signs and love: an informational strategy to exist on Instagram

Abstract: The present work aims to think the informational function of the city signs. We believe, a priori, to be a strategy of existence for the internet, meeting the needs and values contained in the information of digital social networks. In this way, we start from the assumption that the Instagram modified the social environments by the forms and streams of sharing of the photographic practices, making things become unstable, especially in the universe of photographic travelers. In order to meet this informational regime, tourist signs are proliferating in the cities. In the specific case of the sign of the city of João Pessoa, which we approached, a data analysis was carried out to ascertain the number of posts and accesses based on the #euamojampa hastag to, together with our theoretical reflections, to verify the informational function of the signs of city in times of life online.

Keyword: City sign. Information. Instagram. Photography.

a Universidade Federal da Paraíba (UFPB). E-mail: tassyjp@gmail.com. Currículo: http://lattes.cnpq.br/5328618364332415
b Universidade Federal da Paraíba (UFPB). E-mail: theujp@hotmail.com. Currículo: http://lattes.cnpq.br/6550728746243858

1 Introdução

No século XXI, foram construídos vários letreiros nas mais diversas cidades do Brasil e do mundo, os quais nitidamente fazem parte da atividade econômica do turismo. Muitas vezes, os letreiros são esteticamente bem-feitos, coloridos, em paisagens privilegiadas, insinuando o amor instantâneo. Algumas vezes estão localizados em pontos estratégicos da cidade, noutros casos são construídos num novo lugar, criando novas práticas de sociabilidades.

O turista, também, é um colecionador fotografias, como um tipo de suvenir, um registro dos momentos únicos que o viajante vivencia em lugares turisticamente importantes. Esses momentos migraram das estantes de casa, dos quadros e porta-retratos, para as telas de computador e dispositivos móveis, possibilitando uma maior visibilidade a essa experiência. Nesse campo, os letreiros tornaram-se um lugar em potencial de fotografia turísticas.

O fluxo de informações através da fotografia digital na internet passa a ter um papel abertamente indispensável, visto que a sociedade vivencia um novo regime de conexão através da internet, fruto das necessidades de troca de informação entre as pessoas. Nesse contexto, redes sociais como o Instagram pode ser visto como via de compartilhamento de informação em tempo real, considerando a dinâmica do desenvolvimento tecnológico. Devido à quantidade de usuários ativos existentes e suas câmeras portáteis, a informação visual consegue ser montada e disseminada instantaneamente.

2 Objetivo norteador

Nossa proposta de análise dos letreiros de cidade está diretamente relacionada ao Instagram. Considerando o letreiro como uma estratégia de existir online, reconhecemos o impacto causado pelo Instagram nesse contexto. Pensamos, assim, na seguinte questão: qual a função informacional dos letreiros de cidade em tempo de Instagram?

3 Caracterização da pesquisa

Considerando o objetivo proposto, foi desenvolvida uma pesquisa com abordagem de cunho bibliográfico, no tocante a análise de traçar um histórico sobre o objeto de estudo, como também ajuda a identificar contradições e respostas sobre o objeto. Bem como uma investigação exploratória e descritiva, no que concerne a análise de dados coletados sobre a tag #euamojampa através da ferramenta Hashtracking.

4 Instagram: por uma existência online

Falar sobre redes sociais é apontar para um lugar de sociabilidades, assim como são as praças ou os bares, por exemplo. Ou como um dia foram algumas calçadas das casas em pequenas cidades. Nelas surgem valores inerentes daqueles lugares de encontro e daquelas formas de relações sociais que ali se estabelecem. Práticas de horários, de conduta, de presença e ausência, e até de tipo de informação.

Na era das redes sociais digitais criou-se um lugar de vivências online, onde nos incluímos também pela possibilidade de participar e comprovar diariamente nossa existência social. Seja qual for a maneira que utilizam, os usuários buscam também afeto, pertencimento, reconhecimento, amor e felicidade. Procuram, a seu modo, encontrar satisfação para que seus

desejos sejam realizados, como também, vencer a solidão, o tédio, fugir da realidade e até mesmo tentar seus "minutos de fama". Enquanto uns chegam à fama e ganham grande notoriedade, outros fazem o possível para prezar por sua transparência. Trata-se, portanto, da percepção de uma prática relacional construída naquele lugar, onde se luta pela existência em rede e pelo ato de ser curtido[36], e até idolatrado pelos outros participantes.

É cabível observar que existimos nas redes sociais digitais também por se dar conta de um tipo de valor simbólico ali impregnado, como Márcia Tiburi destaca: "Não aparecemos apenas porque esse é nosso modo de habitar a cidade, a sociedade, de estar no mundo. Aparecer tornou-se urgente, como forma de capital" (2017, p.121). Por isso, postam-se diariamente informações sobre as coisas do mundo. Conteúdos diversos, em formatos de textos, imagens, áudios e vídeos, de acordo com as necessidades de cada integrante da rede social Instagram.

Entendemos que ele é uma rede social predominantemente de fotografias, diferentes de outras tantas. Linascheke (2011) ressalta que o Instagram é uma comunidade fotográfica, e isso explica tamanho sucesso. Comparando-o com redes sociais como o Twitter e o Facebook, o autor observa que o Instagram é a única rede social inteiramente baseada em fotografias. Há algum texto permeando tudo isso, alguns comentários, e outras tantas curtidas, mas, mesmo assim, segundo ele, tudo se resume à imagem fotográfica e é justamente por isso que o Instagram é único, não há como fazer uma postagem sem se utilizar de uma imagem.

Nada mais atual para se comparar com a obra A sociedade do espetáculo de Guy Debord do que a rede social Instagram. O espetáculo, de acordo com o pensamento debordiano, não é apenas um conjunto de imagens, mas uma relação social entre pessoas, mediatizada por imagens.

Com base na reflexão de Susan Sontag, desde a invenção da fotografia, no século XIX, o mundo vivencia uma mudança no paradigma das visualidades, pelas práticas, valores e costumes circunscritos no uso da câmera fotográfica nos mais diversos grupos sociais. Os desdobramentos dados pela fotografia foram capazes de transformar a sociedade. Por exemplo, "viajar se torna uma estratégia de acumular fotos" (SONTAG, 2004, p.20), e não apenas de desbravar lugares, conhecer pessoas e relatar em textos.

A interferência do ato fotográfico sobre as coisas do mundo pode ser percebida em pontos turísticos, eventos, fachadas, vestimentas etc., cujas estruturas muitas vezes são feitas para serem fotografadas, isto é, para existir no campo visual das fotos. Para Sontag, em síntese, "hoje, tudo existe para terminar numa fotografia" (2004, p.35). Para nós, o Instagram potencializou esse aforismo principalmente pelo sistema de circulação das imagens, amplificando os tratamentos visuais das coisas para serem fotografadas e postadas potencialmente.

Em consonância com os aparelhos celulares, pela portabilidade das câmeras e sua conexão com as redes sociais virtuais, podemos atestar dois aspectos da cultura fotográfica no Instagram: de um lado, pessoas capturando tudo que convém para partilhar com os outros nas redes sociais a ideia de que estiveram em determinado lugar; e, do outro lado, os lugares mendigando cada vez mais para existirem dentro dos jogos simbólicos de fotografia instaurados no cotidiano das redes sociais virtuais, pelas pessoas que capturam incessantemente suas fotos. Por isso, os lugares buscam estratégias, tais como: os letreiros para participarem deste regime. Eles são

36 Fazemos referência direta às ferramentas de participação e interação contidas em plataformas como o Facebook e o Instagram, com o titulo de like (gostar, em inglês).

potencialmente fotografáveis e, por tabela, fazem o lugar existir no fluxo informativo dessas imagens colecionadas pelos viajantes, e publicamente postas numa plataforma como o Instagram.

Com o auxílio das hastags[37], muitas vezes já induzidas pelos próprios monumentos[38], os usuários criam "rastros" que são publicados, arquivados, e, portanto, são recuperáveis e buscáveis. Isso resulta numa visibilidade imediata e "gratuita" para as cidades que possuem tais letreiros. Essa funcionalidade locativa abriu caminho para um compartilhamento de insights do cotidiano das pessoas em tempo real.

Os letreiros de cidades, construídos nesse modismo da segunda década do século XXI, foram impulsionados pelas lógicas simbólicas das redes sociais digitais, sobretudo na prática fotográfica dos viajantes usuários do Instagram. Eles são feitos para fazer com que as cidades participem enquanto lugar nesse fluxo de visibilidade na internet, aumentando assim o seu capital simbólico. São monumentos ao self, por assim dizer, feitos para terminarem numa fotografia, aparecerem online e se tornarem hastags. Buscam, assim, se fortalecer enquanto forma de valor informacional no Instagram, contribuindo com o espetáculo para cumprir com o desdobramento contido nos interesses dos gestores.

4 Letreiros de cidade: a instagramização das coisas

Para entender melhor o encantamento pelos letreiros e compreender por que eles atraem tantos olhares, câmeras fotográficas e corações, basta voltar no tempo até 1923, ano de inauguração do símbolo em Hollywood4[39]. A princípio a intenção da construção não foi tornar a cidade famosa. O motivo de sua criação foi como peça publicitária para vender lotes do empreendimento imobiliário. A proposta era deixar as letras posicionadas ali durante um ano e meio para incentivar a compra de terrenos próximos. Por isso, a primeira aparição das letras continha, além do nome da cidade, o complemento "land", que significa "terra" em inglês, formando a palavra Hollywoodland. O que inicialmente era uma ação de publicidade caiu na graça dos moradores e foi parar nas telas de cinema do mundo, acompanhando a ascensão do cinema americano.

No continente europeu, o slogan I Amsterdam[40] faz um trocadilho na língua inglesa, sugerindo a frase "Eu sou Amsterdã". Localizado na parte de trás do Rijksmuseumque e que é o museu de arte mais importante da Holanda, na Museumplein, o monumento tornou-se rapidamente um ícone da cidade e uma das fotografias mais procuradas para quem visita Amsterdam, a capital holandesa.

A região norte do Caribe também não deixou a onda passar. Cancún, o paraíso mexicano de ilhas, também tem seu famoso letreiro turístico. O monumento chamado de Cancun Sign[41] é um

37 As hashtags cumprem o papel de agrupar imagens relacionadas a um determinado assunto. O usuário pode adicionar uma tag(etiqueta) a uma imagem, utilizando o símbolo (#), unindo-a automaticamente a todas as outras imagens "tagueadas" com a mesma palavra. Quando a combinação é publicada, transforma-se em um hiperlink que leva para uma página com outras publicações relacionadas ao mesmo tema.

38 No caso de letreiros de lugares que já se constituem com o jogo da velha no início da escrita em sua forma natural, expressando essa participação no universo online.

39 The Hollywood Sign. Disponível em: <https://hollywoodsign.org/ > Acesso em: 22de agosto de 2018.

40 <I amsterdam letters . Disponível em: https://www.iamsterdam.com/en/about-amsterdam/overview/i-amsterdam-letters > Acesso em: 22 de agosto de 2018.

41 Welcome to happiness welcome to Cancun Sign! Disponível em: <http://wwwilson.wixsite.com/cancunsign2 > Acesso em: 22 de agosto de 2018.

grande e colorido letreiro, aberto oficialmente para visitantes em 31 de julho de 2014, uma das mais famosas atrações para os visitantes e turistas da ilha mexicana fica na famosa Playa Delfines, conhecida por ser a mais bela de Cancún e também chamada de El Mirador, por oferecer uma bela vista do lugar.

Os três letreiros citados foram inesgotavelmente fotografados por milhares de turistas desde suas criações, tornando-se lugares obrigatórios de fotografia para viajantes que ali passavam.

Sob a égide da imagem digital, o Instagram é um espaço fotográfico inventivo, o qual permite variadas maneiras de utilização dos perfis. Uma forma comum de uso está relacionada com a amostragem do cotidiano de si. Os usuários são um tipo de curadores dos próprios perfis, ao elegerem critérios pessoais de publicação que, normalmente, não denunciam contra a projeção de si: lugares, objetos, pessoas e performances devem obedecer a uma lógica naquela forma de exposição para os seus seguidores, isto é, dentro de um regime político de produção de discursos sob vigilância.

As coisas do mundo passaram a serem pensadas para serem fotografadas para postagens e consequentemente existirem nas imagens da rede social virtual, semeando seu capital simbólico. Aqui consideramos o que Marshall McLuhan explica quando privilegia um olhar sobre o impacto do meio de comunicação na vida social, antes mesmo de se preocupar com os efeitos ideológicos da informação sobre o receptor. Para ele, "(…) é o meio que configura e controla a proporção e a forma das ações e associações humanas" (2005, p.23). Nesse sentido, o meio recria as relações interpessoais e as formas dos ambientes, notado por nós quando as coisas passaram a se orientar visualmente numa conotação sugerida pelo funcionamento do Instagram. Por exemplo, estabelecimentos preparam cenários e iluminações para seus clientes fazerem suas selfs; restaurantes dão maior atenção ao visual de seus drinks para prosperar nos perfis dos clientes; eventos montam lugares para seus visitantes fazerem seus registros fotográficos com hastag sugerida, amplificando sua divulgação; enfim, podemos identificar uma gama de gestos em função dessa lógica, inclusive os letreiros de cidade, a fim de se tornarem fotografias e hastags na plataforma, dentro dos parâmetros de curadoria dos usuários.

> Como efeito disso, a instagramização dos espaços físicos, públicos e privados, dos objetos, das formas de circulação na cidade e de experiências envolve reordená-los e editá-los para que sejam visíveis e publicáveis[42] (BENTES, 2017).

Trata-se de uma instagramização das cidades que ajustam seu ambiente a fim de existir online. Muitos dos letreiros de cidade escrevem uma forma de amor de passagem (e não passageiro), mas que, na ocasião, são registrados para perpetuar enquanto memória fotográfica. O amor expresso parece estar dentro dos critérios dos curadores e vigilantes do Instagram, principalmente pelas relações estabelecidas das pessoas com os lugares. Ao tempo que constroem uma forma de projetar um lugar afetivamente acolhedor para os turistas (e talvez não seja), fundamentados na estratégia de fortalecer o mercado turístico daquele espaço. Tornam-se, assim, instagramáveis, ao participarem desse jogo.

42 Texto publicado na #Dobras 15, intitulado: Instagramização da vida: uma curadoria do visível. Disponível em: <http://medialabufrj.net/blog/2018/08/dobras-15-instagramizacao-da-vida-uma-curadoria-do-visivel>Acesso em 17 de agosto de 2018.

Concordamos com Bauman (2001) quando explica a sociedade a partir da concepção de liquidez, calcada na cultura do consumo como base de valor de toda sociabilidade dos indivíduos. A vida não se trata apenas de ser, mas também de ter. "(…) A satisfação de alcançar um objeto é apenas momentânea" (2001, p.70). Assim como o consumo, centrado no ato efêmero de obter algo e, logo, passar para o próximo item. Os amores ganham novas significações por parte de uma vida liquefeita e veloz como a atual. O amor duradouro é remodelado nas práticas de sociabilidades modernas, homogeneizada com os valores culturais do consumo contido nas formas de relações sociais amorosas. Em vias virtuais de relacionamento, "muito mais tem acontecido no caminho em direção à líquida e individualizada sociedade moderna para tornar os compromissos de longo prazo pouco numerosos (…)" (BAUMAN, 2004, p.61). É apenas um amor rápido, de passagem, fixado numa foto e postado para um grupo de seguidores entenderem que alguém esteve naquela cidade, ao tempo que os seguidores conhecem fotograficamente aquele lugar através das diversas informações reconhecíveis – muitas vezes nada se sabe contextualmente daquele acontecimento pela sua forma de representação.

Nesse sentido, a ação informativa do letreiro de cidade se rende às mudanças ocorridas a partir da invenção do Instagram, agregando valores como o registro, o amor e a recordação na prática dos fotógrafos viajantes, dentro dessa lógica de existência online na plataforma em questão.

5 #euamojampa: o caso do letreiro da cidade de João Pessoa

Entre tantos letreiros famosos espalhados pelo mundo, a capital Paraibana, João Pessoa, sentiu a necessidade de possuir também seu monumento e declarar aos seus visitantes o amor pela cidade.

O letreiro com a frase "Eu amo Jampa" ou "Eu <3 Jampa", foi inaugurado em 28 de dezembro de 2015[43], situado no Busto de Tamandaré[44], que fica entre as praias de Tambaú e Cabo Branco, ambas consideradas as praias mais famosas da cidade. O letreiro, segundo a gestão municipal, é uma homenagem e representa "o amor pela cidade estampado em um dos principais pontos turísticos da capital". Desde sua fundação o local onde se está o letreiro costuma ser visitado por turistas e pessoenses, um dos cenários mais disputados para fotos e selfies. Um reflexo disso são os números oferecidos pelo Instragram de postagens realizadas utilização da localização e a hashtag. Em uma breve pesquisa de dados no próprio aplicativo verificamos o número de 41.512 publicações públicas[45] até o dia 23 de agosto de 2018.

Diante dessa expressiva quantidade de publicações, resolvemos fazer um diagnóstico mais preciso para entender melhor a dimensão compartilhamentos de informações fotográficas relacionadas ao letreiro. Para a análise foi escolhida a hashtag #euamojampa que faz relação ao próprio letreiro e a ferramenta de rastreio foi a Hashtracking[46] em publicações públicas, que oferece o serviço de rastreamento de hashtag no Instagram. O diagnóstico foi realizado entre os

43 Texto publicado no site da Prefeitura de João Pessoa, intitulado Prefeitura instala letreiro em homenagem a João Pessoa. Disponível em: <http://www.joaopessoa.pb.gov.br/prefeitura-instala-letreiro-em-homenagem-a-joao-pessoa> Acesso em 23 de agosto de 2018.

44 Monumento construído em homenagem ao Almirante Joaquim Marques Lisboa, o Marquês de Tamandaré, patrono da Marinha do Brasil. Localiza-se na divisa entre as praias de Cabo Branco e Tambaú, no município brasileiro de João Pessoa. Conhecido popularmente como "Busto de Tamandaré".

45 Pois alguns perfis são restritos apenas aos seus seguidores, o que dificulta uma contabilidade mais precisa.

dias 16 a 23 de agosto de 2018, exatamente durante uma semana. Os seguintes dados foram apresentados, conforme as figuras 01 e 02 (verificar figuras no apêndice A). A Figura 01 apresenta que, durante uma semana, os usuários do Instagram, utilizando a hashtag #euamojampa fizeram 349 postagens, o que gerou 631 comentários e 17.906 curtidas, 3.054,545 impressões (número de vezes que seu conteúdo é exibido, independentemente de ter sido clicado ou não) e o alcance de 1.003,57 (número total de pessoas que visualizam seu conteúdo). Já a figura 05 expõe como funciona o engajamento em relação à #euamojampa no Instagram.

Desta amostragem mínima, de uma semana, acreditamos ter um número significativo de visualizações a ponto de fazer com que as cidades e os demais lugares criem tipos de estratégia, como os letreiros, para produzirem informação fotográfica e passarem a existirem com veemência no ambiente do Instagram.

A figura 03 (verificar figura no apêndice A) apresenta as buzzywords relacionadas à hashtag #euamojampa. Foram encontradas 46 palavras que foram utilizadas em postagens junto tag analisada. Isso comprova que a repercussão de uma imagem fotográfica feita no letreiro da cidade e postada no Instagram pode adquirir uma dimensão de visibilidade incalculável, dando subsídio à importância do monumento enquanto proliferador de informação nas redes sociais digitais. A figura 04 (verificar figura no apêndice A) aponta a geolocalização de postagens realizadas com a hashtag em questão. A ferramenta verificou 16 locais distintos, todos no Brasil, apenas numa semana de análise de dados.

Levamos em consideração também uma série de hastags correlatas capazes de representar o letreiro em questão (#jampa, #eus2jampa, #euamojp), de perfis pessoais que, às vezes, não colocam as tags em suas postagens e perfis profissionais que replicam imagens e buscam emplacar outras hastags com esse tipo de informação.

Desse vasto número de publicações, acreditamos que essa produção informativa expressiva atesta a importância do letreiro na função de fazer a cidade circular nas plataformas virtuais. A partir da pluralidade de versões fotográficas dos turistas que passam por João Pessoa, ancoradas no letreiro da cidade, cumprem o papel de existir no Instagram. Aliás, consideramos que a criação dos letreiros de cidade são impulsionas pela nova mídia que se instaurou. Imaginamos, por comparação, os letreiros mais famosos, das cidades que realmente possuem um mercado turístico expressivo mundialmente.

5 Considerações Finais

Diante do exposto, acreditamos que os letreiros de cidade são estratégias de informação eficientes para que os lugares existam online no Instagram, atendendo à lógica do capital simbólico que ali se constitui. Através da informação fotográfica praticada pelos turistas, os lugares se propagam para o mundo, divulgando uma forma de amor simbólico a fim de atender aos interesses mais diversos.

O Instagram deve ser considerado, portanto, como um meio de comunicação de significativo impacto social, a ponto de percebermos sua intervenção cultural, tanto nos mais diversos ambientes sociais, os quais frequentamos diariamente, quanto nas relações interpessoais

46 Hashtracking.com: Powerful Tracking for Hashtags. . Disponível em: https://www.hashtracking.com> Acesso em 23 de agosto de 2018.

que, através de estratégias, almejam repercutir na rede social virtual em busca de existir no fluxo da sociedade e construir seu capital simbólico através dos likes, comentários e reposts da vida.

Referências

BAUMAN, Zygmund. **Modernidade líquida**. Rio de Janeiro: Jorge Zahar Editor, 2001.

_____. **Amor líquido**: sobre a fragilidade dos laços humanos. Rio de Janeiro: Jorge Zahar Editor, 2004.

BENTES, Anna. Instagramização da vida: uma curadoria do visível. In: **Dobras**, UFRJ, 2017.

DEBORD, Guy. **A sociedade do espetáculo**. 11ed. Rio de Janeiro: Contraponto, 2009.

LINASCHEKE, J. **Getting the most from Instagram**. Berkeley: Peachpit Press. 2011.

MCLUHAN, Marshall. **Os meios de comunicação como extensões do homem**. 20 ed. São Paulo: Cultrix, 2005.

SONTAG, Susan. **Sobre fotografia**. 5ed. São Paulo: Companhia das letras, 2004.

TIBURI, Marcia. Pós-verdade, pós-ética. In: **Ética e pós-verdade**. Porto Alegre: Dunblinense, 2017.

Apêndice A

Figura 1: Activity #euamojampa in 8/16/2018 11:05 am — 8/23/2018 10:25.

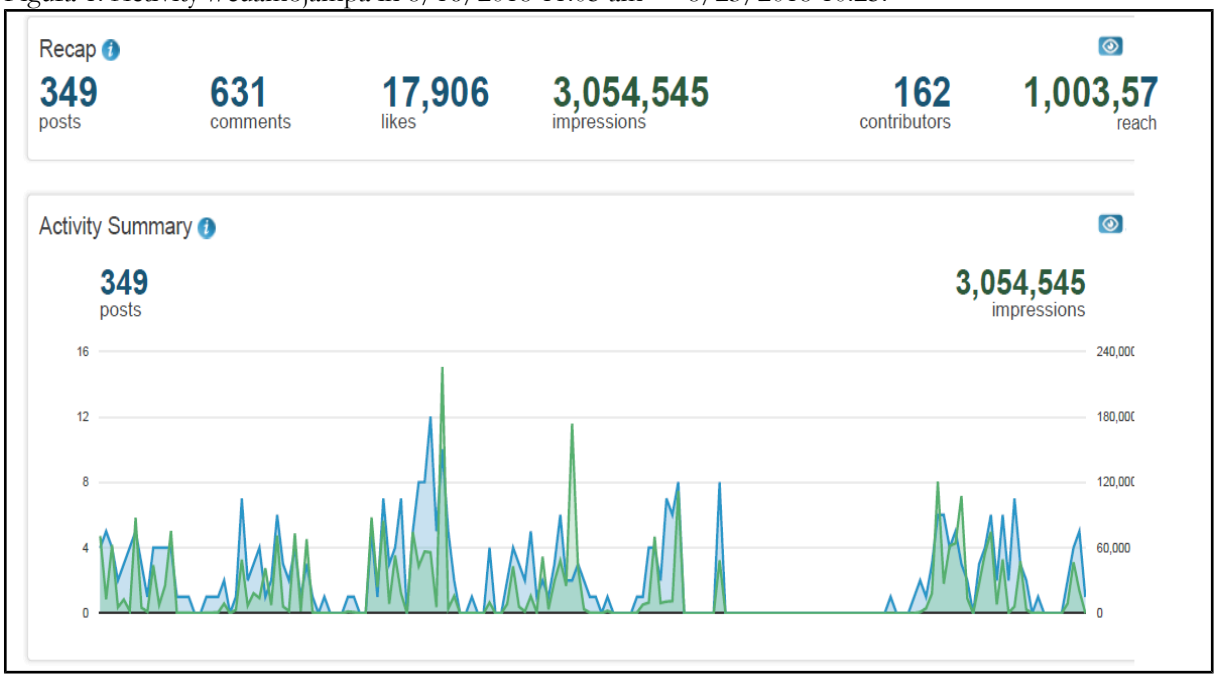

Fonte: Hashtracking, 2018.

Figura 2: Engagement Rate #euamojampa in 8/16/2018 11:05 am — 8/23/2018 10:25.

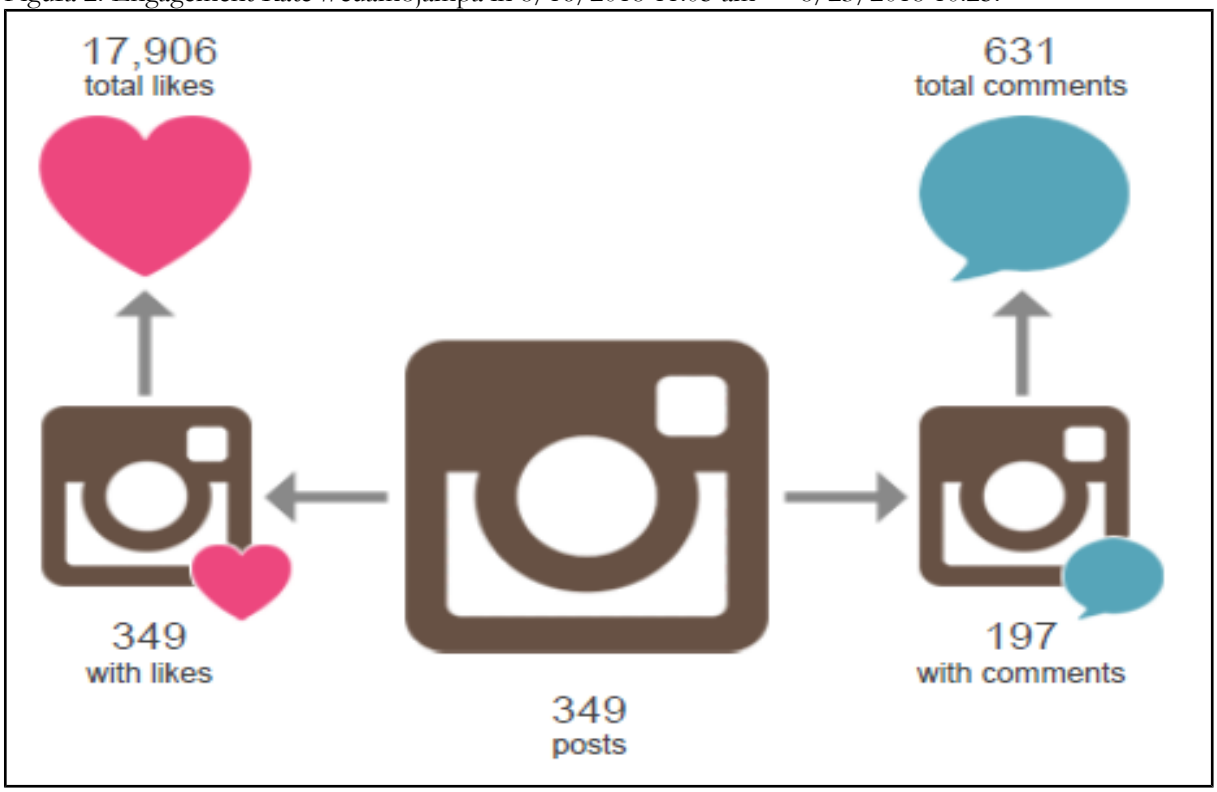

Fonte: Hashtracking, 2018.

Figura 3: Buzz Words subjects #euamojampa in 8/16/2018 11:05 am — 8/23/2018 10:25.

Fonte: Hashtracking, 2018.

Figura 4: Geolocation of posts #euamojampa in 8/16/2018 11:05 am — 8/23/2018 10:25.

Fonte: Hashtracking, 2018.

Vídeo da apresentação

Título: Letreiros e amores: uma estratégia informacional para existir no Instagram.

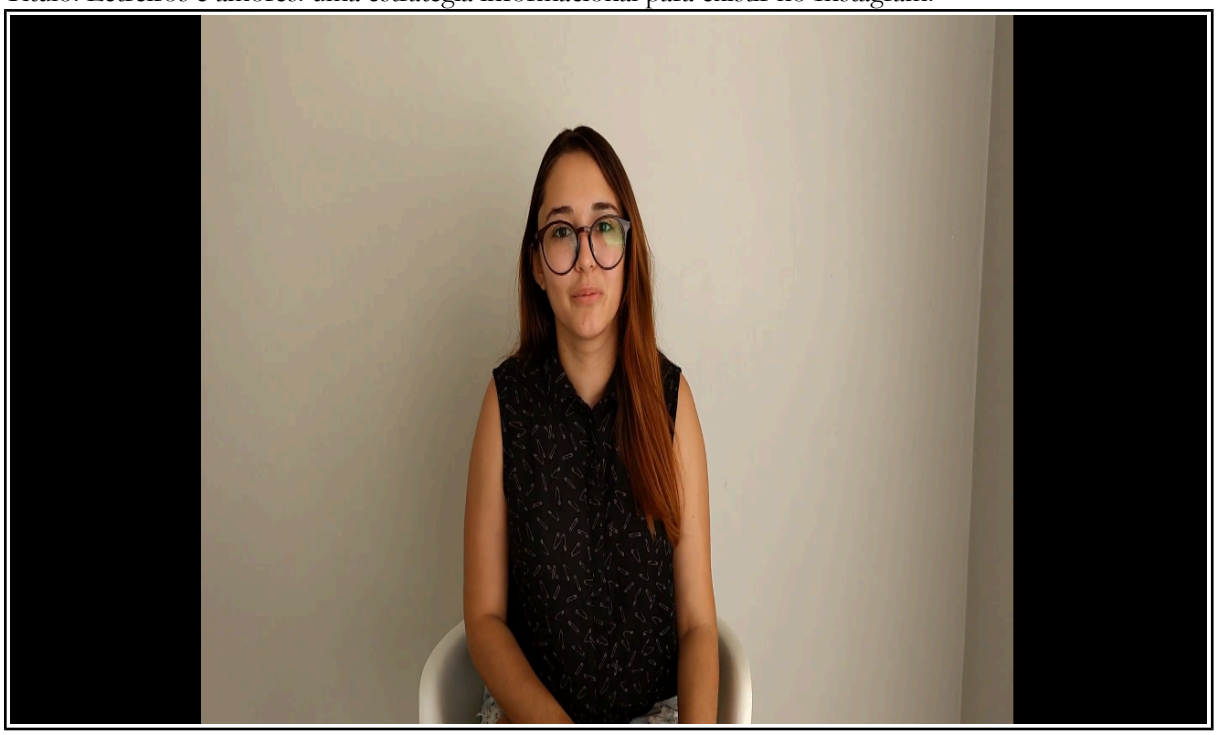

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=9

Transcrição da apresentação

O nosso trabalho faz parte do II Workshop Informações, Dados e Tecnologia, realizado na Universidade Federal da Paraíba no ano de 2018, intitulado de "Letreiros e amores: uma estratégia informacional para existir no Instagram".

Os letreiros construídos nas cidades parelha a sua função estrutural, parelha a sua função na cidade, considerando como estratégia que as cidades de hoje em dia fazem para existir no universo online, principalmente a partir de redes sociais como o Instagram. Então nossa questão é: qual a função informacional desses letreiros em tempo de instagram?

Apresentando a nossa pesquisa considerando o objeto é de cunho bibliográfico, buscando traçar um histórico sobre o objeto e algumas questões sobre ele, como também uma investigação exploratória descritiva com o uso da ferramenta hashtag para coleta de dados.

Nosso trabalho começa discutindo sobre redes sociais, como espaço de sociabilidade, redes sociais que existiam, por exemplo, nas calçadas das casas e agora tem essa conotação virtual no espaço online como as redes sociais Facebook, Twitter, Instagram, são algumas redes que a gente pode referenciar.

Nossa centralidade é o Instagram, então pensando em um universo que constitui dentro da rede social do Instagram, é importante a gente pensar como um espaço também com valores de sociabilidade como os nossos, onde hoje em dia estar no Instagram, estar em uma rede social é não só uma função de existência, uma forma não só de estar lá mas também de acumular um capital simbólico, como a partir dos "likes" a partir das visualizações dos nossos canais. Então a gente parte deste princípio e vamos tendo outros autores, reflexões, acerca do universo da fotografia, ela muda a sociedade de tal maneira, que tem que ser pensado que tudo na sociedade passa a ser fotografável. Tudo potencialmente pode virar uma fotografia e em tempos de redes sociais como o Instagram, que é uma rede social predominante uma rede de fotografia, uma rede social que o canal fotografia é uma das estratégias, mas que ganham uma visibilidade de acesso muito maior que seriam na nossa sala de casa, nos espaços que normalmente colocarem as nossas fotografias.

Então neste sentido, a gente constrói uma reflexão acerca desses valores sociais e pensa que esse surto de letreiros sociais que surgem em algumas cidades, nas mais diversas cidades pequenas e grandes, eles estão lá não apenas para aprender uma questão digamos assim da própria cidade, uma questão física do universo urbano, mas também para fazer com que aqueles espaços existam nessa disputa de capital simbólico que é o Instagram, a partir dos interesses que as cidades têm, considerando seus letreiros.

Para compreender melhor nosso objeto, precisamos falar sobre a Instagramlização das coisas. Letreiros como o de Hollywood, Amsterdam e Cancún se tornaram figurinhas dos álbuns dos fotógrafos viajantes, os letreiros foram inesgotavelmente fotografados. Com potencialização digital e a popularização do Instagram, pessoas, coisas e lugares, foram se transformando em espaços digitais, como por como, por exemplo, restaurantes e bares que modificaram seus ambientes e cenários para se tornarem potencialmente fotografáveis, ou seja, Instagramaveis, com o objetivo de serem publicados nos mais diversos perfis.

Neste sentido para uma análise de caso, nós consideramos o letreiro da cidade de João Pessoa, que fica localizado no busto de Tamandaré, é um letreiro "Eu Amo Jampa" criado em 2015, para tanto nós usamos a ferramenta hashtag a fim de fazer uma análise quantitativa sobre a circulação deste material no Instagram.

Este diagnóstico é um subsídio para justificar a importância da gente pensar os letreiros enquanto fluxo informacional, principalmente em tempos de Instagram, talvez eles deem projeções muito mais importantes para as cidades no universo online do que no próprio espaço físico que não sendo fotogravável.

Diante do que foi exposto, acreditamos, que os letreiros das cidades são estratégias de informação eficientes para que os lugares sejam registrados online e consequentemente na rede Instagram.

Identificação de entidades destaque para a melhoria da Análise de Vínculos

Roberto Zaina[a], Vinicius Faria Culmant Ramos[b] e Gustavo Medeiros de Araujo[c]

Resumo: A proposta do presente estudo é a de desenvolver um método para a identificação automática de elementos relevantes em Relatórios de Inteligência Financeira. Então, inicialmente, explicamos a adoção de uma métrica específica para indicar suspeitas de lavagem de dinheiro, que é o uso de interpostas pessoas, comumente conhecidas como "laranjas". Uma forma de se identificar tais pessoas é verificar coincidências de pessoas como empregadas e sócias de empresas que operaram entre si. Detalhamos a metodologia adotada, que se iniciou com a tabulação das operações financeiras do Relatório de Inteligência Financeira e depois com a coleta dos dados relativos aos quadros societários das empresas e dos vínculos empregatícios dos sócios. Posteriormente, foi explicado o desenvolvimento de um script de extração, tratamento e carga dos dados em um programa de Business Intelligence, que trouxe como resultado uma tabela com as prováveis interpostas pessoas. Esta tabela, juntamente com os demais dados, foi importada para um programa de análise de vínculos, que permite visualizar os dados por meio de grafos. O resultado final foi um grafo que destaca as pessoas suspeitas de serem "laranjas" e, desta forma, facilita a análise do investigador.

Palavras-chave: Lavagem de Dinheiro. Interpostas Pessoas. Grafos.

Featured entity identification to improve the Link Analysis

Abstract: The purpose of the present study is to develop a method for the automatic identification of relevant elements in Financial Intelligence Reports. So we initially explained the adoption of a specific metric to indicate suspicions of money laundering, which is the use of interposed people, commonly known as "oranges". One way to identify such people is to verify coincidences of people as employees and members of companies that operated among themselves. We detail the methodology adopted, which began with the tabulation of the financial operations of the Financial Intelligence Report and then with the collection of the data related to the companies' corporate staff and the employment relationships of the members. Subsequently, we explained the development of a script extracting, processing and loading the data into a Business Intelligence program, which resulted in a table with the likely interposed people. This table, along with the other data, was imported into a link analysis program, which allows visualizing the data through graphs. The final result was a graph highlighting the people suspected of being "oranges" and, thus, facilitates the researcher's analysis.

Keyword: Money laundry. Interposed People. Graphs.

a Universidade Federal de Santa Catarina (UFSC). E-mail: rzaina@gmail.com. ORCID: https://orcid.org/0000-0002-1887-5951. Currículo: http://lattes.cnpq.br/2044312005144633

b Universidade Federal de Santa Catarina (UFSC). E-mail: v.ramos@ufsc.br. ORCID: https://orcid.org/0000-0002-8319-743X. Currículo: http://lattes.cnpq.br/0442142220296336

c Universidade Federal de Santa Catarina (UFSC). E-mail: gustavo.araujo@ufsc.br. ORCID: https://orcid.org/0000-0003-0572-6997. Currículo: http://lattes.cnpq.br/2609254559240670

1 Introdução

A investigação criminal é um conjunto de diligências que visam apurar a existência de um crime (BRAZ, 2013). Na investigação de lavagem de dinheiro o que se busca apurar é se bens ou valores foram ocultados ou dissimulados para esconder sua origem criminosa.

Pela lavagem, o dinheiro proveniente de atividades ilícitas é introduzido nos circuitos financeiros legais, por meio de complexas operações que promovem a desvinculação da origem ilícita dos valores oriundos do crime (OLIVEIRA, 2012).

Uma das principais informações usadas nas investigações de lavagem é o Relatório de Inteligência Financeira (RIF), que é produzido pelo Conselho de Controle de Atividades Financeiras (COAF) e é resultado da análise de operações suspeitas de lavagem ou de financiamento do terrorismo (COAF, 2017).

No âmbito policial, as metodologias geralmente usadas para análise do RIF dependem totalmente da interpretação humana, mesmo quando se utilizam ferramentas tecnológicas.

Isto porque as ferramentas são usadas meramente para a visualização dos dados como, por exemplo, em planilhas ou diagramas, ficando o investigador encarregado de identificar o que é relevante no RIF, baseado em seu conhecimento e experiências profissionais.

2 Objetivos

O objetivo geral deste estudo é desenvolver um método para a identificação automática de elementos relevantes em Relatórios de Inteligência Financeira.

E os objetivos específicos são:

1. Estabelecer, com base em tipologias de lavagem de dinheiro, as métricas para a definição de elementos relevantes;
2. Executar programa para processar as métricas nos dados tabulados;
3. Executar programa para visualizar grafos sobre os dados processados.

3 Procedimentos Metodológicos

A metodologia utilizada está esquematizada na Figura 1, que ilustra as etapas desde o estudo de tipologias de lavagem de dinheiro até chegar a uma lista com CPFs de prováveis interpostas pessoas.

Como ilustra a etapa 1, o primeiro passo foi selecionar um critério para estabelecer relevância de elementos contidos nos Relatórios de Inteligência Financeira.

A escolha do critério foi norteada pelas tipologias descritas na publicação do artigo "Casos & Casos" (COAF, 2016), que descreve 61 modus operandi de lavagem de dinheiro sobre ativos financeiros gerados por crimes como corrupção, desvio de recursos públicos, contra o sistema financeiro, sonegação fiscal, tráfico de drogas e tráfico de pessoas.

Pela análise das tipologias foi selecionado um fenômeno que aparece em vários tipos de crimes, especialmente os de lavagem de dinheiro, que é a utilização de interpostas pessoas, também conhecidas como "laranjas",

As interpostas pessoas são as que têm sua documentação usada para, por exemplo, de forma fictícia, participar de empresas, abrir contas bancárias ou firmar contratos. Podem ser pessoas que

não têm consciência de tais fatos ou, então, têm conhecimento mas permitem em troca de alguma vantagem.

Um indicativo de interposta pessoa em uma empresa, é quando primeiro ela era empregada e depois se torna sócia na mesma empresa ou em outra empresa relacionada.

Este foi o critério selecionado para o presente estudo, ou seja, identificar pessoas que constam como empregadas e sócias de uma mesma empresa ou de empresas relacionadas. Neste caso, para estabelecer o que são "empresas relacionadas" decidimos usar aquelas que constam em operações financeiras de um mesmo RIF.

Na etapa 2 foram estabelecidos os critérios para identificação de interpostas pessoas, o passo seguinte é a estruturação dos dados, a partir de um RIF pré-selecionado e com suas informações anonimizadas, por conta do sigilo policial.

Já na etapa 3, por ser o RIF disponibilizado em formato PDF, não estruturado, foi necessário tabular suas informações em planilha. O resultado desta tabulação foi gravado como "OPERACOES_RIF.xlsx".

Figura 1: Metodologia usada.

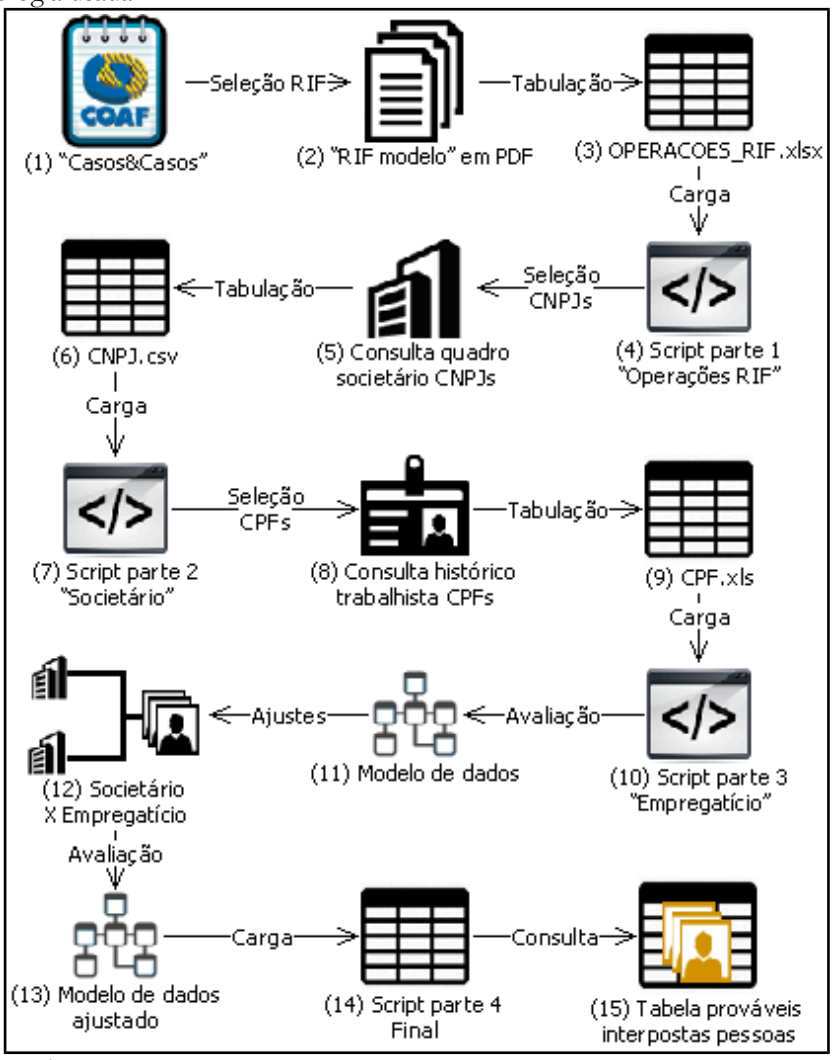

Fonte: Elaborado pelos autores.

Considerando que os dados do RIF precisariam ser cruzados com outros dados de sistemas corporativos, decidiu-se usar uma ferramenta de business intelligence (BI). O programa escolhido foi o Qlikview[47].

Na etapa 4 foi criado um documento no Qlikview denominado "RIF interpostas pessoas.qvw". Depois, os dados da planilha com as operações do RIF foram carregados pelo script [OPERACOES RIF] (Apêndice A).

Após esta primeira carga de dados, foi necessário avaliar quais os dados ainda seriam necessários para conseguir identificar as possíveis interpostas pessoas.

Em síntese, seriam necessários dados relativos aos quadros societários das empresas relacionadas no RIF e, em seguida, os vínculos empregatícios dos seus sócios.

As etapas 5 e 6 ilustram que CNPJs foram consultados em sistema interno e que o resultado foi estruturado em um arquivo denominado "CNPJ.csv".

Posteriormente, na etapa 7, o arquivo foi carregado pelo script [SOCIETARIO] (Apêndice A). Nas etapas 8 e 9 foram levantados os vínculos empregatícios dos sócios das empresas e o resultado foi estruturado em um arquivo "CPF.xls".

Após isto, conforme a etapa 10, a arquivo "CPF.xls" foi carregado no Qlikview com o seguinte script [EMPREGATICIO] (Apêndice E).

Por meio das cargas acima descritas todos os dados necessários para a identificação das prováveis interpostas pessoas foram carregados: operações financeiras do RIF, quadros societários das empresas e vínculos empregatícios dos sócios destas empresas.

A etapa 11 mostra que, pela forma como foram carregados, os dados ficaram gravados no arquivo do Qlikview em 5 tabelas, conforme o a Figura 2.

Figura 2: Modelo de dados da 1ª carga.

Fonte: Elaborado pelos autores.

47 Ver mais em: https://www.qlik.com/pt-br

Considerando que o objetivo é identificar pessoas que foram empregadas e sócias de empresas citadas no RIF, a próxima ação é verificar se existem registros de CNPJs coincidentes nas tabelas "EMPREGATICIO" e "SOCIETARIO", conforme a etapa 12. Após o emprego de várias funções diferentes, foi escolhida a inner join, que traz como resultado somente os registros existentes em ambas as tabelas. Feito isto, o modelo de dados ficou conforme a Figura 3.

Figura 3: Modelo de dados da 2ª carga.

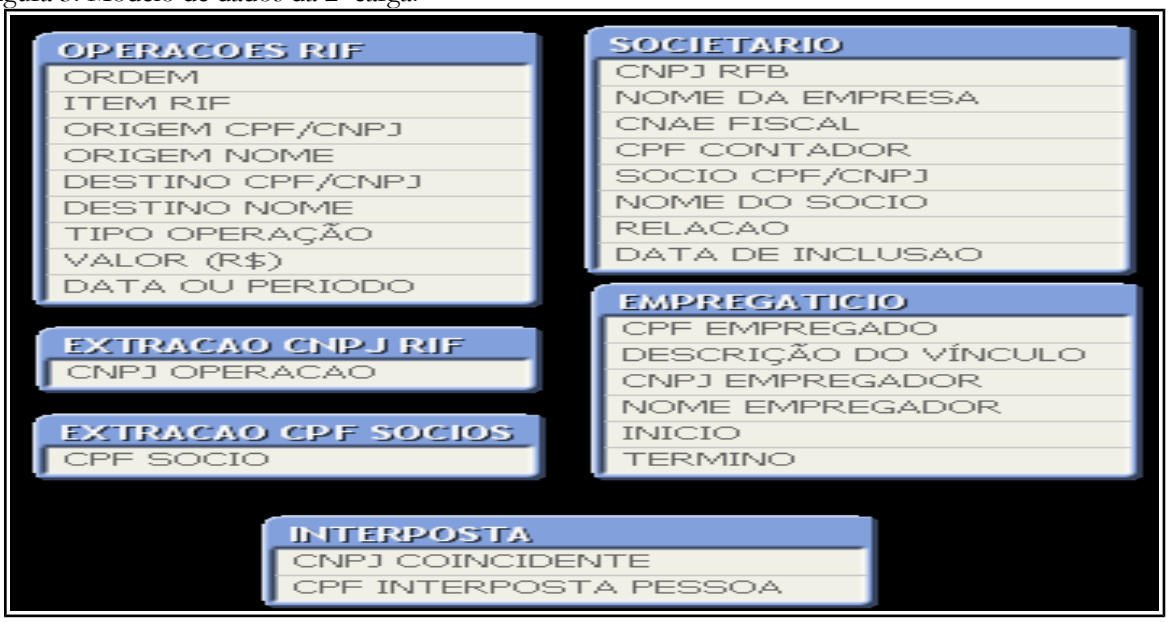

Fonte: Elaborado pelos autores.

Na etapa 13 foi estabelecido o relacionamento entre as tabelas, usando como chave o CPF das pessoas. Com estas alterações o modelo de dados ficou como mostra a Figura 4.

Figura 4: Modelo de dados da 3ª carga.

Fonte: Elaborado pelos autores.

Com este modelo de dados finalmente é possível a criação de objetos para consultar as prováveis interpostas pessoas, conforme as etapas finais 14 e 15.

4 Resultados

O principal resultado foi o desenvolvimento de um método, por meio do programa Qlikview, que permite carregar e cruzar dados tabulados dos Relatórios de Inteligência Financeira e, ainda, dos dados das empresas que realizaram operações suspeitas e de seus sócios.

Como resultado do processamento do script nos dados do "RIF modelo", chegou-se ao Quadro 1, que mostra 04 CPFs suspeitos de serem de interpostas pessoas.

Quadro 1: CPFs dos possíveis "laranjas".

CPF INTERPOSTA PESSOA
311133387
2288877700
34545476598
52627277933

Fonte: Elaborado pelos autores.

Este resultado pode ser aproveitado em outros programas usados pelos investigadores, especialmente os que permitem a "análise de vínculos", que mostram os dados por meio de grafos.

A análise de vínculos é o "retrato gráfico de dados investigativos, feito para facilitar o entendimento de grandes volumes de dados, possibilitando aos investigadores entender as conexões entre indivíduos" (COADY, 1985 apud SPARROW, 1991, tradução nossa).

O resultado da importação foi o grafo mostrado de forma ilustrativa na Figura 5 e com mais resolução no Apêndice B.

Para a criação dos grafos utilizamos o programa IBM i2 Analyst's Notebook[48], que permite importar dados tabulados. Foram importadas as planilhas usadas neste estudo e se definiu como um dos atributos das pessoas se ela é uma "interposta pessoa", conforme o resultado da Tabela 1. Por enquanto, somente pela análise visual da Figura 5 não se consegue perceber imediatamente quais são as prováveis interpostas pessoas.

Contudo, considerando que foi definido um atributo "interposta pessoa", é possível utilizar um recurso de "formatação condicional" para destacar tais ocorrências no grafo.

Para tanto, foi escolhida uma formatação que automaticamente dobrará o tamanho do ícone e colocará uma moldura na cor laranja nas entidades que tiverem o atributo "interposta pessoa".

O resultado da aplicação desta formatação condicional é o grafo mostrado de forma ilustrativa na Figura 6 e com mais resolução no Apêndice C.

Ao compararmos as Figuras 5 e 6 é possível verificar que o destaque das entidades do tipo "interposta pessoa" melhora a visualização do grafo, automatiza a detecção de prováveis "laranjas" e, consequentemente, facilita a análise do Relatório de Inteligência Financeira.

48 Ver mais em: www.ibm.com/br-pt/marketplace/analysts-notebook

Figura 5: Ilustração de grafo inicial.

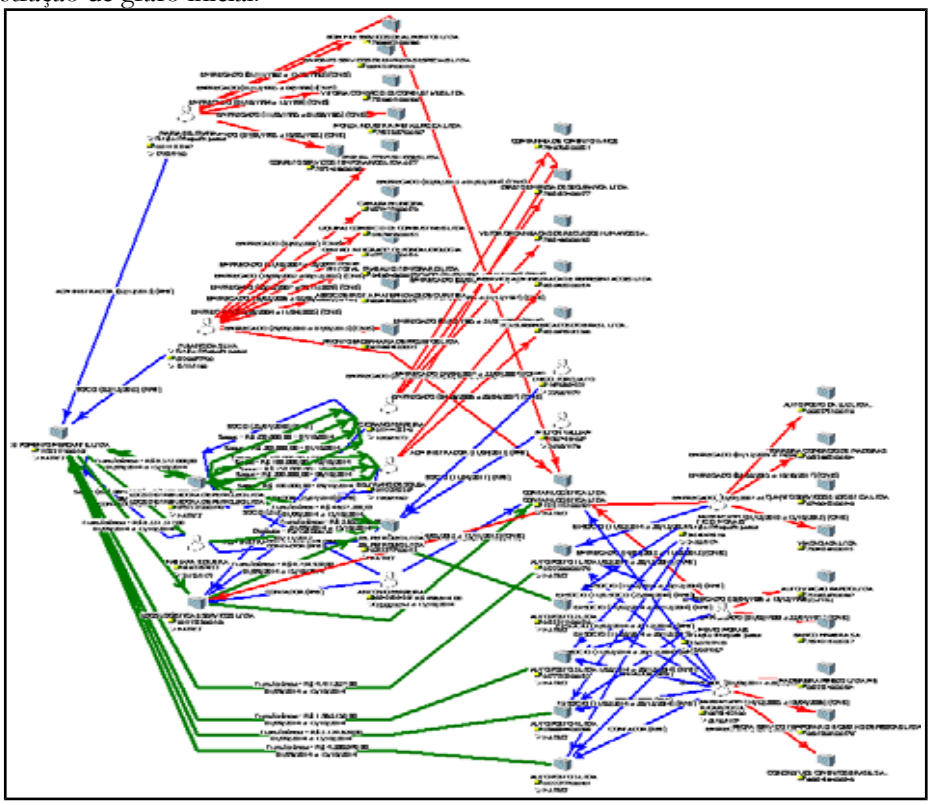

Fonte: Elaborado pelos autores.

Figura 6: Ilustração de grafo destacando as prováveis interpostas pessoas (“laranjas”).

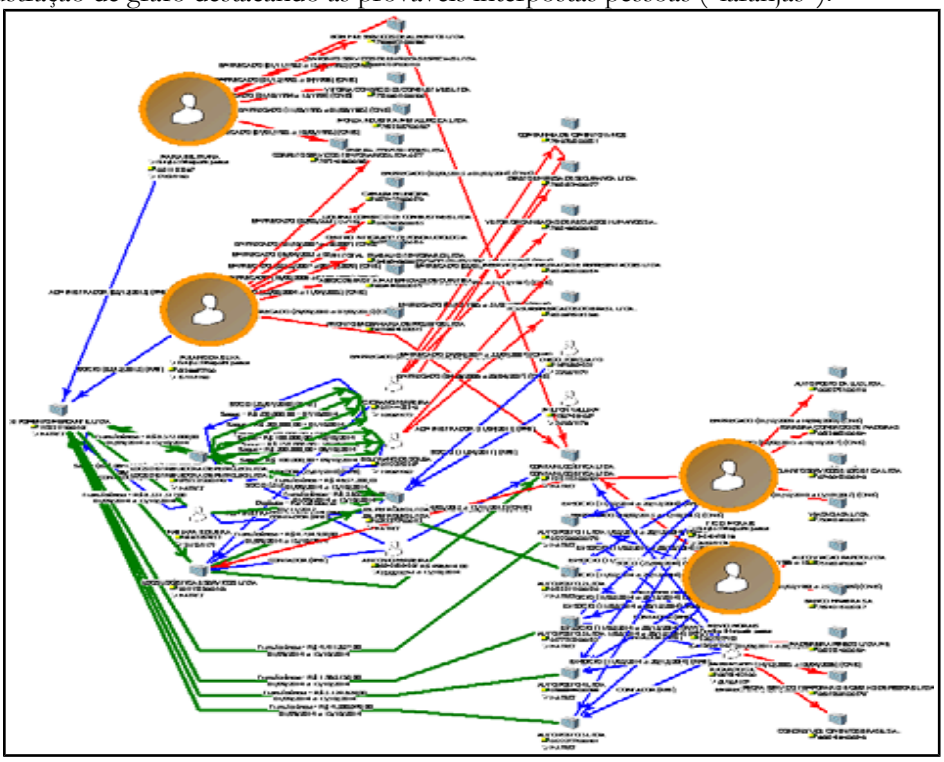

Fonte: Elaborado pelos autores.

4 Considerações Finais

Com o objetivo de identificar elementos relevantes em Relatórios de Inteligência Financeira, decidiu-se verificar a possibilidade de reconhecer automaticamente possíveis "laranjas" como sócias de empresas que realizam operações suspeitas.

Então, foi desenvolvido um método que envolve a coleta, a estruturação, o tratamento e a análise de dados relativos a Relatórios de Inteligência Financeira (RIF), quadros societários e vínculos trabalhistas.

Este estudo considerou uma tipologia bem específica, que é a utilização de prováveis interpostas pessoas ("laranjas") para o cometimento de crimes e especificamente quando tais pessoas coincidem como empregadas e sócias de certas empresas.

Como principal resultado está o grafo mostrado na Figura 6, que ao destacar as entidades dos prováveis "laranjas" melhora significativamente a visualização do grafo e amplia instantaneamente a compreensão por parte do investigador que analisa o RIF.

Outra evolução pretendida é a utilização de técnicas de aprendizado de máquina, com a possibilidade de ensinar o computador a identificar os elementos mais relevantes em Relatórios de Inteligência Financeira.

O método ora desenvolvido mostra como a configuração de métricas em determinadas tecnologias auxilia no processamento dos dados e na análise das informações do RIF.

Consequentemente, podem ampliar a capacidade investigativa dos órgãos que atuam em investigações de lavagem de dinheiro e de outros crimes relacionados.

A partir deste estudo pretendemos evoluir para estabelecer métricas de identificação de outras tipologias de lavagem de dinheiro e, assim, desenvolver novos métodos automáticos para análise de RIF.

Referências

ANGELONI, Maria T.; REIS, Eduardo S. Business Intelligence como Tecnologia de Suporte a Definição de estratégias para melhoria da qualidade do ensino. Enanpad, 2006. Disponível em: www.anpad.org.br/enanpad/2006/dwn/enanpad2006-adid-0815.pdf. Acesso em 29/09/2018.

BRASIL. COAF – Conselho de Controle de Atividades Financeiras. Relatório de Atividades, 2017. Disponível em: http://www.fazenda.gov.br/centrais-de-conteudos/publicacoes/relatorio-de-atividades/arquivos/relatorio-de-atividades-coaf-2017.pdf/view. Acesso em: 29/09/2018.

BRASIL. LEI No 9.613, DE 3 DE MARÇO DE 1998. Disponível em: http://www.planalto.gov.br/ccivil_03/LEIS/L9613.htm. Acesso em: 29/09/2018.

BRASIL. Ministério da Fazenda. Conselho de Controle de Atividades Financeiras. Casos & Casos – Coletânea Completa de Casos Brasileiros de Lavagem de Dinheiro. Brasília:

COAF, 2016. Disponível em: https://www.fazenda.gov.br/centrais-de-conteudos/publicacoes/casos-casos/arquivos/casosecasos_coletanea-completa_setembro2016.pdf . Acesso em: 29/09/2018.

BRAZ, José Alberto Campos. Investigação criminal. Leya, 2013.

FERRO JÚNIOR, Celso Moreira; DANTAS, George Felipe de Lima. A descoberta e a análise de vínculos na complexidade da investigação criminal moderna. 2006. Disponível em: http://www.egov.ufsc.br/portal/sites/default/files/anexos/13124-13125-1-PB.pdf. Acesso em: 03/06/2018.

OLIVEIRA, Tarsis Barreto. O bem jurídico-penal no crime de lavagem de dinheiro. Revista Esmat, [S.l.], v. 4, n. 4, p. 269-299, set. 2012. ISSN 2447-9896.

SPARROW, Malcolm K. The application of network analysis to criminal intelligence: An assessment of the prospects. Social networks, v. 13, n. 3, p. 251-274, 1991.

Apêndice A – Script final do documento "RIF_interpostas_pessoas.qvw"

/* Script criado para carga dos seguintes dados: - Operações do RIF; - Quadros societários das empresas que realizaram operações; - Vínculos empregatícios dos sócios das empresas que realizaram operações. */

// Configurações gerais do documento:

```
SET ThousandSep='.';
SET DecimalSep=',';
SET MoneyThousandSep='.';
SET MoneyDecimalSep=',';
SET MoneyFormat='R$ #.##0,00;-R$ #.##0,00';
SET TimeFormat='hh:mm:ss';
SET DateFormat='DD/MM/YYYY'; SET TimestampFormat='DD/MM/YYYY hh:mm:ss[.fff]';
SET FirstWeekDay=6;
SET BrokenWeeks=1;
SET ReferenceDay=0;
SET FirstMonthOfYear=1;
SET CollationLocale='pt-BR';
SET MonthNames='jan;fev;mar;abr;mai;jun;jul;ago;set;out;nov;dez';
SETLongMonthNames='janeiro;fevereiro;março;abril;maio;junho;julho;agosto;setembro;outubro;novembro;dezemb
ro';
SET DayNames='seg;ter;qua;qui;sex;sáb;dom';
SET LongDayNames='segunda-feira;terça-feira;quarta-feira;quinta-feira;sexta-feira;sábado;domingo';
```

// Carga de dados das Operações do RIF:

```
[OPERACOES RIF]:
LOAD
ORDEM,
[ITEM RIF],
KeepChar([ORIGEM CPF/CNPJ],'0123456789') as [ORIGEM CPF/CNPJ],
[ORIGEM NOME],
KeepChar([DESTINO CPF/CNPJ],'0123456789') as [DESTINO CPF/CNPJ],
[DESTINO NOME],
[TIPO OPERAÇÃO],
[VALOR (R$)],
[DATA OU PERIODO]
FROM *OPERACOES_RIF*.xlsx (ooxml, embedded labels, table is Plan1);
```

// Extração dos CNPJs que realizaram operações no RIF:

```
[EXTRACAO CNPJ RIF]:
LOAD
IF(LEN([ORIGEM CPF/CNPJ])>11,[ORIGEM CPF/CNPJ]) as [CNPJ OPERACAO]
Resident [OPERACOES RIF];
LOAD
IF(LEN([DESTINO CPF/CNPJ])>11,[DESTINO CPF/CNPJ]) as [CNPJ OPERACAO]
Resident [OPERACOES RIF];
```

// Carga de dados dos Quadros societários das empresas que realizaram operações:

```
SOCIETARIO:
LOAD
KeepChar(CNPJ,'0123456789') as [CNPJ SOC],
[NOME DA EMPRESA],
[CNAE FISCAL],
```

```
KeepChar([CPF CONTADOR],'0123456789') as [CPF CONTADOR],
KeepChar([SOCIO CPF/CNPJ],'0123456789') as [SOCIO CPF/CNPJ],
[NOME DO SOCIO],
RELACAO, [DATA DE INCLUSAO],
KeepChar([SOCIO CPF/CNPJ],'0123456789') as [CPF CHAVE],
Left(KeepChar(CNPJ,'0123456789'),8) as [RAIZ CNPJ SOC]
FROM *CNPJ*.csv (txt, codepage is 1252, embedded labels, delimiter is ';', msq, filters(
Remove(Row, RowCnd(CellValue, 1, StrCnd(null)))));

// Extração dos CPFs dos sócios das empresas que realizaram operações no RIF:

[EXTRACAO CPF SOCIOS]:
LOAD
IF(LEN([SOCIO CPF/CNPJ])<12, [SOCIO CPF/CNPJ]) as [CPF SOCIO]
Resident SOCIETARIO;

// Carga de dados dos vínculos empregatícios dos sócios das empresas que realizaram operações:

EMPREGATICIO:
LOAD
KeepChar([IDENTIFICADOR ORIGEM],'0123456789') AS [CPF EMPREGADO],
[DESCRIÇÃO DO VÍNCULO],
KeepChar([IDENTIFICADOR DESTINO],'0123456789') AS [CNPJ EMPREGADOR],
[NOME EMPREGADOR],
INICIO,
TERMINO,
KeepChar([IDENTIFICADOR ORIGEM],'0123456789') as [CPF CHAVE],
Left(Right(000&KeepChar([IDENTIFICADOR DESTINO],'0123456789'),14),8) as [RAIZ CNPJ
EMPREGADOR] FROM *CPF*.xls (biff, embedded labels, table is Plan1$);

// Identificação de "Interpostas Pessoas": CPFs relacionados à CNPJs que constam nas tabelas "SOCIETARIO" e
"EMPREGATICIO"

INTERPOSTAS:
LOAD [RAIZ CNPJ SOC] as [CNPJ COINCIDENTE]
Resident SOCIETARIO;
Inner Join LOAD[RAIZ CNPJ EMPREGADOR] as [CNPJ COINCIDENTE],
[CPF EMPREGADO] as [CPF INTERPOSTA PESSOA],
[CPF EMPREGADO] as [CPF CHAVE]
Resident EMPREGATICIO;
```

Apêndice B – Grafo inicial (detalhamento da Figura 5).

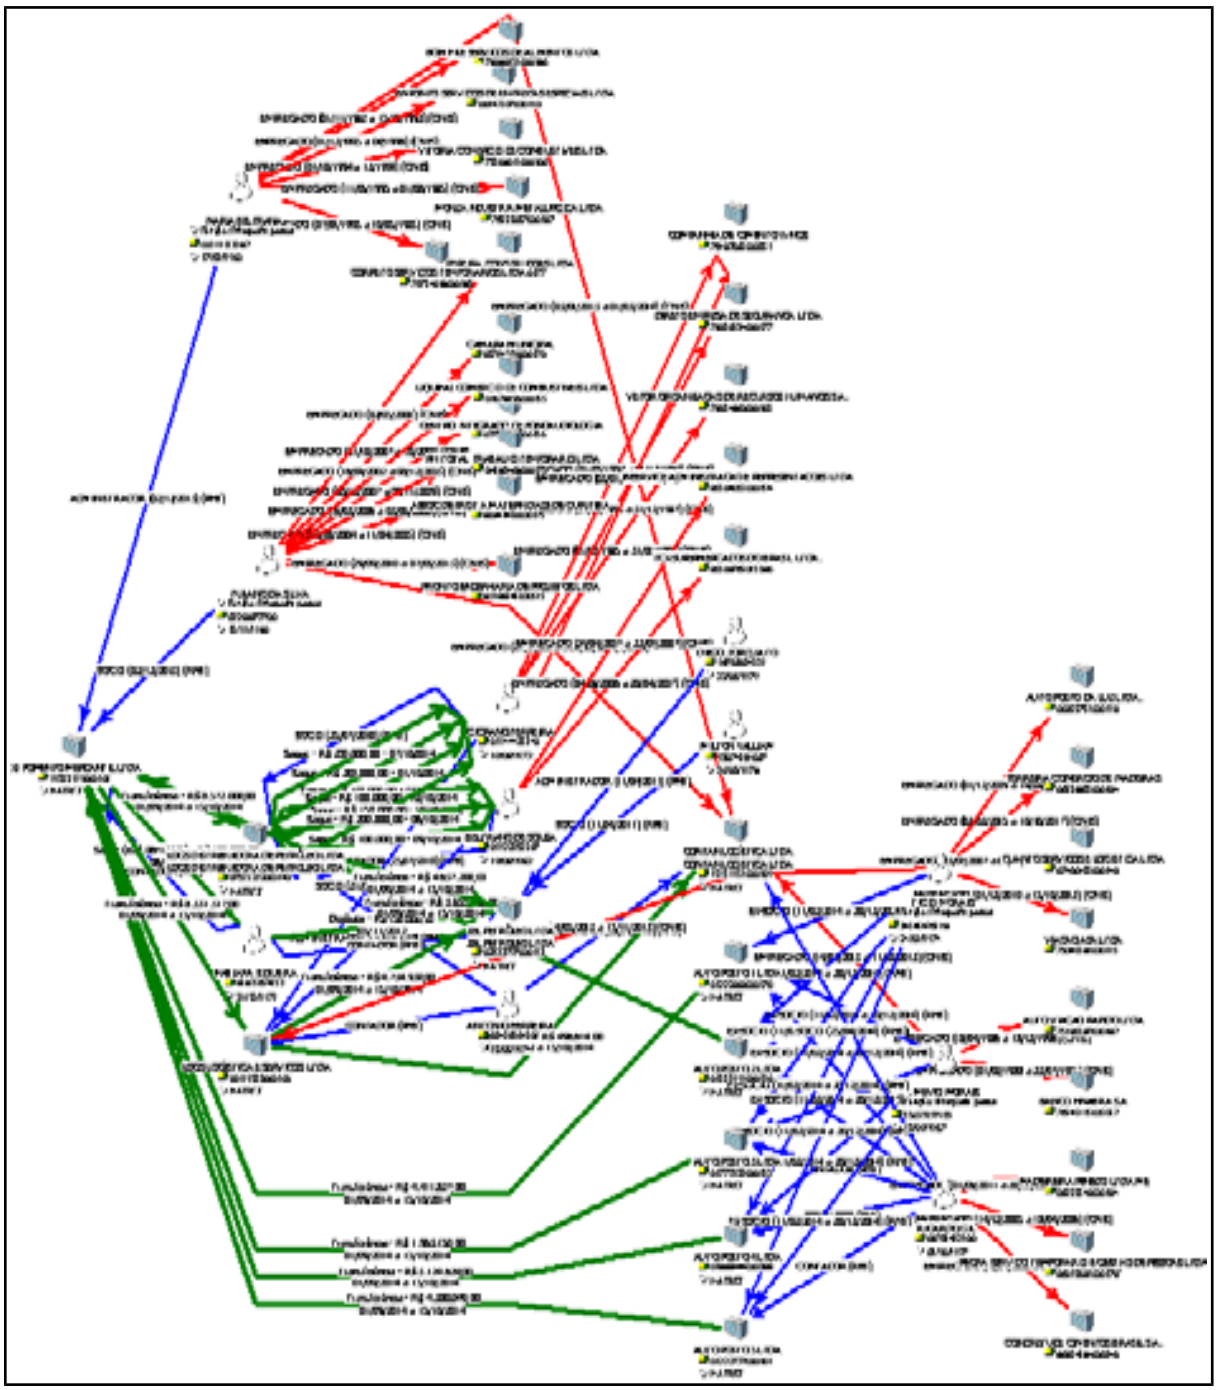

Apêndice C – Grafo destacando as prováveis interpostas pessoas (detalhamento Figura 6).

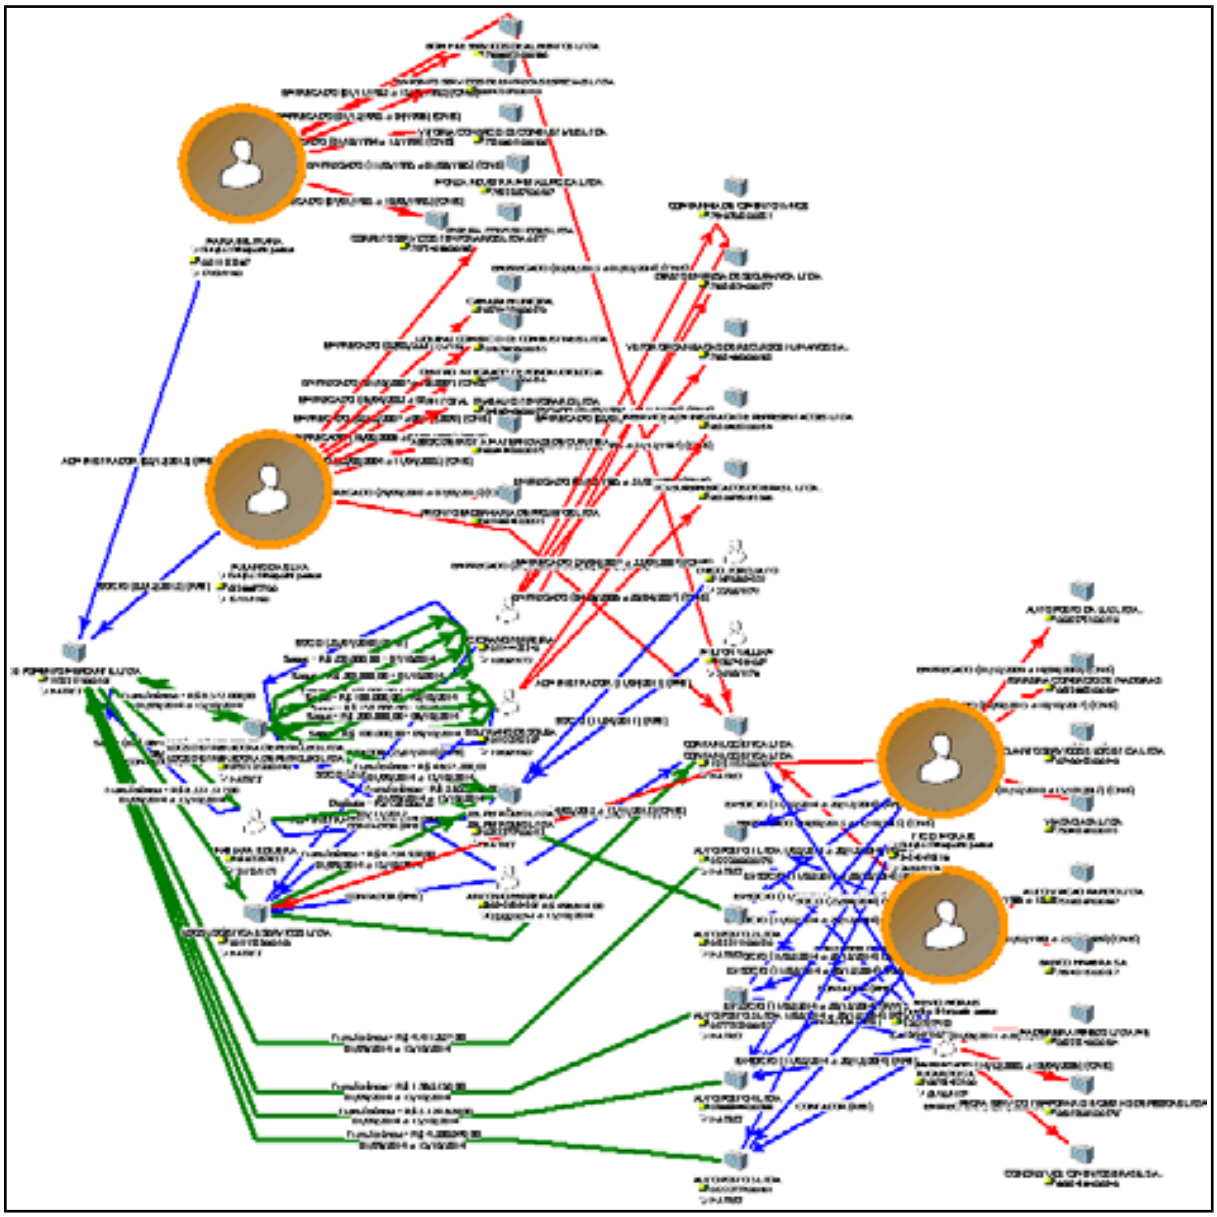

Vídeo da apresentação

Título: Identificação de entidades destaque para a melhoria da Análise de Vínculos.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=10

Transcrição da apresentação

Esse trabalho é a identificação de entidades destaques para a melhoria da análise de vínculos, o qual foi realizado na Universidade Federal de Santa Catarina pelo mestrando Roberto Zaína, sob orientação dos professores Professor Dr. Gustavo Medeiros de Araújo e Professor Dr. Vinícius Faria Ramos Culmant.

Esse trabalho foi aceito no WIDAT 2018 no 2º Workshop de Informação, Dados e Tecnologia.

Bom esse trabalho está sobre a motivação de lavagem de dinheiro e análise de relatórios de inteligência financeira que são relatórios produzidos pela COAF.

De forma resumida existem algumas operações financeiras que são identificadas como suspeitas, essas operações financeiras identificados como suspeitos pelas entidades financeiras são comunicadas a COAF, onde avalia essa atividade suspeita e gera um relatório chamado relatório de inteligência financeira e esse relatório é enviado pelas autoridades, no caso, por exemplo a polícia federal.

Bom, há alguns problemas em relação à geração desses relatórios entre as informações analisadas e investigação de lavagem de dinheiro. Essas informações são descritas no relatório de inteligência financeira e comumente tem centenas de registros de operações financeiras envolvendo dezenas de pessoas e empresas.

Há um grande volume de dados para se investigar e fazer análise no relatório de inteligência financeira. Há um número grande de dados e uma complexidade de informações e de conexões entre entidades bastante grande.

Então o pessoal desenvolveu uma metodologia para poder fazer a identificação desses dados. O pessoal viabilizou a implementação das ferramentas de análise para fazer a busca, a coleta e o tratamento dos dados. No relatório de inteligência financeira a pessoa faz a seleção de um RIF modelo depois a estruturação das operações suspeitas no RIF uma seleção de alguns CNPJ, a consulta do quadro societário das empresas e posterior estruturação dessa a planilha, seleção de CPF bem societário, consulta de vínculos trabalhistas entre sócios de um posterior estruturação da planilha, a normalização dos dados originais, porque as informações são sigilosas e é necessário que os dados estejam normalizados.

Como resultado do uso de ferramentas de análise de vínculo em operações RIF, toma um fluxo resumido da metodologia esse RIF ele é tabulado, ou seja, as informações tabuladas em um relatório texto são analisadas manualmente e são transformadas em tabelas, essas tabelas são diagramadas pela ferramenta de análise de grafo. É possível realizar consultas de cnpj e fazer a importação e tabulação dessas consultas e cnpj e agregar mais informações a esses grafos.

Inicialmente a gente teria na primeira diagramação um diagrama desse tipo com as informações retiradas do RIF e cada informação é possível fazer cruzamento com outras bases de dados e aumentar essa rede de informações.

Então, essa rede de informação é aumentada realizado consultas pelo CPF, CNPJ das empresas aumentando aí o tamanho do grafo, ou seja, essas linhas em verde são as linhas do RIF original e as outras linhas em vermelho, azul e preto são informações de outras bases de dados, como a Receita Federal por exemplo.

Dessa forma, é um grafo bastante grande e dependendo do tamanho do RIF esse grafo pode aumentar muito mais se essa complexidade de informação que o agente tem que trabalhar e tentar identificar os principais suspeitos e é aqui um trabalho para tentar fazer uma identificação e criar um modelo para identificar quais são as entidades destaque.

Nesse caso a partir de um modelo na COAF de operações financeiras suspeitas em operações financeiras, por exemplo, se há sócios entre empresas que foram empregados de uma empresa e dona de uma outra empresa e as transações financeiras entre essas empresas, isso é considerado pela COAF como modelo de suspeita.

Então, a gente pegou esse modelo como suspeita, aí realizamos junto com uma ferramenta de BI uma relação dessas entidades e depois essa relação um carregamento na ferramenta de análise de vínculo.

Nós usamos a Business Intelligence para poder melhorar nessa questão da visualização das entidades destaque. A ferramenta que foi utilizado foi a QlikView que é uma ferramenta de BI comum e traz todas as informações relevantes de uma ferramenta de Business Intelligence e também a gente consegue incluir scripts específicos no qual a gente realizou esses scripts seguindo modelos de operações suspeitas da COAF a gente criou esses scripts para poder é levantar quais que são um suspeito seguindo aquele modelo da COAF.

Então, a metodologia seguindo o modelo da COAF é feita uma tabulação do modelo RIF com as operações, essas operações são carregadas por um script específicos para aquele tipo de modelo da COAF, no caso a métrica utilizada sócios e empregadas esse resultado dessas métricas são tabulados é feito uma consulta de históricos trabalhistas em outras bases. É feito um ajuste de métricas para poder pegar principalmente quem é o sócio da empresa e empregado em outra empresa a e esses caras. O resultado desses scripts são levados para a ferramenta de BI para identificar o que chama de prováveis interpostas pessoas.

Esses modelos de dados foram utilizados da primeira carga, modelo de dados da segunda carga de operações do RIF de societários e esse modelo é usado pra poder fazer aquela identificação da interposta das pessoas destaques as entidades destaques depois de feito essa consulta com script a gente tira de algumas pessoas que são as pessoas importantes mais importantes ali dentro de todo aquele grafo que apresentamos no começo.

Do grafo inicial que a gente tem a partir das informações do RIF cruzada com outras informações de outras bases como base da receita federal, então a gente pega as informações do livro como se fosse da receita federal faz uma análise de bussines inteligente guiada pelo modelo da COAF e assim conseguimos destacar as principais pessoas dentro desse grafo, ou seja, isso aqui é realmente um resultado que facilita o agente a identificar aquelas pessoas suspeitas e iniciar uma investigação.

Como conclusão a análise de vínculos é uma metodologia importante e bastante eficiente para detecção de processos envolvidos em operações financeiras ilícitas.

Entretanto, grafo é muito grande e dependendo da quantidade de bases agregada dificulta bastante a visualização, então para melhorar a identificação, direto no coração as pessoas que são os mais responsáveis dentro dessa rede criada é desenvolver um método baseado no modelo da

COAF para poder identificar os principais atuantes os principais modus dentro daquele modelo para fazer a identificação. Qualquer pergunta contactar.

Slides da apresentação

Título: Identificação de entidades destaque para a melhoria da Análise de Vínculos.

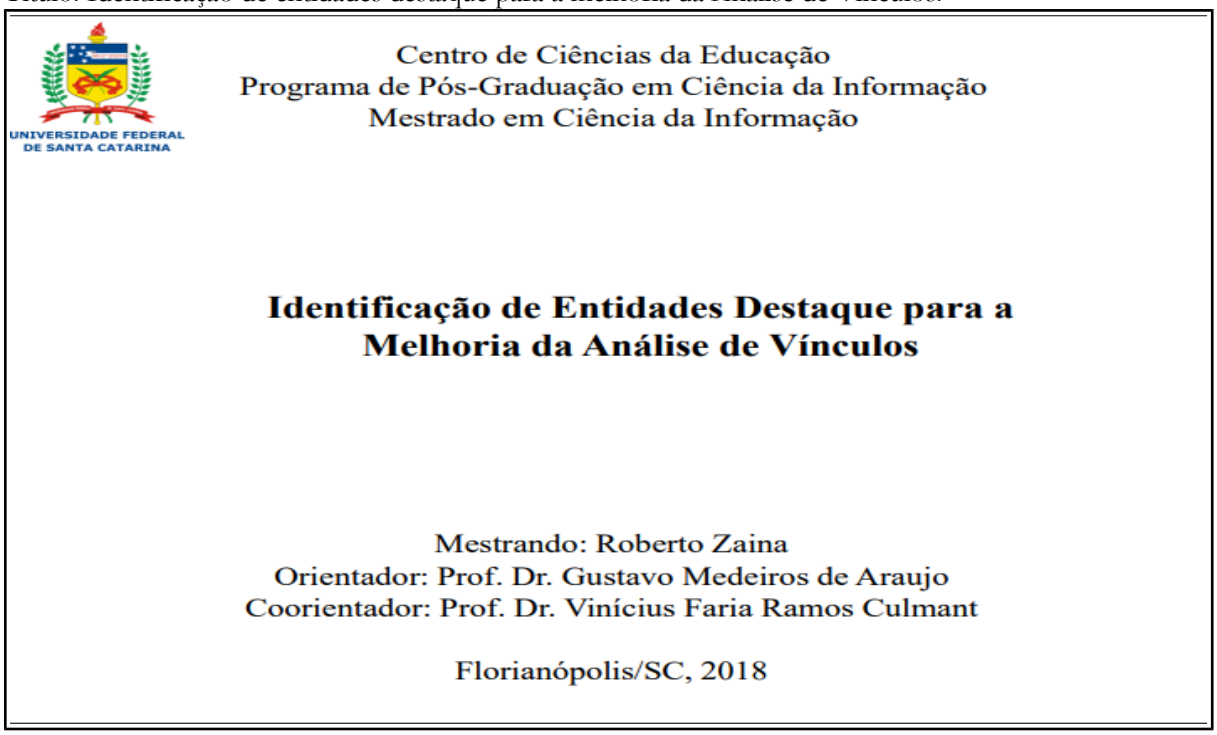

UNIVERSIDADE FEDERAL DE SANTA CATARINA

Centro de Ciências da Educação
Programa de Pós-Graduação em Ciência da Informação
Mestrado em Ciência da Informação

Identificação de Entidades Destaque para a Melhoria da Análise de Vínculos

Mestrando: Roberto Zaina
Orientador: Prof. Dr. Gustavo Medeiros de Araujo
Coorientador: Prof. Dr. Vinícius Faria Ramos Culmant

Florianópolis/SC, 2018

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=10

Humanidades Digitales: visualização da produção científica

Mirelys Puerta Diaz[a], *Edgar Bisset Alvarez*[b] *e Silvana Aparecida Borsetti Gregório Vidotti*[c]

Resumo: O presente artigo aborda as Humanidades Digitais através da produção científica publicada nas bases de dados científicas nacionais e internacionais. No estudo, utilizou-se o método da bibliometria aplicada para identificar a produção científica indexada sobre o objeto pesquisado. A pesquisa é descritiva e quali-quantitativa. Utilizou-se como fonte, a Base de dados de Periódicos em Ciência da Informação e documentos recuperados com o Google Acadêmico através do software Publish or Perish, visando verificar a produção teórica das HD e as métricas de interesse. Aplicou-se para a visualização das métricas, o aplicativo RAW Graphs, baseado na web, trata-se de um framework de código aberto utilizado para a visualização de dados complexos. Com isso, foi possível constatar que no Brasil, os estudos sobre humanidades digitais na Ciência da Informação foram publicados somente a partir do ano 2014, enquanto no contexto internacional, as publicações já vinham sendo publicadas desde aproximadamente o ano 2000.

Palavras-chave: Humanidades digitais. Visualização de dados. Análise métrica da produção científica.

Digital Humanities: visualization of scientific production

Abstract: This article addresses the Digital Humanities through the scientific production published in national and international scientific databases. In the study, the applied bibliometric method was used to identify the indexed scientific production on the researched object. The research is descriptive and qualitative-quantitative. It was used as source, the Database of Periodicals in Information Science and documents retrieved with Google Academic through the software Publish or Perish, to verify the theoretical production of the HD and the metrics of interest. It was applied to the visualization of the metrics, the web-based RAW Graphs application, it is an open-source framework used for the visualization of complex data. With this, it was possible to verify that in Brazil, studies on digital humanities in Information Science were only published as from 2014, while in the international context, publications had been published since about 2000.

Keyword: Digital Humanities. Data Visualization. Metric Analysis of Scientific Production.

a Universidade Estadual Paulista (UNESP). E-mail: mireblue18@gmail.com. ORCID: https://orcid.org/0000-0002-2312-2540. Currículo: http://lattes.cnpq.br/4493369991075218

b Universidade Federal de Santa Catarina (UFSC). E-mail: edgar.bisset@ufsc.br. ORCID: https://orcid.org/0000-0002-5388-5944. Currículo: http://lattes.cnpq.br/6259487897392078

c Universidade Estadual Paulista (UNESP). E-mail: vidotti@marilia.unesp.br. ORCID: https://orcid.org/0000-0002-4216-0374. Currículo: http://lattes.cnpq.br/7390573927636069

1 Introdução

Nos últimos anos têm se observado um crescente avanço das pesquisas que envolvem as Humanidades Digitais (HD), o que possibilitou defini-las como campo disciplinar, perfil formativo ou como saber ligado ao movimento do livre acesso. E, esta produção científica também se ampliou a nível internacional, e, de tal maneira, que na opinião de Rodríguez-Yunta (2012), atualmente as HD podem ser consideradas como uma topic tag de significado ambíguo, cujo exponencial crescimento deve motivar a reflexão dos profissionais da Ciência da Informação.

Deste modo, esta área de estudo tem se convertido em verdadeira fonte para o desenvolvimento de projetos apontados como ponto de encontro entre as Ciências da Computação, o Ambiente digital e as Ciências Humanas e Sociais, neste sentido, Ortega (2013, p.18):

> "[…] as Humanidades Digitais podem ser definidas como o espaço de convergência entre as ciências da computação, meio digital e as disciplinas humanísticas na busca de novos modelos interpretativos e novos paradigmas de conhecimento em concordância com as transformações operadas no âmbito da sociedade digital."

Entretanto, apesar da crescente popularidade deste campo, não existe consenso no que diz respeito às suas bases teórico-epistemológicas, muito menos, quanto à construção de uma definição que resuma a essência do que são as HD, como aliás, fica evidenciado, no levantamento feito por Jason Heppler[49] em 2015, que reuniu cerca de 800 definições diferentes sobre o que são as HDs.

2 Objetivos

O presente trabalho tem como objetivo geral apresentar o comportamento da produção científica das Humanidades Digitais[50], a partir da análise dos dados coletados nas bases de dados Google Acadêmico e a Base de dados de Periódicos em Ciência da Informação (BRAPCI).

3 Procedimentos Metodológicos

A presente pesquisa descritiva combina as abordagens qualitativa e quantitativa e Aplica-se a análise métrica da produção científica para alcançar seu objetivo.

A coleta de dados foi realizada sem limitações na data de publicação na BRAPCI, e através do buscador Google Acadêmico utilizando o software Publish or Perish (PoP), onde limitou-se a busca aos anos 2000-2017. O uso de PoP se justifica porque a interface nativa de Google Acadêmico não é muito adequada para análises bibliométricas.

Por meio da coleta na BRAPCI, se pretende identificar, além da presença das Humanidades Digitais nas pesquisas da Ciência da Informação brasileira, o foco das suas abordagens. Com esse fim a busca foi realizada em língua portuguesa ("humanidades digitais"). O Método de pesquisa aplicado para a análise dos dados é o de análise bibliométrica da produção científica.

A coleta, processamento e análise de dados em Google Académico, foi apoiada pelo uso da ferramenta PoP, que recupera e faz análise de citações acadêmicas obtidas de fontes como

49 https://github.com/hepplerj/whatisdigitalhumanities/blob/master/dayofquotes_full.csv
50 Digital humanities, em sua versão em inglês.

Google Acadêmico. Da variedade de fontes de dados que usa PoP (por exemplo, Crossref, Google Acadêmico, Web of Science y Scopus) foi escolhida a do Google Acadêmico (GA) porque é considerada uma útil ferramenta para pesquisa de literatura científica de forma ampla, em muitas disciplinas e fontes acadêmicas (artigos revisados por pares, teses, livros, resumos e artigos de editoras acadêmicas, sociedades profissionais, repositórios de pré-impressão, repositórios de universidades e outras organizações acadêmicas). O PoP facilita o cálculo de várias métricas (HARZING, 2011), das quais, foram selecionadas para análise, as especificadas no Quadro 01.

Quadro 1:

Métrica	**Descrição**
Anos de publicação	Primeiro e mais recente ano de publicação encontrado nos resultados atualmente selecionados.
Anos de citação	Número de anos, desde o primeiro ano encontrado nos resultados atualmente selecionados até o ano da consulta (geralmente o ano corrente).
Documentos	Número total de resultados atualmente selecionados.
Quantidade de citações recebidas	A soma das contagens de citações em todos os resultados atualmente selecionados.
Promédio de citações por ano (citações/ano)	Número médio de citações por ano (ou seja, citações / anos de citação)
Promédio de citações por documento (Citações / documento)	A soma das contagens de citações em todos os artigos, dividida pelo número total de artigos. A média e o modo também são calculados e disponibilizados separadamente.
Citações / autor	Número médio[51] de citações por autor
Artigos / autor	Número médio[52] de artigos por autor.
Autores /documento	Número médio de autores[53] por artigo.
h-index[54]	Índice H de Hirsch
Índice g[55]	Índice g de Egghe

Fonte: Research in International Management, 2017.

Os resultados obtidos com o programa ficam disponíveis na tela e também podem ser copiados para a área de transferência do Windows, para colar em outros aplicativos ou salvar em

51 Calculado da seguinte forma: Para cada trabalho, sua contagem de citações é dividida pelo número de autores para esse artigo, para devolver a contagem de citações normalizada por autor para o artigo. As contagens de citações normalizadas são então somadas em todos os artigos para fornecer o número de citações por autor sobre o conjunto de resultados.

52 Calculado da seguinte forma: Para cada trabalho, a contagem de 1 / autor é calculada para fornecer a contagem de autor normalizada para o trabalho. A contagem normalizada dos autores é então resumida em todos os artigos para fornecer o número de artigos por autor.

53 Calculado como a soma do autor conta em todos os artigos, dividido pelo número total de artigos. A média e o modo também são calculados e disponibilizados separadamente.

54 Métrica que mede o impacto cumulativo da publicação de um pesquisador, observando a quantidade de citações que seu trabalho recebeu. O índice h foi proposto por J.E. Hirsch no ano 2005.

55 O índice g é um índice para quantificar a produtividade na ciência, com base no registro de publicação (uma métrica em nível de autor). O índice é calculado com base na distribuição de citações recebidas pelas publicações de um determinado pesquisador, de tal forma que dado um conjunto de artigos classificados em ordem decrescente do número de citações que eles receberam, o índice g é o maior número único de tal forma que o topo g artigos recebidos juntos pelo menos g 2 citações.

vários formatos de saída (vector graphic (svg), image (png), data model (json)) para futura referência ou análise posterior. Sendo que, a capacidade de exportar o código embutido em SVG e o modelo de dados JSON é compatível com essa abordagem aberta, o que permite explorar novos usos para esses produtos, facilitando o surgimento de novos métodos de visualização dos dados inseridos.

Aplicou-se para a visualização dos dados resultantes da coleta com o PoP, o aplicativo baseado na web, RAWGraphs[56]; um framework de código aberto utilizado para a visualização de dados complexos, desenvolvido no Laboratório de Pesquisa DensityDesign (Politecnico di Milano), cria visualizações baseadas em vetores personalizados da biblioteca d3.js. O RAWGraphs funciona com valores separados por delimitador (ou seja, arquivos csv e tsv), bem como, com textos copiados e colados de outros aplicativos (por exemplo, Microsoft Excel, TextWrangler, TextEdit). E, com base no formato svg, as visualizações podem ser facilmente importadas e editadas com aplicativos de gráficos vetoriais (ou seja, Adobe Illustrator, Inkscape, entre outros) para refinamentos adicionais ou diretamente incorporadas em páginas da web. Sendo que, o aplicativo Inskcape foi utilizado para melhorar a aparência dos gráficos gerados pelo aplicativo web RAWGraphs.

RAWGraphs surge como uma das ferramentas mais favoráveis para usar tanto em termos de características operacionais quanto características funcionais para a visualização de dados (ATWOOD e REZNIK-ZELLEN, 2018, p18).

Neste estudo foram utilizados as seguintes visualizações do RAWGraphs:

- Gráfico de Dispersão (Scatter Plot): facilita criar Círculos aninhados para representar hierarquias e comparar valores. Essa visualização é particularmente eficaz para mostrar a proporção entre elementos através de suas áreas e posição dentro de uma estrutura hierárquica.
- Círculo Packing: Círculos aninhados permitem representar hierarquias e comparar valores. Essa visualização é particularmente eficaz para mostrar a proporção entre elementos através de suas áreas e sua posição dentro de uma estrutura hierárquica.
- Treemap: essa visualização é útil para ver o peso das categorias pertencentes a uma estrutura hierárquica.

Foram identificadas como limitações do presente estudo, erros ou omissões referente ao uso do PoP no Google Acadêmico, as quais são mais frequentes do que no Scopus e no Web of Science. O uso do programa requer a limpeza da lista de publicações obtidas na busca, eis que, também coletou registros que não correspondem com a estratégia de busca. Além disso o Google Scholar limita seus resultados a 1000 registros, os quais são classificados por número de citações recebidas, portanto, os 1000 coletados pelo PoP são os resultados mais citados, sendo assim omitidos muitas publicações que ainda não foram citadas.

56 O projeto, liderado e mantido pelo Laboratório de Pesquisas DensityDesign (Politecnico di Milano) foi lançado publicamente em 2013 e é considerado como uma das ferramentas mais importantes no campo da visualização de dados.

4 Resultados

Verificou-se com o levantamento bibliográfico realizado na base de dados BRAPCI, que trouxe como resposta, apenas, um total de 9 documentos, dos quais, 5 foram publicados no ano de 2017, o raso aprofundamento da temática pela comunidade acadêmica no Brasil.

Sendo que, o principal foco das pesquisas desenvolvidas no cenário brasileiro abordam as humanidades digitais relacionadas à temáticas como, as tecnologias da informação e as comunicações, suas abordagens desde a Ciência da Informação, sua relação com a mediação, a web, a ciência aberta, entre outros que estão representados na nuvem de palavras da figura 1.

Figura 1: Visualização de nuvem de palavras-chave que aparecem nos documentos recuperados da Brapci,

Fonte: Elaboração própria por meio da ferramenta on-line wordart.com.

Já a busca realizada no Google Acadêmico através do software PoP, recuperou, um total de 883 documentos, dos quais 510 são livros e 373 artigos de periódicos.

Os trabalhos levantados para esta pesquisa tem as humanidades digitais e a sua relação com áreas como, as bibliotecas como principal foco, além disso, também as humanities computing, suas abordagens desde a História como ciência, sua relação com o fenômeno do big data.

Identifica-se na própria infraestrutura das pesquisas sobre as humanidades digitais, um interesse pela análise do seu próprio ecossistema, seus abordagens vinculados a web 2.0, Internet, as redes sociais, assim como as diversas ferramentas para sua visualização. Resulta interessante a quantidade de estudos de caso que descrevem os projetos em humanidades digitais que surgiram nos últimos 17 anos; ficando demonstrado e representados na nuvem de palavras da figura 2.

E, a partir dos documentos recuperados pelo PoP foi possível realizar a fase de normalização dos dados devido à necessária limpeza da lista de publicações obtidas na busca. Porém, os resultados das métricas foram os especificados no Quadro 2.

Figura 2: Visualização de nuvem de palavras que aparecem nos títulos dos documentos recuperados de PoP.

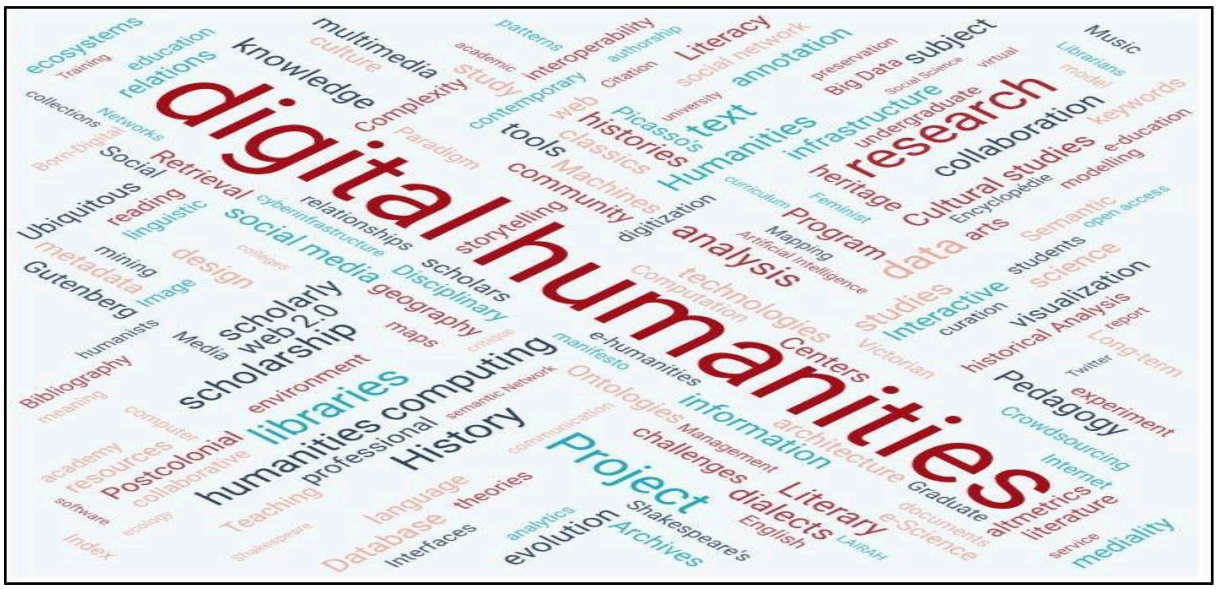

Fonte: Elaboração própria por meio da ferramenta on-line wordart.com.

Quadro 2: Resultado das métricas.

Métrica	Valor
Anos de publicação	2000-2017
Anos de citação	17
Total de documentos	883
Quantidade de citações recebidas	34454
Promédio de citações por ano (citações/ano)	453.34
Promédio de citações por documento (Citações / documento)	39.02
Citações / autor	29453.97
Artigos / autor	663.97
Autores / documento	1.80
h-index	74
Índice g	164

Fonte: Elaborado pelos autores.

Inicialmente se recuperaram um total de 1000 registros, sendo considerados para a análise 883, foram eliminados aqueles registros duplicados e que não respondiam à estratégia de busca definida, como se mostra no quadro 2.

O número promédio das citações por ano, é uma métrica muito útil que possibilita a avaliação do impacto geral dos autores que publicam sobre esta temática em específico. As métricas individuais de Citações / autores recuperados do PoP, apresenta o impacto de cada pesquisador, o que pode ser usado como uma alternativa aos h-index individuais. Um dado interessante que se percebe durante a análise, foi que os livros estão dentro as publicações com maior promédio de citação pelos autores.

A figura 3 demonstra que os autores que mais citações receberam (NK Hayles, L Manovich, R Kitchin, P Juola, entre outros) encontram-se no centro da visualização, o que significa que quanto maior o número de citações, maior raio de cobertura dos autores que estão localizados no centro do gráfico.

O ano de maior quantidade de publicações sobre humanidades digitais foi o 2012 com um total de 166 trabalhos; seguido do ano 2013 com 122 publicações e o 2014 com 103. Um fato interessante que nos últimos 3 anos diminuiu consideravelmente a produção científica de maior impacto sobre a temática segundo a fonte consultada em relação a anos anteriores. Do ano 2015 ao 2017 diminuiu a metade do total de publicações.

A figura 4 mostra a relação das dimensiones ano de publicação e o total de citas recebidas por ano. Quanto maior o número de citações maior raio de cobertura dos anos que estão localizados no gráfico. Essa visualização das métricas mencionadas denota, com excepção do ano 2011 e 2008, que os três anos mais produtivos foram os mais citados.

Figura 3: Visualização da métrica de autores e total de citações recebidas.

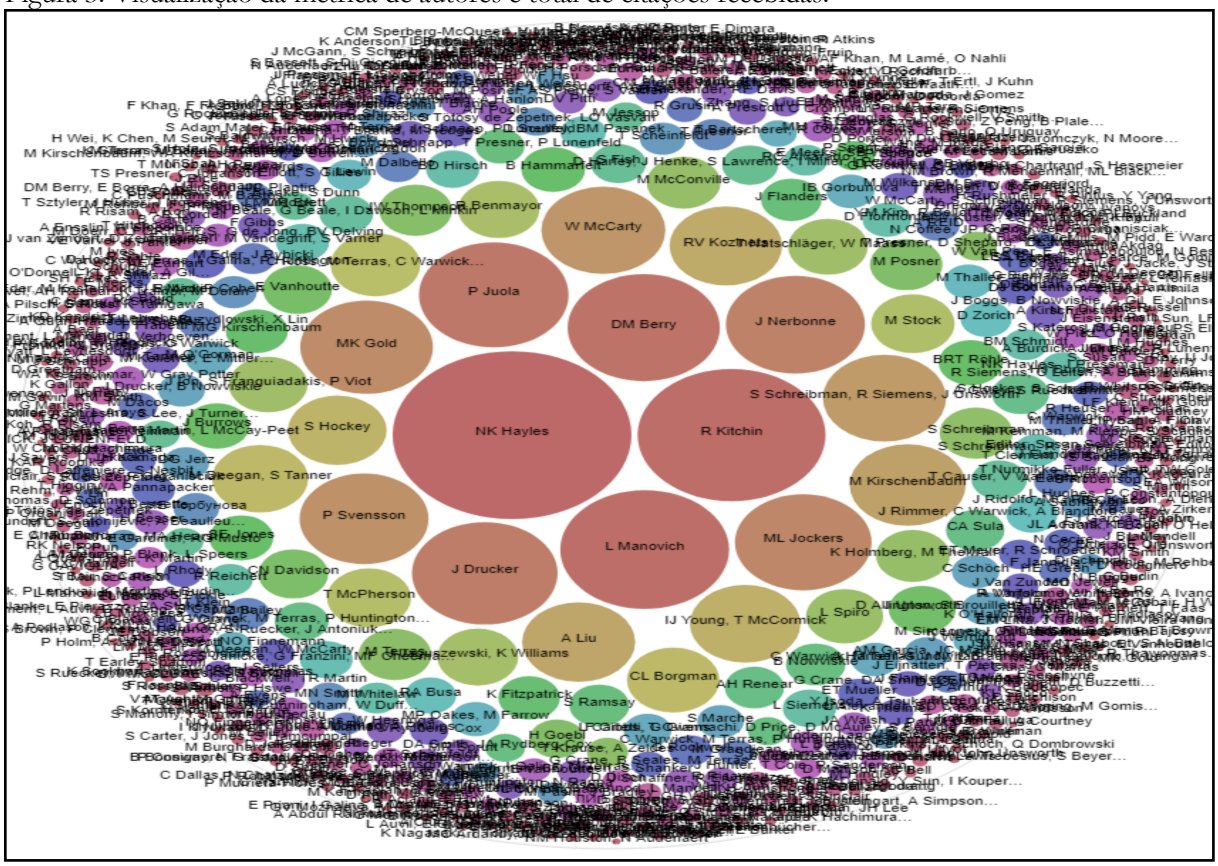

Fonte: Elaboração própria por meio da ferramenta RAWGraphs.

A visualização da figura 5 denota que, os 5 trabalhos mais citados não aparecem nas 10 primeiras posições do ranking do Google Acadêmico, dos quais o 50% deles são publicações do ano 2012. Uma relação detalhada dos dados em relação aos autores mais citados está listada abaixo:

- NK Hayles (citações= 762; ano= 2012; GSRank =848)

- NK Hayles (citações= 746; ano= 2007; GSRank =315)
- L Manovich (citações= 700; ano= 2011; GSRank =95)
- R Kitchin (citações= 682; ano= 2014; GSRank =542)
- P Juola (citações= 598; ano= 2008; GSRank =485)
- ML Jockers (citações= 543; ano= 2013; GSRank =861)

Figura 4: Visualização da métrica dos totais de produções científicas por ano.

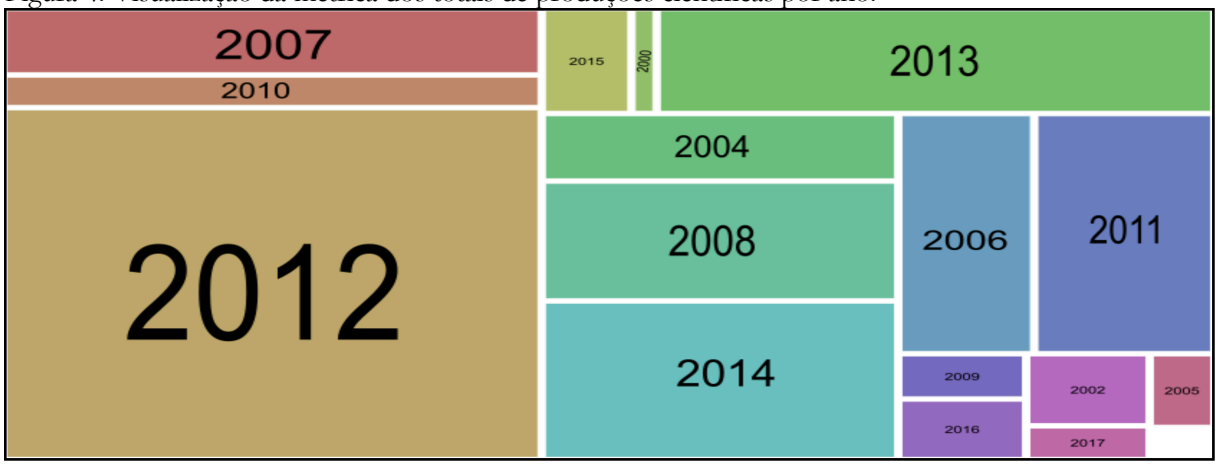

Fonte: Elaboração própria por meio da ferramenta RAWGraphs.

Figura 5: Visualização das métricas do total de citações recebidas pelos autores e o GSR (Google Scholar Rank).

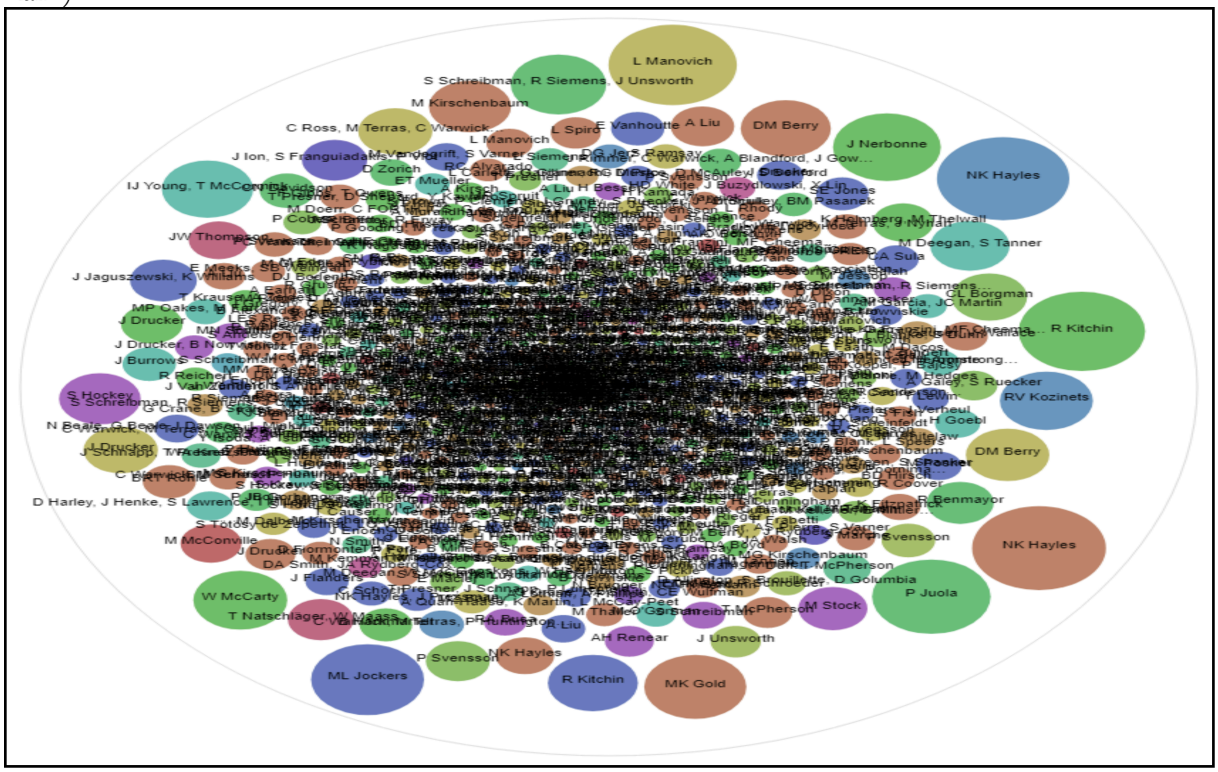

Fonte: Elaboração própria por meio da ferramenta RAWGraphs.

Identificou-se que somente o 25 % dos 10 primeiros resultados do Google Acadêmico estão em acesso aberto e disponíveis para a comunidade científica.

Essa visualização das métricas mencionadas, denota, que não necessariamente os artigos mais citados pelos autores (exemplo. Cuddon, Hayles e Röhle) são colocados nos primeiros 10 resultados da pesquisa feita pelos usuários no Google Acadêmico. Outro fato interessante é que, os autores com mais citações são os do ano 2012, como foi identificado na figura 3.

Também se verifica, que as publicações correspondentes a 2012 estão entre as mais citadas.

O gráfico da figura 6, mostra a correlação entre a dimensão da idade das publicações e o total de citações recebidas. O Eixo X= idade das publicações (0-18); Eixo Y= total de citações recebidas por autor (0-762); Tamanho rádio= GSRank (0-980); cor= autores).

No gráfico da Figura 6 a posição dos círculos que estão mais perto do Eixo Y são aqueles trabalhos que possuem menor tempo de publicação. Além disso, é preciso destacar que aquelas publicações que estão posicionadas mais perto do eixo Y, e que apresentam maior número de citações, coincidem com os trabalhos melhores posicionadas no GSRank.

Figura: 6 Visualização de métrica da idade das publicações e do total de citações recebidas.

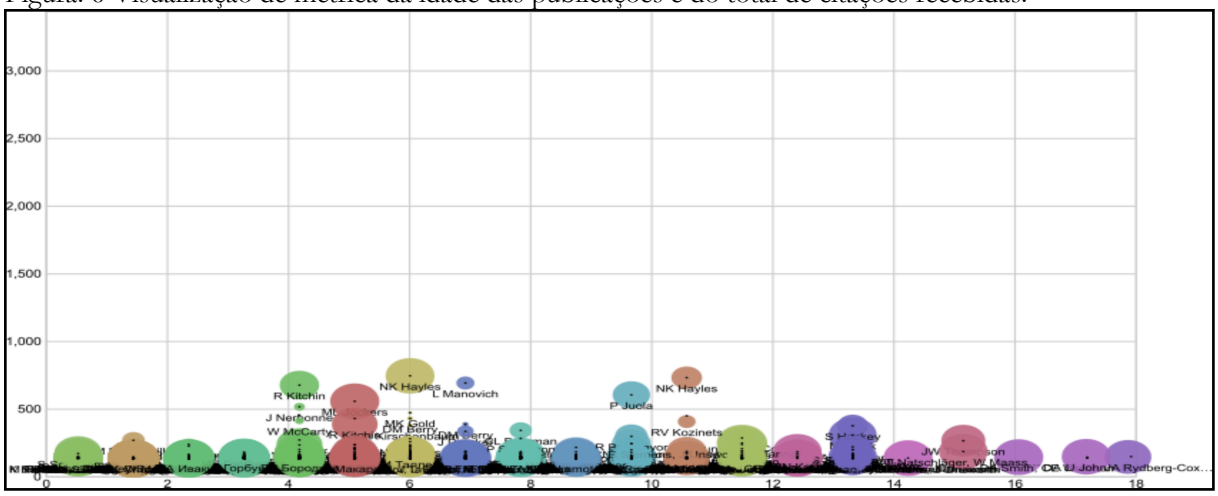

Fonte: Elaboração própria por meio da ferramenta RAWGraphs.

A figura 6 mostra também o fato que das 7 pesquisas mais citadas e com mais de 500 citações recebidas (NK Hayles do 2011 e do ano 2007, L Manovich, R Kitchin, ML Jockers, P Juola e J Nerbonne) o 57% são das mais actuais, pois têm somente 6 anos de publicados, como é o caso das publicações de NK Hayles do 2011, R Kitchin, J Nerbonne e ML Jockers.

5 Conclusão ou Considerações Finais

Foi possível concluir que o uso de softwares de visualização de dados nas análises métricas é comum na área da Ciência da Informação, embora, as configurações dos modelos complexos e altamente personalizados ainda sejam difíceis para os profissionais que não possuem as competências necessárias durante o desenvolvimento da pesquisa, o que demandaria uma quantidade significativa de tempo para correto domínio das ferramentas.

Também que, as principais publicações recuperadas sobre o tema estudado, não são oriundas de fontes ou tipologias documentais tradicionais de análise métrica da produção científica, e que os livros, são as principais fontes do foco de estudo.

Comportamentos interessantes foram identificados em relação às métricas de citações recebidas de artigos científicos de fontes alternativas às de sua publicação original, como é o caso das redes sociais acadêmicas (ex. academia.edu, researchgate). Este fato demonstra a tendência dos pesquisadores em compartilhar suas publicações e ganhar maior visibilidade para seu trabalho nestas plataformas, para além de sua publicação em periódicos científicos.

O ano de 2012 foi identificado como o ano mais produtivo em humanidades digitais e cujas publicações foram as mais citadas.

Identificou-se que a tendência geral é de que os documentos mais citados não apareçam nas 100 primeiras posições do ranking acadêmico do Google.

Referências

ADAMS, J.L.; GUNN, K.B. Digital Humanities: Where to Start. **College & Research Libraries News**, v. 73, n. 9, p. 536-539, 569, 10 2012.

ATWOOD, T. P., e REZNIK-ZELLEN, R. Using the Visualization Software Evaluation Rubric to explore six freely available visualization applications. **Journal of eScience Librarianship**, v. 7, n.1, e1122 p. 1-20, 2018. Recuperado de: https://escholarship.umassmed.edu/jeslib/vol7/iss1/3/ Accesado em: 15 novembro 2018

HARZING, Anne-Wil, et al. **The Publish or perish book**. Melbourne: Tarma software research, 2011.

MAURI, M., Elli, T., CAVIGLIA, G., UBOLDI, G., & AZZI, M. RAWGraphs: A Visualisation Platform to Create Open Outputs. In **Proceedings of the 12th Biannual Conference on Italian SIGCHI Chapter** (p. 28:1–28:5), 2017. New York, NY, USA: ACM. Recuperado de: https://doi.org/10.1145/3125571.3125585 Accesado em: 24 septembro 2018.

POOLE, A.H. The conceptual ecology of digital humanities. **Journal of Documentation**, Bradford, v. 73, n. 1, p. 91-122, 2017.

RAWGraphs Team. **Introduction to RAWGraphs**. Licensed under CC BY-NC-SA 4.0. Recuperado de: https://rawgraphs.io/learning/introduction-t o-rawgraphs/Accesado em: 23 septembro 2018.

VERBEKE, D. Digital Humanities and Libraries – DH 2014. **META: tijdschrift voor bibliotheek & archief**, v. 90, n. 7, p. 41-42, 2014.

WONG, S.H.R. Digital Humanities: What Can Libraries Offer? **Portal : Libraries and the Academy**, Baltimore, v. 16, n. 4, p. 669-690, 10 2016.

ORTEGA, N. R. Humanidades Digitales, Digital Art History y cultura artística: relaciones y desconexiones. **ARTNODES: Revista de Arte, Ciencia y Tecnología**, Catalunya, n. 13, p. 16-25, 2013.

RODRÍGUEZ-YUNTA, L. Humanidades digitales, ¿una mera etiqueta o un campo por el que deben apostar las ciencias de la documentación. **Anuario ThinkEPI**, v. 7, pp. 37-43, 2013.

Vídeo da apresentação

Título: Humanidades Digitales: visualização da produção científica.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=11

Transcrição da apresentação

El vídeo trata de una presentación para el segundo taller de información datos y tecnología 2018 WIDAT, titulado Humanidades Digitais: Visualização da produção científica. Como autores de este trabajo, quien les habla, la doctoranda, Mirelys Puerta Días, de la Universidade Estadual Paulista Júlio de Mezquita Filho del campus de Marília, del programa de posgraduación en ciencias de la información El doctor profesor Edgar Bisi Álvarez, de la Universidade Federal de Santa Catarina en Florianópolis, y la profesora y doctora Silvana Aparecida Borsetti Gregorio Vidotti, de la Universidade Estadual Paulista Júlio de Mezquita Filho.

El presente trabajo aborda las humanidades digitales a través de la producción científica publicada en las bases de datos científicas nacionales e internacionales.

En el estudio se utiliza como método bibliométrico aplicado para identificar la producción científica indexada sobre el objeto pesquisado. El estudio es descriptivo y cuali cuantitativo; se utiliza como fuente la base de datos de periódicos en ciencias de la información y documentos, BRAPCI, recuperando también documentos a través de google académico mediante el software Publish or Perish, visando de esta forma verificar la producción teórica de las humanidades digitales y las métricas de interés para el presente trabajo.

Se aplica para la visualización de las métricas el aplicativo Raw Graph, basado em la web que trata de un framework de código abierto utilizado para la visualización de datos complejos. La coleta de datos fue realizada sin limitaciones en las fechas de acreditación en el caso de la plataforma BRAPCI, y a través del buscador google académico se utilizó como software el aplicativo Publish or Perish ya mencionado, donde se limitó la búsqueda a los años 2000-2017. El uso de este aplicativo se justifica porque la interfaz nativa de google académico no es muy adecuado para análisis bibliométrico.

Por medio de la colecta en la base BRAPCI se pretende identificar más allá de la presencia de las humanidades digitales de las pesquisas de ciencias de la información brasileira, el foco de su sabor. Con este fin la búsqueda fue realizada en la lengua portuguesa, en el caso de BRAPCI; en la lengua inglesa en el caso de google académico.

El método de pesquisa aplicado fue el análisis de datos del análisis bibliométrico de la producción científica, y como ya se mencionó fue realizada en Google académico y apoyada por la herramienta PoP, Publich or Perish, que recupera y hace un análisis de citaciones académicas obtenidos a través de las fuentes como Google académico, Crosref, Web of Science y Scopus.

En este caso nuestra pesquisa fue cogió como la fuente o Google académico, porque esta es una considerada con una útil herramienta para la pesquisa en literatura científica, incluye muchas disciplinas y fuentes académicas, artículos revisados por pares tesis, libros, resúmenes, artículos de editoriales académicas, repositorios institucionales, entre otras fuentes de interés.

En el caso de este aplicativo se facilita el cálculo de múltiples y variadas métricas las cuales el presente estudio identificó las siguientes: años de publicación, años de citación, cantidad de citaciones recibidas, el promedio de citaciones por año, el promedio de citaciones por documento, citaciones por autor, entre otras métricas como el índice h y el índice y. Se utiliza también en el aplicativo Raw Graph porque sube como una de las herramientas más favorables

para usar tanto en términos de características operacionales así como las funcionales para las visualizaciones de datos.

En este estudio fueron utilizados las siguientes visualizaciones del Raw Graph: gráfico de dispersión, ciclo parking y triman. En este caso esta visualización es útil para ver el peso de las categorías pertenecientes a una estructura jerárquica.

Como resultado se verificó que el levantamiento bibliográfico realizado en la base de datos BRAPCI que trajo como respuesta a penas un total de nueve documentos los cuales cinco fueron publicados en el año 2017, es poco el profundamente de la temática por la comunidad académica en Brasil.

En el caso de la búsqueda realizada en Google académico a través del software PoP se recuperó un total de 883 documentos de los cuales 510 son libros y 373 artículos de periódico.

Los trabajos levantados para estas pesquisas tienen a las humanidades digitales en su relación con las áreas como las bibliotecas como principal foco. Esta temática está relacionada con otras categorías como humanities computing y sus abordajes también de intereses de la historia como ciencia y su relación con el fenómeno de big data.

Las temáticas de interés que preocupan actualmente a la comunidad científica que publica sobre la temática en humanidades digitales pueden verificarse en las figuras que se muestran en pantalla. En el caso de los resultados las métricas de autores del total de citaciones recibidas se identificaron que los autores con más citaciones fueron Hayles, Manovich, Kitchin, Juola, entre otros y se encuentran como centro en la visualización que se muestra en pantalla lo que significa que cuanto mayor es el número de citaciones, mayor es el radio de cobertura de los autores que están localizados en el centro de la gráfica que se muestra en pantalla.

En relación a las métricas del total de publicaciones científicas por año se identificó que el año 2012, contó con un total de 166 trabajos, seguido del año 2013 con un total de 122 publicaciones y el año 2012 con 103. Tenemos un dato interesante en este caso de las métricas es que los últimos tres años disminuyó considerablemente la producción científica de mayor impacto sobre la temática, humanidades digitales.

Según las fuentes consultadas en relación a los años anteriores y que del año 2015 a 2017 disminuyó a casi la mitad del total de publicaciones. En el caso de las métricas del total de citaciones recibidas por los autores y el ranking de Google scholar la figura que se muestra en pantalla muestra que los cinco trabajos más citados no aparecen entre las diez primeras posiciones del ranking de Google académico de las cuales el 50 por ciento pertenecen al año 2012.

Una relación detallada de estos datos en relación a los autores más citados es: el autor Hayles con citación de 762 del año 2012, se encuentra en un ranking de Google Scholar de 848 en la posición; también se identifica a Manovich por ejemplo con un total de citaciones de 700 se encuentra en un ranking de 95 en Google scholar en el resultado. Kitchin 682 y aparece en el 542 de posición y por su parte Juola que con su publicación del año 2008 aparece en el ranking 485 de Google scholar.

Entre las consideraciones finales y principales de nuestra pesquisa en las principales publicaciones recuperadas sobre el tema estudiado, no son oriundas de cuentas y tipologías

documentales tradicionales de análisis métricos de producción científica y que los libros son las principales fuentes de foco de estudio. También se identificó que comportamientos interesantes fueron identificados en relación a las métricas de citaciones recibidas de artículos científicos de fuentes alternativas y de su propia publicación original como es el caso de las redes sociales Academia y ResearchGate. Este hecho demuestra la tendencia de los investigadores en compartir sus publicaciones y ganar mayor visibilidad para su trabajo en estas plataformas más allá de su publicación en periódicos científicos.

Se identifica también que el año 2012 fue identificado como el año más productivo de las humanidades digitales y cuyas publicaciones fueron las más citadas y que hay una tendencia general entre los documentos más citados no aparecen entre las primeras posiciones del ranking de Google académico.

Agradecemos en esta investigación a la UNESP y al programa de posgraduación en Ciencia de la información y al CAPES por la ayuda/financiamiento de la misma.

Slides da apresentação

Título: Humanidades Digitales: visualização da produção científica.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=11

Gestão de dados da Biodiversidade: aplicação do padrão de metadados Darwin Core

Filipi Miranda Soares [a], Raíssa Yuri Hamanaka[b] e Benildes Coura Moreira dos Santos Maculan[c]

Resumo: No contexto da gestão de dados de pesquisa e da necessidade de padronização do armazenamento e tratamento dos mesmos para posterior reutilização, torna-se imprescindível o uso de metadados para a representação dos dados. Devido a importância do uso de metadados para a recuperação de documentos, o estudo objetivou analisar a aplicação do padrão de metadados Darwin Core (DwC) em um registro de ocorrência do Portal da Biodiversidade. Para avaliar a aplicação do DwC pelo Portal da Biodiversidade, foi feita uma correlação entre os metadados do DwC com os metadados do registro de ocorrência do repositório, buscando-se entender o significado de cada metadado e se eles correspondem de fato aos metadados do DwC, uma vez que a documentação do Portal da Biodiversidade apresenta o DwC como padrão de metadados adotado. Dos 34 campos do registro de ocorrências analisadas, a maioria tinha correspondência com os campos do padrão de metadados. Houve casos de duplicação de campos no repositório da biodiversidade, da criação de campos no repositório que não existiam no DwC e da existência de campo inadequado no repositório. A partir do exemplo do Portal da Biodiversidade é possível delinear a importância da curadoria digital, ao procurar agrupar conjuntos de dados semelhantes e estruturá-los de forma a possibilitar o reúso dos mesmos.

Palavras-chave: Gestão de dados de pesquisa. Metadados. Darwin Core.

Biodiversity data management: applying the Darwin Core metadata standard

Abstract: In the context of the management of research data and the need to standardize the storage and treatment of them for later reuse, it is essential to use metadata to represent the data. Due to the importance of using metadata for document retrieval, the study aimed to analyze the application of the Darwin Core (DwC) metadata standard in a Portal da Biodiversidade occurrence record. To evaluate the application of the DwC by the Portal da Biodiversidade, a correlation was made between the metadata of the DwC with the metadata of the record of occurrence of the repository, trying to understand the meaning of each metadata and if they correspond in fact to the metadata of the DwC, since the documentation of the Portal da Biodiversidade presents DwC as the metadata standard adopted. Of the 34 occurrence record fields analyzed, most corresponded to the metadata standard fields. There have been cases of duplication of fields in the biodiversity repository, the creation of fields in the repository that did not exist in the DwC and the existence of an inadequate field in the repository. Based on the example of the Biodiversity Portal, it is possible to delineate the importance of digital curatorship by seeking to group similar data sets and structure them in a way that allows them to be reused.

Keyword: Research data management. RDM. Metadata. Darwin Core.

a Universidade Federal de Minas Gerais (UFMG). E-mail: filipivgp2011@gmail.com. ORCID: https://orcid.org/0000-0002-0674-7960. Currículo: http://lattes.cnpq.br/1290270601346793

b Universidade Federal de Minas Gerais (UFMG). E-mail: raissa0201@gmail.com. ORCID: https://orcid.org/0000-0001-9516-5825. Currículo: http://lattes.cnpq.br/7188479615806578

c Universidade Federal de Minas Gerais (UFMG). E-mail: benildes@gmail.com. ORCID: https://orcid.org/0000-0003-4303-9071. Currículo: http://lattes.cnpq.br/5336218259257800

1 Introdução

No atual contexto do fenômeno Big Data, em que são gerados grandes volumes de dados não-estruturados em meio digital, torna-se de extrema importância a questão da organização do dado para sua posterior recuperação.

Inseridos nesse contexto estão os pesquisadores, produzindo um volume grande de dados científicos, o que impacta na definição das atuais fontes de informação

(para além do periódico científico) e no compartilhamento de dados, e, em consequência, na comunicação científica. Dessa forma, surgem desafios na gestão dos dados de pesquisa disponíveis em rede (SAYÃO; SALES, 2012).

Como solução para esses desafios têm origem o conceito de curadoria digital que "além de reduzir a duplicação de esforços na criação de dados de pesquisa […] reforça o valor de longo prazo dos dados existentes quando os tornam disponíveis para a reutilização em novas pesquisas" (SAYÃO; SALES, 2012, p. 184).

Para garantir o reúso dos dados de pesquisa por pesquisadores, é necessário que os sistemas computacionais consigam acessá-los. Assim, tanto dados quanto algoritmos devem ser criados segundo os princípios de reusabilidade, encontrabilidade, acessibilidade e interoperabilidade (FAIR, 2016). Isso pode ser problematizado pelas seguintes questões: "se você disponibilizar seus dados para um cientista ou pesquisador que não esteve envolvido com seu projeto, seriam capazes de entendê-lo?"; "eles conseguiriam utilizar os dados efetiva e apropriadamente?"; "como criar, organizar, gerir, descrever, preservar e compartilhar dados, efetivamente?" (STRASSER et al., 2012, p. 1, tradução nossa).

A efetiva gestão de dados de pesquisa e sua posterior reutilização por demais pesquisadores, depende de um conjunto de práticas durante a coleta, o processamento e a análise dos mesmos. Essas práticas compõem o ciclo de vida dos dados (CVD), que é formado pelos seguintes elementos: planejar, coletar, assegurar, descrever, preservar, descobrir, integrar e analisar (STRASSER et al., 2012). Para Sant'ana (2016), cada etapa ou elemento do CVD possui características em comum: privacidade, integração, qualidade, direito autoral, disseminação e preservação. Sayão e Sales (2012) dividem o CVD em ações: para todo o ciclo de vida (descrição e representação da informação, planejamento da preservação, participação e monitoramento e curadoria e preservação); sequenciais, que se repetem em cada etapa do ciclo (conceitualização, criação ou recebimento, avaliação e seleção, arquivamento, preservação, armazenamento, acesso, uso e reuso e transformação) e ocasionais (eliminação, reavaliação e migração).

O foco deste estudo foi o elemento "descrição" do CVD, definido como "dados que são descritos com precisão e minuciosamente usando os padrões de metadados apropriados" (STRASSER et al., 2012, p. 3, tradução nossa).

Conforme Costa (2017), há algumas iniciativas brasileiras em relação à gestão de dados de pesquisa, e dentre elas se destacam: o Programa FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) de Pesquisa em e-Science; o Portal da Biodiversidade; a Infraestrutura Nacional de Dados Espaciais no Brasil (INDE); as medidas de incentivo ao acesso aberto do Instituto Brasileiro de Informação em Ciência e Tecnologia (IBICT) e o desenvolvimento do repositório de dados do Instituto de Energia Nuclear.

Para explicitar o elemento descrição (e seus fatores) do CVD, analisaram-se os metadados de um registro de ocorrência do repositório de dados do Portal da Biodiversidade em comparação com o padrão de metadados Darwin Core (DwC). DwC é um padrão internacional com base em taxon, composto por um conjunto de elementos (propriedades, atributos ou conceitos) desenvolvidos para padronizar o compartilhamento de informações sobre diversidade biológica.

2 Objetivo

Analisar a aplicação do padrão de metadados Darwin Core (DwC) em um registro de ocorrência do Portal da Biodiversidade[57].

3 Procedimentos metodológicos

O universo de pesquisa é todos os registros no Portal da Biodiversidade e como amostra foi selecionado o registro de ocorrência da espécie Rhinella granulosa (Spix, 1824), leigamente conhecida como sapo da caatinga. O procedimento adotado foi correlacionar os metadados do DwC com o significado atribuído a cada campo do registro e avaliar o seu uso. Assim, as categorias de análise selecionadas para análise foram os metadados adotados para descrição do registro de ocorrência, que foram correlacionadas com o conjunto de metadados do DwC.

4 Resultados

A análise determinou que o registro selecionado possui 34 metadados, apresentados em formato de folha de dados (CSV[58]), baixado do Portal da Biodiversidade, que serão apresentados na ordem que aparecem no registro.

Os dois primeiros metadados do registro são <Nome da instituição> e <Sigla da instituição>. Eles representam um mesmo dado e possuem o mesmo equivalente no DwC, que é o metadado <institutionCode>. O primeiro campo de metadado está sem informações e o segundo apresenta a sigla ICMbio. Esses dois campos deveriam ser apenas um campo, pois significam a mesma coisa. Assim, seria necessário apenas definir o formato de entrada de dados: nome por extenso da instituição ou apenas a sigla.

Em seguida, aparece o metadado <Nome da base de dados>, que possui equivalente no DwC como <datasetName> e está preenchido corretamente. O campo seguinte foi denominado <Sigla da base de dados> e não possui equivalente no DwC. A melhor prática sugerida seria unir esses dois campos em apenas um e padronizar a entrada de dados: nome por extenso da base de dados ou apenas sigla.

Depois vem o campo <Responsável pelo registro> que possui o metadado equivalente no DwC <recordedBy>, com valor formatado de acordo com as recomendações do DwC para este campo.

Em sequência, são apresentados dois campos que equivalem a um mesmo campo no DwC, mas foram preenchidos com valores distintos: <Número do registro no portal> e <Número do registro na base de dados>, que equivalem semanticamente ao campo <catalogNumber> no DwC. O primeiro apresenta o valor numérico '1067665' e o segundo o valor "Nº Da Autorização/Licença Sisbio: 44832".

57 Disponível em:<https://portaldabiodiversidade.icmbio.gov.br/portal>. Acesso em: 30 set. 2018.
58 Comma-separated values é um formato de arquivo que apresenta dados tabelados.

Após, aparece o campo <Data do registro> que é ambíguo. Não é possível saber se o valor da data que preenche o campo é a data de registro na base de dados ou a data que o evento (ocorrência) aconteceu. No padrão DwC, o metadado para descrever a data de ocorrência é o <eventDate>, presente no registro como <Data do evento>. Quando baixado em formato CSV, o valor do campo <Data do registro> muda de '05/02/2017' para '06/02/2017', a mesma data presente no campo <Data do evento>. Não há um campo de data de registro no DwC. O campo com significado mais próximo seria <dcterms:modified>, que se refere à última data de modificação do registro documental da ocorrência na base de dados. Além disso, o DwC recomenda utilizar esquemas de codificação para preenchimento das datas, como a ISO 8601:2004(E), o que não foi aplicado no Portal da Biodiversidade. O valor do campo <Data do evento> apresenta outro problema: está definido como '06/02/2017 a 06/02/2017'. Se o evento aconteceu no dia seis de fevereiro e não foi inserido o intervalo específico de horas em que ele ocorreu, não é necessário inserir a data como intervalo de datas, uma vez que o evento aconteceu em apenas um dia.

O metadado seguinte, <Data de Carência>, não possui equivalente no DwC e não está claro ao que esta data se refere.

Depois, aparece o metadado <Nome científico>, que possui o equivalente <scientificName> no DwC. O valor desse campo no registro é 'Rhinella granulosa', que não está de acordo com as recomendações do DwC (DARWIN CORE TASK GROUP, 2015), que orienta indicar o nome científico completo, com autor e data. A melhor prática seria apresentar o nome 'Rhinella granulosa (Spix, 1824).

Em seguida vem <nome comum>, que possui o equivalente <vernacularName> no DwC, e está preenchido em conformidade com as melhores práticas recomendadas pelo padrão.

O campo seguinte, <Nome científico na base de dados>, não deveria existir. O nome científico da espécie é um identificador único, ou seja, não pode variar. Logo, é desnecessário que haja dois campos com o mesmo valor no registro de ocorrência.

Logo em seguida aparecem os metadados <Nível taxonômico>, <Número de indivíduos>, <Reino>, <Filo>, <Classe>, <Ordem>, <Família> e <Gênero>, que têm valores que atendem às orientações de melhores práticas do DwC, e possuem como equivalentes, respectivamente: <taxonRank>, <individualCount>, <kingdom>, <phylum>, <class>, <order>, <family> e <genus>. Depois vem o metadado <Espécie>, que repete o mesmo valor de dois outros campos do registro de ocorrência, portanto, é redundante sua presença no registro. A sugestão seria substituir esse metadado por <specificEpithet>, que representa o epíteto[59] da espécie no nome científico.

A seguir aparecem os metadados <Estado de conservação>, <Categoria de Ameaça> e <Status de Sensibilidade>, que ainda não têm equivalência no DwC. Entretanto, uma extensão[60] está sendo desenvolvida para representar informações de estado de conservação. Após, aparecem metadados com informações de localização: <Localidade>, <País>, <Estado/Província>, <Município>, <Latitude> e <Longitude>, que possuem equivalentes no DwC, respectivamente:

59 Designa uma espécie ou subespécie diferente dentro de um mesmo gênero.

60 Disponível em: <https://tools.gbif.org/dwca-validator/extension.do?id=http://purl.org/plic/terms/3.2.1/ThreatStatus>. Acesso em: 25 set. 2018.

<locality>, <country>, <stateProvince>, <municipality>, <decimalLatitude> e <decimalLongitude>, e têm valores conforme as orientações do padrão.

Depois aparecem os campos <Outras informações da localidade> e <Jurisdição>, que não possuem equivalentes no DwC.

Por fim, o metadado <Destino do Material> tem o equivalente no DwC <MaterialSample>.

5 Considerações finais

Conforme o objetivo do estudo, foram analisados 34 campos de um registro de ocorrência do Portal da Biodiversidade em correlação com os campos do padrão de metadados DwC. Na maioria das análises, em cerca de 65% dos casos, houve correspondência do campo do registro com o campo do padrão de metadados. Entretanto, houve casos de duplicação de campos no repositório da biodiversidade, valores inadequados, criação de campos que ainda não existem no DwC e existência de campo inadequado no repositório.

O Portal da Biodiversidade reuni registros de ocorrência de nove bases de dados de biodiversidade brasileira, sendo uma iniciativa de gestão de dados que desde 2016 está integrado ao Sistema de Informação sobre a Biodiversidade Brasileira (SiBBr), que está ligado ao Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC).

Essa iniciativa é um exemplo que permite perceber a importância da curadoria digital, que procura agrupar conjuntos de dados semelhantes e estruturá-los de maneira a possibilitar o seu reúso. Para tanto, é necessário manter interoperabilidade entre as diferentes bases, o que pode ser alcançado por meio do uso de padrões de metadados. Considera-se que na implementação do CVD, os metadados são essenciais, pois possibilitam a padronização da representação e/ou codificação dos dados para sua futura recuperação.

Acredita-se que a padronização dos dados coletados e armazenados em repositórios permite a democratização dos dados ao garantir o acesso efetivo aos mesmos.

Referências

COSTA, Maíra Murrieta. **Diretrizes para uma política de gestão de dados científicos no Brasil**. 2017. 288 f. Tese (Doutorado em Ciência da Informação) – Faculdade de Ciência da Informação, Universidade de Brasília, Brasília, DF, 2017.

DARWIN CORE TASK GROUP. Biodiversity Information Standards. Darwin Core. 2015. Available from: <http://rs.tdwg.org/dwc>. Accessed on: 8 Sept. 2018.

FAIR principles for data stewardship. **Nature Genetics**, London, v. 48, n. 4, p. 343, Apr. 2016.

SANT'ANA, Ricardo César Gonçalves. Ciclo de vida dos dados: uma perspectiva a partir da Ciência da Informação. **Inf. Inf.**, Londrina, v. 21, n. 2, p. 116-142, maio/ago. 2016.

SAYÃO, Luis Fernando; SALES, Luana Faria. Curadoria digital: um novo patamar para preservação de dados digitais de pesquisa. **Inf. & Soc.: Est.**, João Pessoa, v. 22, n. 3, p. 179-191, set./dez. 2012.

STRASSER, Carly et al. Primer on data management: what you always wanted to know: but were afraid to ask. **DataONE**, Oakland, CA, p. 1-11, fev. 2012.

Vídeo da apresentação

Título: Gestão de dados da Biodiversidade: aplicação do padrão de metadados Darwin Core.

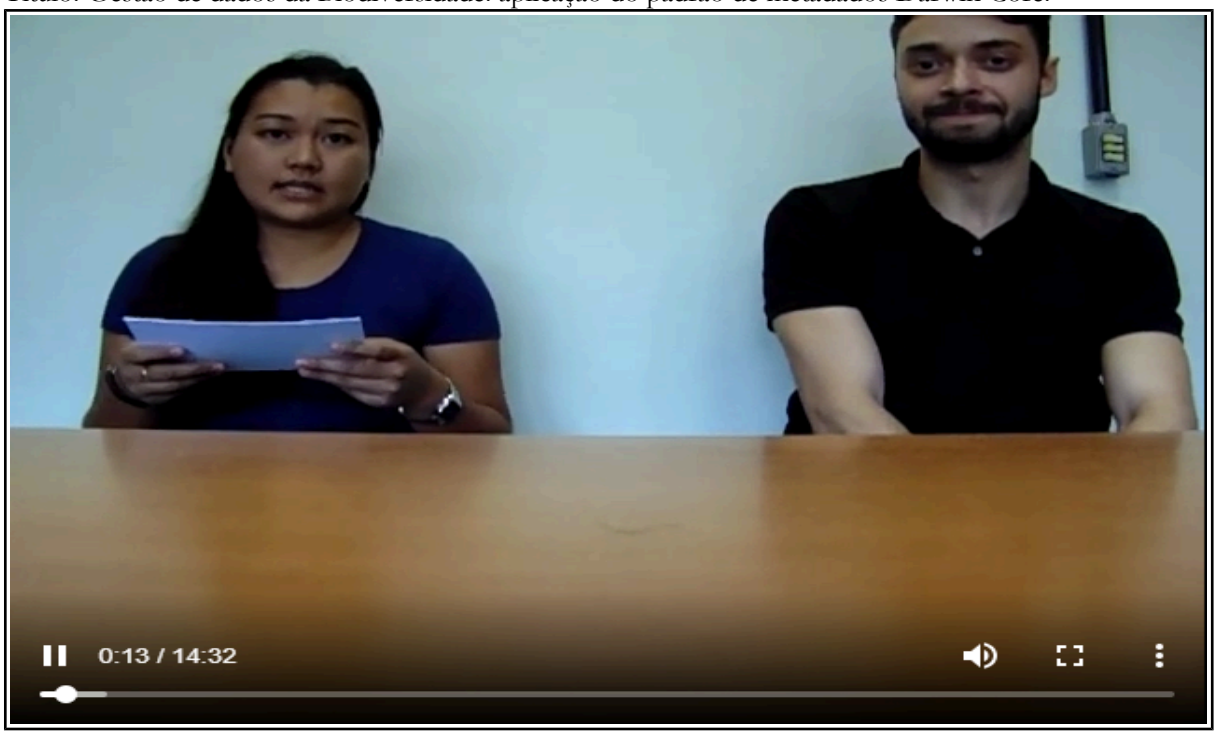

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=12

Transcrição da apresentação

Olá nós vamos apresentar um artigo que submetemos ao 2º Workshop de Informação, Dados e Tecnologia (WIDAT), os autores do artigo foram eu Raíssa e Filipi e a orientadora Benildes nós dois somos mestrando do programa de gestão e organização do conhecimento da escola de Ciência da Informação da UFMG – a Benildes é orientadora do Filipi é professora também na escola do Centro de Informação tanto na graduação quanto na pós.

O título do nosso artigo é "Gestão de dados da Biodiversidade: aplicação do padrão de metadados Darwin Core".

Nós vamos apresentar a estrutura do artigo, vou começar com referencial teórico o objetivo do artigo que ele vai explicar a metodologia e os resultados e depois eu vou apresentar as considerações finais.

Começamos contextualizando e falando um pouco do Big Data, esta grande quantidade de dados não estruturados.

É grande o volume de dados não estruturados e dessa influência esse grande volume de dados sempre existiu, mas agora que na ciência da informação está surgindo essa preocupação de lidar com esses dados e principalmente os dados científicos, os dados que são coletados pelos pesquisadores, e os desafios seriam no armazenamento desses dados pra posterior compartilhamento dos dados e para gerar de fato uma comunicação científica efetiva.

Então, pensando nesses dados científicos que devem ser armazenadas surgiu esse conceito de curadoria digital e essa curadoria digital gira em torno de evitar a criação de dados duplicados e aí também levou a questão do armazenamento de dados de forma padronizada para permitir o reúso desses dados então a questão do reúso de dados é a palavra-chave da curadoria.

Quando se fala em reúso de dados a gente pensa basicamente em duas características: como é que os dados serão reutilizadas pensando em disponibilizar esses dados em formatos abertos com uma série de critérios que estabeleça garantia da qualidade da disponibilização dos dados e também pensar na descrição de forma lógica e padronizada desses dados coletados pelos pesquisadores para que alguém que não tenha participado da coleta dos dados consiga entender e efetivamente utilizar esses dados.

Então, para permitir esse reúso dos dados científicos podemos pensar em gestão de dados, no nosso artigo essa parte do referencial teórico nós utilizamos basicamente três autores Strasser, Sayão e Sales e quando eles pensam no reúso de dados eles pensam no ciclo de vida dos dados, ou seja, é aquele conjunto de dados que se precisa ser submetido a uma série de etapas para que eles sejam armazenados e possivelmente compartilhados de forma efetiva, só que de acordo com o objetivo do nosso artigo nós focamos na etapa de descrição dos dados que eles definem como uma descrição detalhada dos dados através de padrões de metadados apropriados, então antes falar um pouco do objetivo do artigo eu queria citar a tese de Costa (2017) em que ela aborda as principais iniciativas de gestão de dados, aqui no Brasil uma delas é o Portal da Biodiversidade que é onde a pesquisa foi realizada, foi selecionado e aí chegamos no objetivo do artigo que é analisar os campos de um registro de ocorrência do portal da biodiversidade e comparar ele com campos do padrão da biologia, ou no caso, no Darvin Core.

Vou falar um pouquinho da metodologia que aplicamos e dos casos que a gente obteve. Primeiramente vou definir os conceitos o que é o portal da biodiversidade e o que é o padrão de metadados Darwin Core que a gente aplicou no portal da biodiversidade. Ele é um repositório de dados científicos sobre registros de ocorrência de espécies brasileiras que é mantido pelo incêndio de bio, e esse repositório aplica o padrão de metadados Darwin Core para descrever esses dados de registros de ocorrências e o que é o padrão de metadados.

Ele foi desenvolvido pelo Darwin Core que é um grupo da GBIF que é uma fundação internacional que publica informações sobre a biodiversidade e desenvolve uma série de ferramentas para o compartilhamento de informações sobre biodiversidade e então Darwin Core foi desenvolvido pelo compartilhamento de informação sobre espécimes e é importante diferenciar o conceito de espécie de espécime porque o conceito de espécie ele é mais amplo.

O que é uma espécie? É grupo de indivíduos uma população com as mesmas características filogenéticas que representa uma mesma espécie, então o conceito de espécie é construído com base nessas observações a essas características genéticas dos indivíduos que são categorizados como uma mesma espécie.

O espécime é uma amostra coletada dessa espécie em questão na atitude de análise então o biólogo vai a campo, ele captura um indivíduo, não lixo por exemplo, ele leva esse bicho para laboratório para analisar e fazer a inscrição taxonômica, a análise genética e todos os outros procedimentos possíveis dentro da biologia – os procedimentos de pesquisa.

Então esse bicho coletado é um espécime, mas esse espécime também pode ser a folha de uma planta, pode ser uma amostra de solo, enfim um espécime é um conceito de amostragem é uma mostra dentro da população. Um indivíduo é coletado dentro da população de uma espécie.

Bom, o Darwin Core ele trabalha com a representação da informação desses registros de espécimes que são os registros de ocorrência, então o biólogo foi a campo ele coletou um organismo ou ele fotografou um bicho, alguma coisa assim, isso é um registro de ocorrência. O que é esse registro de ocorrência? Tem basicamente a descrição taxonômica da espécie, qual foi o animal observado naquele local, quando ocorreu essa observação esse evento que como é chamado na biologia os dados desse local os dados do período de tempo que aconteceu a esse evento e outras relações típicas de dentro do contexto da biologia como habitat que esse bicho habita, enfim e todas os outros metadados conferidas dentro do Darwin Core levando em conta esses outros conceitos.

Então a metodologia que adotamos foi selecionar um registro dentro do portal da biodiversidade especificamente o registro da espécie que nela granulosa que é vulgarmente conhecido como o sapo da caatinga e a gente analisou campo a campo desse registro são 34 metadados, então analisamos o conteúdo de cada um desses metadados para ver se eles são equivalentes ao que é recomendado no glossário do Darwin Core e nas recomendações do preenchimento desses metadados.

Então o que a gente analisou dentre esses 34 campos no registro da biodiversidade? Existem alguns erros como por exemplo a questão de duplicatas de metadados. O primeiro exemplo que abordamos no artigo é o nome da base de dados e sigla da base de dados no glossário onde tem as orientações de preenchimento do quadro de metadados do Darwin Core, ele orienta que seja

adotado só um valor, esse é um campo único, então nome da base de dados que é dataset name que está no corpo do Darwin Core. Trata-se apenas de um metadado, então a sigla da base de dados ou nome da base de dados só podem entrar nesse campo, mas é preciso especificar qual o valor que vai ser adotado como padrão ou a sigla da base de dados, no caso do portal da biodiversidade esse campo aparece publicado tanto por extenso na base de dados quanto com a sigla e isso é considerado um erro no portal da biodiversidade.

Outro problema que foi detectado foi em relação ao preenchimento dos campos metadados porque o Darwin Core ele recomenda que seja seguida uma série de protocolos e vocabulários controlados e o preenchimento desses campos e formatos também, por exemplo, as datas elas devem seguir um padrão ISO e no caso do portal da biodiversidade eles não seguem esse padrão, então existem diversos formatos de entrada de data nos campos desses registros.

Um outro problema também envolvendo as datas é referente a data do evento, então um evento de registro de ocorrência da espécie ele tem início preciso específico, com dia da ocorrência a hora minuto segundo, se possível então a data de início e término do evento ela tem que ser mais específico possível e no caso do portal da biodiversidade esse dado não é apresentado dessa forma eles apresentam simplesmente o dia de início e o dia do término do evento, muitas vezes é o mesmo dia porque os eventos costumam ser curtos por efeito de observação ou de coleta de espécies geralmente duram bons minutos ou horas, mas geralmente não duram mais de um dia. Então isso é um uma outra inconsciência que observamos no padrão.

Por último, outro erro que foi detectado no registo do portal da biodiversidade foi que existem metadados que não estão presentes no núcleo do Darwin Core que é o núcleo central de metadados, no corpo de 176 metadados isso dificulta o compartilhamento de dados, porque existem dados nesse registo que não são compatíveis com os metadados desse conjunto do Darwin Core. Esses dados não podem ser compartilhados, então eles extrapolam o núcleo desse conjunto dos termos do Darwin Core.

E agora então eu vou passar a palavra para Raíssa que fará as considerações finais.

Nas considerações finais fizemos um resumo desses resultados que o Filipi apontou. Houve 65% de correção do registro de ocorrência com padrão de metadados Darwin Core.

Além disso nas considerações finais a gente realça a importância de iniciativas como o portal de biodiversidade, porque ele reuniu o registro de ocorrência da espécie de nove bases de dados brasileiras em uma só e além disso ele levou em consideração dois pontos importantes da curadoria digital, a questão de disponibilizar esse registro de ocorrência em um formato aberto e também a questão de dessas informações estarem devidamente descrita porque houve 65% de equivalência com padrão de metadados.

Então essa iniciativa que incentiva de fato o reúso daqueles dados, principalmente pelo fato de agrupar conjuntos de dados com temáticas semelhantes que estavam dispersos em meio digital em um único repositório nós enfatizamos muito essa questão, ou seja, a importância desse tipo de iniciativa em gestão de dados e principalmente a importância disso na democratização no acesso aos dados e para facilitar o uso efetivo dos dados e consequentemente facilitar a construção da ciência mesmo.

Agradeço ao professor Guilherme pelas contribuições em sala de aula e também pela oportunidade de participar no WIDAT.

Slides da apresentação

Título: Gestão de dados da Biodiversidade: aplicação do padrão de metadados Darwin Core.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=12

Evasão estudantil e Ciência de Dados: primeiros passos de uma pesquisa aplicada no contexto da educação a distância da Universidade Estadual do Centro-Oeste

Sandro Rautenberg[a], Alan H. Costa[b], Paulo R. V. do Carmo[c], Renan Augusto Mattos Nutse[d], Maria Aparecida Crissi Knuppel[e] e Marta Clediane Rodrigues Anciutti[f]

Resumo: A Educação a Distância é uma alternativa de ensino para indivíduos que necessitam horários e locais de estudo flexibilizados. Dentre as instituições que oferecem essa modalidade de ensino, a Universidade Estadual do Centro-Oeste (UNICENTRO) ministra cursos de graduação a distância por intermédio do Núcleo de Educação a Distância (NEaD). Em uma análise realizada, o NEaD destaca um alto índice de evasão de alunos. Para melhor entender essa realidade, institucionalmente, formalizou-se um projeto de extensão empregando tecnologias da Ciência de Dados. Iniciado em Junho/2018, o projeto visa inferir alguns elementos de análise e apoiar decisões pedagógicas a partir dos microdados do Ambiente Virtual de Aprendizagem MOODLE. Neste sentido, este artigo tem como objetivo relatar os primeiros passos do referido empreendimento. Decorridos seis meses de execução, dentre os resultados preliminares alcançados, pontua-se: i) o estabelecimento de um workflow para desenvolver os cenários de exploração e visualização de dados; ii) a concepção de uma camada para ingestão de dados, mitigando os efeitos indesejáveis de versionamento de modelos de dados do MOODLE; e iii) a formalização de um meio de comunicação para com os gestores do NEaD/UNICENTRO, quando da prospecção de cenários de exploração de dados.

Palavras-chave: Ciência de Dados. Educação à Distância. Evasão Estudantil. MOODLE. Ambientes Virtuais de Aprendizagem.

Student evasion and Data Science: first steps of an applied research to the distance learning context of the Centro-Oeste State University

Abstract: Distance Learning is a teaching alternative for individuals who need flexible schedules and places for studying. Among the institutions that offer this kind of education, the Universidade Estadual do Centro-Oeste (UNICENTRO) teaches undergraduate distance courses through the Núcleo de Educação a Distância (NEaD). In an initial analysis, the NEaD highlights a high evasion rate among students. To better understand this reality, institutionally, a project was formalized using Data Science technologies. Initiated in June/2018, the project aims to infer some elements from the microdata of the MOODLE Learning Management System for supporting pedagogical decisions. In this sense, this article aims to report the first steps of this effort. After six months of execution, the preliminary results achieved include: i) the establishment of a workflow for developing data exploitation scenarios; ii) the design of a data layer,

a Universidade Estadual do Centro-Oeste (UNICENTRO). E-mail: sandro.rautenberg@gmail.com. ORCID: https://orcid.org/0000-0002-2375-9365. Currículo: http://lattes.cnpq.br/1550342830820869

b Universidade Estadual do Centro-Oeste (UNICENTRO). E-mail: alanhenschel2@gmail.com. Currículo: http://lattes.cnpq.br/5036418154205354

c Universidade Estadual do Centro-Oeste (UNICENTRO). E-mail: pauloviviurka4@gmail.com

d Universidade Estadual do Centro-Oeste (UNICENTRO). E-mail: renanmnutse@gmail.com. Currículo: http://lattes.cnpq.br/6322152109754016

e Universidade Estadual do Centro-Oeste (UNICENTRO). E-mail: knuppelc@gmail.com. Currículo: http://lattes.cnpq.br/2901507472605831

f Universidade Estadual do Centro-Oeste (UNICENTRO). E-mail: martanciutti@gmail.com. ORCID: https://orcid.org/0000-0003-3852-032X. Currículo: http://lattes.cnpq.br/8331126599019568

mitigating the undesirable effects of versioning of the MOODLE's data model; and iii) the formalization of a communication model with the NEaD/UNICENTRO managers, when prospecting data exploitation scenarios.

Keyword: Data Science. Distance Learning. Student Evasion. Moodle. Learning Management System.

1 Introdução

Com o avanço do uso da Internet, produz-se cada vez mais dados em várias plataformas digitais. Diversos aplicativos e dispositivos interconectados (computadores, smartphones, etc.) relacionam uma série de eventos (van der AALST, 2014), armazenando enormes quantidades de registros, sinais, imagens, vídeos e posts. Por conseguinte, os dados são abundante e velozmente produzidos, podendo servir como matéria-prima à Tomada de Decisão (ECONOMIST, 2018). Por isso, o desenvolvimento de soluções computacionais que obtém insumos de conhecimento de volumes de dados torna-se foco de investimento das organizações.

Figura 1: Contexto do Trabalho.

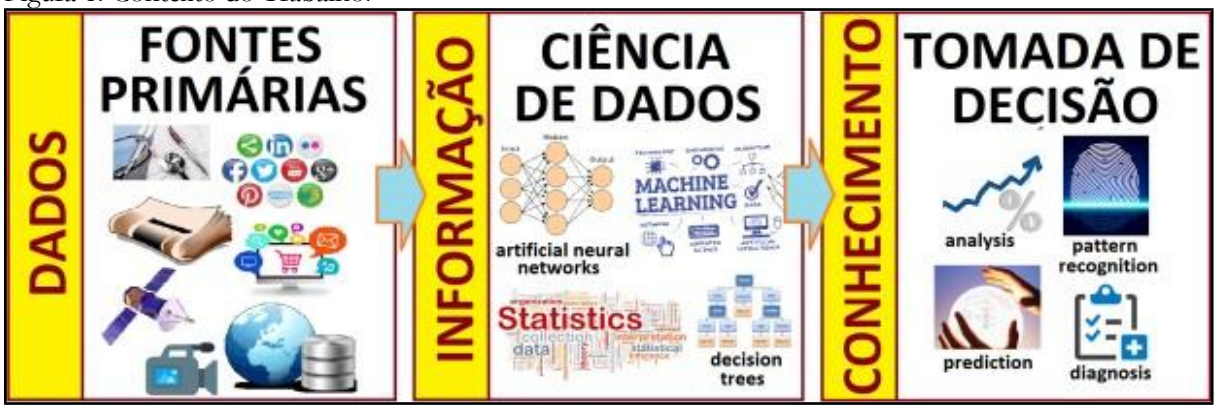

Fonte: Dados da Pesquisa.

Atualmente, esse contexto relaciona os conceitos de Ciência de Dados e Tomada de Decisão como segue. Conforme ilustrado na Figura 1, tem-se as fontes de dados cujas características dificultam a captura, o armazenamento, o gerenciamento, a análise e a exploração de dados por parte de ferramentas computacionais tradicionais (GARTNER, 2018; MANYIKA et al., 2011). Para auxiliar a análise e a exploração de dados, pode-se recorrer à Ciência de Dados (do inglês, Data Science).

A Ciência de Dados é caracterizada como uma camada de métodos devotados à extração de informação útil a partir de complexas e dinâmicas bases de dados (BUGNION; MANIVANNAN; NICOLAS, 2017). E, por conseguinte, ao recuperar informação útil, pode-se auxiliar os gestores no desempenho de suas atividades decisórias.

Diante dessa visão, este trabalho parte do pressuposto que as organizações voltadas ao Ensino a Distância (EaD)1 podem se beneficiar dos métodos e tecnologias da Ciência de Dados para melhorar seus processos. Principalmente, em face destas organizações adotarem Tecnologias da Informação e Comunicação (TICs), produzindo conjuntos de dados a serem explorados, a partir dos: i) gerenciamento da vida acadêmica de seus discentes; e ii) uso de meios digitais para o compartilhamento de material educacional. No tocante às referidas organizações, um dos problemas principais enfrentados é a Evasão Estudantil2, fenômeno cuja taxa média anual alcança 25% dos alunos matriculados (ABED, 2014).

Pontualmente, esse problema também é enfrentado pelo Núcleo de Educação à Distância da Universidade Estadual do Centro-Oeste (NEaD/UNICENTRO). O NEaD/UNICENTRO tem como incumbência a difusão do conhecimento tecnológico e científico para os diferentes

segmentos sociais, por intermédio de projetos, atividades e programas de EaD. Mediante seus polos avançados, essa organização é capilarizada em 51 municípios no Estado do Paraná (NEAD, 2018), circunvizinhando quase todos os 399 municípios da referida unidade federativa. Institucionalizado no ano de 2005, atualmente, o NEaD/UNICENTRO enfrenta o desafio de minimizar seus índices de Evasão Estudantil, que está em torno de 54%.

Tecnologicamente, para minimizar os índices de Evasão Estudantil, Silva (2017) pontua a construção de modelos preditivos. Tais modelos deveriam identificar preventivamente a probabilidade de um aluno evadir. Segundo a autora, com a utilização de modelos preditivos, pode-se abstrair informações confiáveis para suporte ao processo de Tomada de Decisão dos gestores, aumentando os índices de retenção discente. Portanto, admite-se que o emprego de métodos e tecnologias da Ciência de Dados é pertinente ao estabelecimento de modelos preditivos da Evasão Estudantil.

Diante disso, para melhor entender e tratar a realidade da Evasão Estudantil inerente ao NEaD/UNICENTRO, um Projeto de Extensão3 foi formalizado em Junho de 2018. Em sua essência, tal empreendimento visa criar modelos de análise e visualização de dados e informações da evasão, baseando-se em metodologias e tecnologias da Ciência de Dados. Cabe ressaltar que objetivos do referido projeto permeiam, principalmente: i) a abstração dos motivos da desistência dos alunos matriculados em cursos de graduação na modalidade EaD; e ii) o amparo em ações afirmativas para aumentar os índices de retenção de estudantes.

2 Objetivo

Diante o exposto, o objetivo deste capítulo de livro é relatar os resultados parciais alcançados no tocante aos primeiros meses de atividades realizadas do projeto de extensão institucionalizado.

3 Materiais e Métodos

Para subsidiar as atividades de EaD, o NEaD/UNICENTRO utiliza o Ambiente Virtual de Aprendizagem MOODLE (Modular Object Oriented Distance LEarning) como plataforma de suporte (versão 3.x). Este é um sistema gratuito que permite a gestão de cursos online, mediante o gerenciamento da comunicação entre atores (docentes, discentes, tutores, etc.) e dos objetos de aprendizagem (ebooks, videoaulas, atividades, fóruns, mensagens, etc.). Assim, o MOODLE oferece um ambiente dinâmico que oportuniza o aprendizado a qualquer momento e em qualquer lugar, ao utilizar a Internet como plataforma de comunicação (MOODLE, 2018).

Atualmente, a base de dados do MOODLE do NEaD/UNICENTRO comporta cerca de 16 gigabytes de dados, contendo os registros de 5.785 alunos de EaD (formados, desistentes ou em formação). De acordo com seu modelo relacional, na referida base de dados, os registros da interação dos usuários para com os objetos disponibilizados são armazenados minuciosamente em suas 300 tabelas de dados. Diante dessa riqueza de detalhes em seus registros, a base de dados do MOODLE é um insumo pertinente ao discernimento da Evasão Estudantil inerente ao NEaD/UNICENTRO.

Neste sentido, para promover a análise e a exploração de dados/informação a partir da base de dados do MOODLE, adota-se a proposta de Bugnion; Manivannan e Nicolas (2017) como

procedimento metodológico da Ciência de Dados. Os referidos autores sugerem sete passos (Figura 2), conforme segue:

- **Obtenção de Dados**. Preconiza as tarefas de avaliação e seleção de dados primários e seus metadados, por exemplo, a partir: do processamento de arquivos de texto; do monitoramento de uma rede de sensores; de consultas a bases de dados de sistemas legados; ou de API (Application Programming Interface) da web.
- **Ingestão de Dados**. Trata das transformações e carga dos dados primários advindos de fontes diferentes e formatos diversificados em uma base de dados centralizada. Isso implica em organizar, representar e inserir dados pré-processados em um repositório de dados principal, mitigando os esforços futuros na geração de informação relevante.
- **Exploração de Dados**. Privilegia a execução de estudos preliminares de modo a estabelecer conjecturas iniciais e entendimentos superficiais dos dados disponibilizados em relação à informação requisitada. Assim, estabelece-se um fluxo de trabalho (workflow) para relacionar os dados em busca da informação relevante.
- **Definição dos Parâmetros**. Está intimamente ligado às escolhas necessárias para o emprego do(s) algoritmo(s) de Aprendizado de Máquina. Nesta atividade, por exemplo: converte-se os dados de entrada conforme os requisitos de manipulação do algoritmo de aprendizado; transforma-se os dados de saída de modo a refletir uma saída legível aos seres humanos; estabelece-se os intervalos dos parâmetros de entrada a serem considerados; define-se os critérios de parada do algoritmo de aprendizado ou o nível de confiabilidade exigido da resposta gerada.
- **Implementação do Modelo**. Prima pela utilização dos algoritmos de Aprendizado de Máquina para estabelecer modelos a partir dos dados de entrada e saída. Iterativamente, envolve o emprego de estratégias de treinamento e testes dos algoritmos para a definição dos parâmetros mais adequados. Como resultado, um modelo é estabelecido que melhor represente as características dos dados utilizados.
- **Utilização do Modelo**. Uma vez estabelecido um modelo, pode-se utilizá-lo para inferir informações sobre dados não utilizados na etapa anterior. Isso confirmará o poder de generalização do modelo perante situações do mundo real.
- **Tomada de Decisão**. Em situações reais, combinando o resultado gerado pelo modelo com o conhecimento particular do domínio, os gestores tomam suas decisões. Uma parte fundamental nesta etapa envolve a customização da apresentação/visualização dos dados e informações através de relatórios e gráficos. Desta forma, é possível gerar insights mais claros e convincentes em um processo de Tomada de Decisão.

Como suporte tecnológico, salienta-se que no Projeto de Extensão é previsto o uso da Linguagem de Programação Python. No contexto do desenvolvimento de softwares, Python destaca-se por ser uma linguagem de programação de alto nível, interpretada, baseada no paradigma de orientação a objetos e com dinamicidade semântica (PYTHON.ORG, 2018). Por dinamicidade semântica entende-se o poder de extensão da linguagem com a adição de novas funcionalidades mediante a incorporação de bibliotecas. Neste sentido, a este projeto poderão ser incorporadas as bibliotecas:

- **Pandas 4**. É uma biblioteca open source de alta performance que facilita o uso de estruturas e ferramentas de análise de dados em soluções computacionais desenvolvidas em Python.
- **Psycopg2 5**. Em aplicações desenvolvidas com Python, permite o acesso rápido e seguro a bases de dados mantidas no Sistema Gerenciador de Banco de Dados PostgreSQL.
- **Matplotlib 6**. É uma biblioteca para desenvolvimento de gráficos estatísticos, podendo ser utilizada em soluções computacionais Python.
- **Seaborn 7.** Assim como a Matplotlib, a Seaborn também permite o desenvolvi- mento de visualizações estatísticas de dados em aplicações Python.
- **NLTK (Natural Language ToolKit)8**. É uma biblioteca feita para processamento de texto em linguagem natural. Possui ferramentas estatísticas e gráficas e corpus textuais para testes em vários idiomas.
- **VADER (Valence Aware Dictionary and sEntiment Reasoner)9**. Juntamente com a NLTK, provê uma ferramenta léxica de suporte à análise de sentimentos. É baseada em regras sintáticas e semânticas, podendo ser utilizada na detecção de tendências positivas, neutras ou negativas em post de mídias sociais ou mensagens entre usuários, por exemplo.
- **Scikit-learn10**. É uma biblioteca open source que implementa vários algoritmos de Aprendizado de Máquina em Python. Inclui algoritmos de classificação, regressão e agrupamento, por exemplo.

Figura 2: Ciclo de Vida da Ciência de Dados.

Fonte: baseado em (BUGNION; MANIVANNAN; NICOLAS, 2017) [tradução dos autores]

4 Discussão e Resultados Parciais

Considerando o ciclo de vida da Ciência de Dados, o estágio atual do projeto institucionalizado envolve a Ingestão de Dados e a Exploração de Dados. Ressalta-se que estes passos são relacionados aos dados e metadados da base de dados do MOODLE, dispendendo esforço significativo por parte dos cientistas de dados quanto ao: i) entendimento da complexidade do modelo de dados; e ii) pré-processamento e limpeza dos dados.

A Figura 3 representa as atividades desempenhadas junto aos gestores do NEaD/UNICENTRO. As atividades envolvem:

A Obtenção de Dados é realizada junto à Coordenadoria de Tecnologia e Informação da UNICENTRO. A base de dados disponibilizada advém de um arquivo de backup do Ambiente Virtual de Aprendizagem MOODLE. Os dados obtidos são estagiados em uma instância local do Sistema Gerenciador de Banco de Dados PostGreSQL.

A Ingestão de Dados é realizada de forma incremental, à medida que os cenários de exploração ou visualização de dados/informação e os respectivos work-flows são definidos em conjunto aos gestores do NEaD/UNICENTRO. A cada cenário definido, uma query é desenvolvida para organizar, coletar e armazenar um subconjunto de dados relevante no repositório centralizado.

Para cada subconjunto e cenário estabelecido, um script Python é desenvolvido para: i) gerar uma apresentação de dados ou visualização informações através de relatórios e gráficos, respectivamente (fase de Exploração de Dados); ou ii) generalizar um modelo abstrato a partir dos dados, mediante o emprego de algoritmos de Aprendizagem de Máquina (fases de Definição de Parâmetros e Implementação de Modelo).

Como meio de comunicação para com os gestores do NEaD/UNICENTRO, gráficos e relatórios são apresentados, fomentando a geração de insights em um processo decisório (fases de Utilização do Modelo e Tomada de Decisão).

Figura 3. Processo de Desenvolvimento de Cenários.

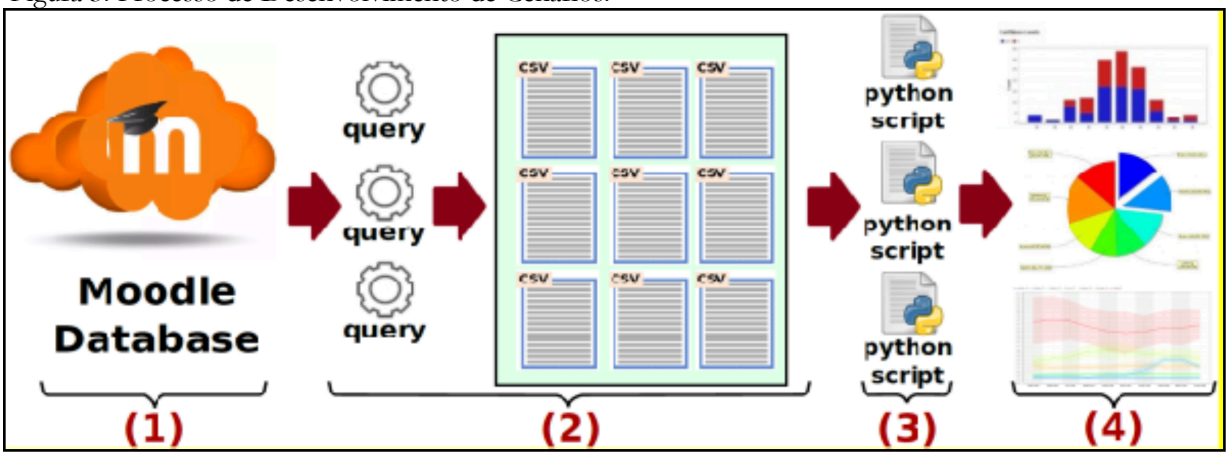

Fonte: Dados da Pesquisa.

Como prova de conceito das atividades estabelecidas, na forma de um ensaio elementar, um cenário de visualização de dados (Figura 4) foi proposto pelos gestores do NEaD/UNICENTRO. Para com os objetivos deste trabalho, o propósito deste ensaio de visualização foi: i) ratificar a forma de trabalho entre os cientistas de dados; e ii) sensibilizar os gestores quanto à forma de comunicação.

Figura 4. Gráfico para comunicação com os gestores. Cenário proposto para auxiliar a análise da distribuição dos conceitos alcançados, disciplina a disciplina, por alunos em formação do curso de graduação EaD "Letras Português e Literatura de Língua Portuguesa".

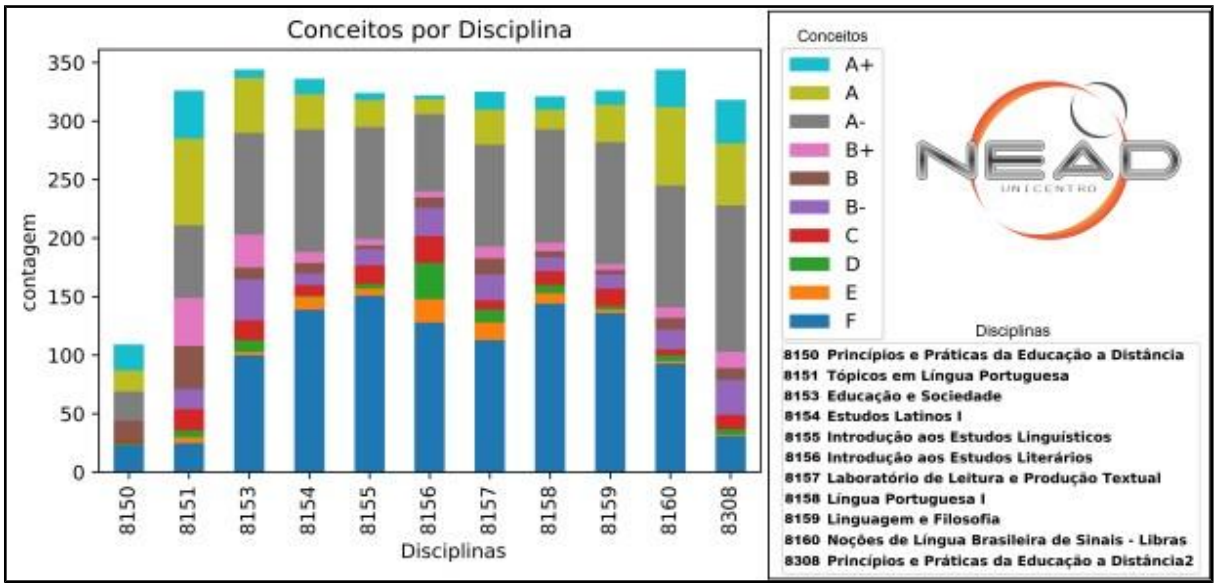

Fonte: Dados da Pesquisa.

5 Considerações Parciais

Este capítulo de livro está circunscrito a um projeto institucional, o qual objetiva a produção de elementos de análise e visualização voltados à compreensão do fenômeno da Evasão Estudantil nos cursos de graduação EaD do NEaD/UNICENTRO. Considerando a evolução dados → informação → conhecimento, o projeto institucionalizado utiliza os microdados do Ambiente Virtual de Aprendizagem MOODLE para abstrair informação útil sobre os padrões de desistência dos alunos matriculados. Consequentemente, com as informações abstraídas submetidas ao conhecimento de domínio dos gestores, pode-se amparar as ações que contribuem ao aumento dos índices de retenção dos estudantes. Em face disso, baseando-se em tecnologias da Ciência de Dados, pretende-se subsidiar um processo profícuo de Tomada de Decisão guiada por Dados no ambiente organizacional do NEaD/UNICENTO.

Neste contexto, considerando o ciclo de vida da Ciência de Dados (Bugnion; Manivannan; Nicolas, 2017) e o período de execução, o projeto encontra-se nas fases de ingestão e exploração de dados. Cronologicamente, decorreram seis meses de atividade. Apesar da infância do projeto, alguns resultados preliminares são de grande relevância ao NEaD/UNICENTRO, sendo:

O estabelecimento do workflow padrão de desenvolvimento de cenários (Figura 3).

A concepção de uma camada independente para obtenção e ingestão de dados (as queries do passo 2 – Figura 3). Como uma camada de tradução de dados, sua utilização isola a ingestão de dados com queries, mitigando os efeitos indesejáveis de versionamento do modelo de dados do MOODLE. Tal feita padroniza a utilização dos dados na visualização da informação ou na generalização de modelos.

A formalização de um meio de comunicação para com os gestores do NEaD/UNICENTRO. Mediante isso, incrementalmente, a prospecção de novos cenários e a compreensão do fenômeno da Evasão Estudantil podem ser facilitadas.

Ademais, como trabalhos futuros para com o projeto institucionalizado, pretende-se avançar à atividade de Utilização de Modelos de Aprendizagem de Máquina. Neste sentido, é prevista a

implementação de soluções baseadas em Agrupamento, Análise de Sentimentos e Modelos Preditivos. Consequentemente, almeja-se aprimorar a Tomada de Decisão nas ações pedagógicas dos gestores do NEaD/UNICENTRO.

Agradecimentos

À Secretaria da Ciência, Tecnologia e Ensino Superior (SETI/PR) pelo suporte financeiro (Projeto – Implementação da Universidade Virtual do Paraná – UVPR/SETI, Termo de Cooperação nº 145/2017, vinculado a unidade gestora do Fundo Paraná).

Referências

ABED – Associação Brasileira de Educação a Distância. **Censo EAD Brasil 2014 – Relatório Analítico da Aprendizagem a Distância no Brasil**. Curitiba, 2015.

ANDIFES, A.; ABRUEM, A.; SESu/MEC, S. Diplomação, retenção e evasão nos cursos de graduação em instituições de ensino superior públicas: resumo do relatório apresentado a ANDIFES, ABRUEM e SESu/MEC pela Comissão Especial. **Avaliação – Revista Da Avaliação Da Educação Superior**, v. 1, n. 2, p. 55-65, 1996.

BIRD, S.; KLEIN, E.; LOPER, E. **Natural Language Processing with Python**. Sebastopol: O'Reilly Media, Inc., 2009.

BÜCHNER, A. **Moodle 3 Administration**. 3ª ed. Birmingham: Packt Publishing, 2016.

BUGNION, P.; MANIVANNAN, A.; NICOLAS, P. R. **Scala: Guide for Data Science Professionals**. Birmingham: Packt Publishing, 2017. Disponível em: <https://goo.gl/kbFxEJ>. Acesso em: nov. 2015.

ECONOMIST. **The world's most valuable resource is no longer oil, but data**. Disponível em: <https://goo.gl/AW4XsF>. Acesso em: 28 jul. 2018.

GARTNER. **What is Big Data? – Gartner IT Glossary – Big Data**. Disponível em: <https://goo.gl/GwQWLA>. Acesso em: 28 jul. 2018.

JOHN, T.; MISRA, P. **Data Lake for Enterprises: Leveraging Lambda Architecture for building Enterprise Data Lake**. Birmingham: Packt Publishing, 2017.

MANYIKA, J.; CHUI, M.; BROWN, B.; BUGHIN, J.; DOBBS, R.; ROXBURGH, C. B.; HUNG, A. **Big data: The next frontier for innovation, competition, and productivity**. Disponível em: <https://goo.gl/Vg2G2U>. Acesso em: 28 jul. 2018.

MOODLE. Features – MoodleDocs. Disponível em: <https://docs.moodle.org/35/en/Features>. Acesso em: 06 set 2018.

MORÉ, R. P. O.; MORITZ, G. de O.; PEREIRA, M. F.; MELO, P. A. de. Modelo de Gestão para Educação a Distância: o Sistema de Acompanhamento ao Estudante – SAE. **RAI – Revista de Administração e Inovação**, v. 7, n. 2, p. 104-125, 2010.

NEaD. **Núcleo de Ensino à Distância da Unicentro – PR » Polos**. Disponível em: <https://goo.gl/wPYJqe>. Acesso em: 05 set. 2018.

PYTHON.ORG. **What is Python? Executive Summary | Python.org**. Disponível em: <https://goo.gl/QYghos>. Acesso em: 06 set. 2018.

SILVA, F. C. da. **Gestão da Evasão na EaD: Modelo Estatístico Preditivo para os Cursos de Graduação a Distância da Universidade Federal de Santa Catarina**. Florianópolis, 2017. 137 f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Centro Sócio-Econômico. Programa de Pós-Graduação em Administração.

UNIVERSIDADE ESTADUAL DO CENTRO-OESTE (UNICENTRO). **RESOLUÇÃO Nº 022 – PROEC/UNICENTRO, DE 16 DE JULHO DE 2018**. Disponível em:<https://goo.gl/7VcZX4>. Acesso em: 06 set. 2018.

van der AALST, W. Data Scientist: The Engineer of the Future. In: Interoperability of Enterprises Systems and Applications Conference (I-ESA'2014), 2014, Albi-France, **Proceedings…** Heidelberg: Springer, 2014.

Vídeo da apresentação

Título: Evasão estudantil e Ciência de Dados: primeiros passos de uma pesquisa aplicada no contexto da educação a distância da Universidade Estadual do Centro-Oeste.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=13

Transcrição da apresentação

Olá meu nome é Sandro Rautenberg e no WIDAT 2018 vamos apresentar o trabalho evasão estudantil e ciência de dados: os primeiros passos de uma pesquisa aplicada no contexto da educação a distância da Universidade Estadual do Centro-Oeste.

Essa apresentação segue o seguinte roteiro: uma introdução à abordagem dos materiais e métodos apresentação de resultados preliminares visto que é um trabalho em andamento as considerações parciais as referências utilizadas na apresentação seguidos pelos agradecimentos e os contatos dos autores.

Bem, para contextualizar o trabalho vamos a algumas assertivas. Primeiramente é sabido que dados atualmente são produzidos em larga escala e amplamente disponibilizados nas plataformas digitais, nesse sentido alguns estudiosos afirma que dados são como o petróleo do futuro é uma matéria prima a ser refinada para tomada de decisão e para refinar dados atualmente recorre a ciência de dados.

A ciência de dados é caracterizada como a união de métodos e tecnologias para extração de informação útil a partir de complexas e dinâmicas bases de dados, trazendo essas assertivas ao contexto do trabalho na questão de enxergar uma tríade de transformação de dados em informação e depois de informação para conhecimento esse trabalho parte do pressuposto que organizações de ensino a distância ou organizações de EAD elas podem melhorar seus processos decisórios com a utilização de tecnologias da ciência de dados.

Nesse sentido, esse trabalho se justifica pela seguinte questão as organizações EAD atualmente enfrentam um sério problema de evasão estudantil só para se ter uma ideia a taxa de evasão estudantil dessas instituições chegou aos índices de 25% dos alunos matriculados no ano de 2014 e essa também é a realidade imposta ao loco desta pesquisa, ou seja, o núcleo de educação a distância da Universidade Estadual do Centro-Oeste têm uma taxa de evasão estudantil em torno de 54% dos seus alunos em educação a distância.

Para diminuir um pouco esse índice de evasão estudantil alguns autores recomendam a construção de modelos preditivos, esses modelos baseados em dados históricos geralmente podem auxiliar os tomadores de decisão a identificar a probabilidade de outro aluno evadir por exemplo ou de extrair informações relevantes que deem suporte ao processo decisório a mudança de uma conjuntura interna nas organizações isso tudo consequentemente tentando aumentar os índices de retenção estudantil.

Trazendo essas ponderações ao contexto do núcleo de educação a distância da UNICENTRO encontra-se justificativa plausível utilizar tecnologias assim citados para construir modelos aperitivos para tratar um pouco dessa evasão estudantil por isso em junho 2018 um projeto de extensão foi criado circunscrito a um estudo da evasão estudantil mediada por tecnologias das ciências de dados.

O objetivo deste trabalho é relatar os resultados parciais deste projeto institucionalizado o projeto são institucionalizados os dados primários advém da plataforma Moodle o ambiente que oportuniza o aprendizado a qualquer momento e em qualquer lugar ao utilizar a internet como plataforma de comunicação entre os atores e os objetos de aprendizagem.

Na sua versão mais recente o Moodle armazena os dados da interação entre atores e objetos de aprendizagem em mais de 300 tabelas de dados no contexto da EAD da Unicentro cabe ressaltar que o Moodle a plataforma Moodle ela mantém o registo de cinco mil setecentos e oitenta e cinco alunos de EAD entre formandos desistentes informamos por isso da utilização desta base de dados.

Por ser uma pesquisa aplicada como procedimento metodológico adota-se o ciclo de vida de ciência de dados proposto por Bugnion; Manivannan e Nicolas (2017).

Nesse ciclo de vida da ciência de dados é composto por sete passos: inicialmente tem-se ao texto de dados das fontes primárias, após isso faça a ingestão dos dados capturados dessas fontes e uma base de dados centralizada a qual permite a exploração inicial destes dados e compreensão dos modelos da semântica inerente aos dados ali armazenados.

Caso a gente necessite trabalhar com algum modelo de aprendizagem de máquina o próximo passo é definição dos parâmetros do algoritmo a ser utilizado. Após isso implementa-se o modelo de acordo com um algoritmo e seus parâmetros para permitir a utilização de uma aplicação computacional essa aplicação computacional é voltada então para a tomada de decisão de seus gestores ou de seus usuários e como suporte tecnológico para implementação das aplicações computacionais adota-se a linguagem de programação Python e algumas das suas bibliotecas como por exemplo Pandas, Psycopg, Matplotlib, Seaborn, NLTK, Vader e Scikit-learn.

Bem, lembrando que essa apresentação é decorrente de um projeto de pesquisa em andamento não só tem uns resultados preliminares a destacar.

Primeiramente a gente destaca que o estágio atual do projeto está nas fases de ingestão de dados e exploração de dados na gestão nós estamos ainda preocupados em entender o modelo de dados do Moodle existem cerca de 300 tabelas altamente relacionadas para a manipular dados a respeito da interação do usuário para os objetos de aprendizagem à medida que a gente vai evoluindo nesse entendimento a gente vai explorando alguns dados e criando algumas constituídas ou alguns cenários iniciais como podem ser percebidos na figura ao lado deste slide.

Por isso nesse instante a gente só tem algumas considerações parciais a relatar primeiramente em relação aos resultados preliminares o primeiro passo que nós temos é a definição do wokflow padrão para desenvolvimento de cenários de exploração e visualização de dados e informação para com os gestores do núcleo de educação a distância da Unicentro.

Esse workflow pode ser percebido na figura ao lado e é constituído de quatro passos essenciais: o primeiro passo diz respeito à ingestão dos dados da plataforma moodle de lá se abstrai os dados primários esses dados primários são pré processados e validados por consultas transcritas em SQL e o resultado desse pré-processamento é armazenado centralizadamente em vários arquivos CSV os quais no terceiro passo são explorados por escrito em python e esses inscritos e por sua vez transforma esses dados em informação e essa informação então ela é visualizada através de gráficos e tabelas ou relatórios afins.

O segundo resultado parcial que nós temos diz respeito ao passo 2.9 do nosso workflow que a concepção de uma camada independente para a atenção e gestão de dados isso para mitigar os efeitos indesejados neste momento do modelo de dados do Moodle, só para constar quando começamos a trabalhar com a base do Moodle ela estava na sua versão 2.9 e atualmente está na

versão 3.3 que é muito diferente da versão 2.9 e o último resultado alcançado a relatar diz respeito à formalização de um meio de comunicação para com gestores do núcleo de educação a distância do Unicentro por vez que eles nunca utilizaram o Moodle como a ferramenta de apoio à decisão.

Como trabalhos futuros a esse projeto visa desenvolver modelos baseados em aprendizagem de máquina para suporte a tomada de decisão uma vez que estes ainda não foram contemplados no presente estágio da pesquisa. Aqui estão as referências utilizadas nesta apresentação, por fim gostaríamos de agradecer foi a Fundação Araucária pelo apoio financeiro e ao Unicentro pela disponibilidade do ambiente de execução desta pesquisa deixamos aqui também os contatos para eventuais dúvidas a respeito do projeto e sugestões para continuidade do mesmo, boa tarde a todos e tenham um bom WIDAT.

Slides da apresentação

Título: Evasão estudantil e Ciência de Dados: primeiros passos de uma pesquisa aplicada no contexto da educação a distância da Universidade Estadual do Centro-Oeste.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=13

Direito Autoral + Creative Commons: uma solução para a academia na Sociedade da Informação?

Enrique Muriel-Torrado[a] *e Rebeca Silva Fernandes de Moura Andrade*[b]

Resumo: O Direito Autoral visa proteger os autores e suas criações e buscar a disseminação do conhecimento na sociedade da informação, porém, é muitas vezes interpretado como uma lei restritiva. Desta forma, surgem alternativas de flexibilização, padronização e utilização das obras por terceiros, as licenças Creative Commons que permitem que o autor escolha a maneira que deseja que sua obra seja propagada, tornando possível que a sociedade compartilhe e consulte obras disponíveis no ambiente digital. As licenças objetivam incentivar o compartilhamento de obras de maneira organizada, seguindo o pré-estabelecido pela lei de no 9.610, que consolida e regulariza os direitos autorais no Brasil. Neste artigo, discutiremos se as licenças Creative Commons podem ser utilizadas para substituir uma lei que encontra-se desatualizada, baseando em algumas atividades comumente realizadas pelos docentes universitários na Sociedade da Informação. A metodologia utilizada foi através de levantamento bibliográfico acerca da matéria e da proposição de lista de ações que ocorrem no ambiente educacional e quais direitos atuam sobre elas. Como conclusão, percebe-se que a lei de Direitos Autorais atual não engloba todas as necessidades do usuário, sendo as licenças capazes de atuar como alternativa de proteção aos autores e oferecer aos usuários alguns direitos, mas que não pode nem deve substituir a lei.

Palavras-chave: Direito Autoral. Creative Commons. Sociedade da Informação.

Copyright + Creative Commons: a solution for academics in the Information Society Era?

Abstract: The copyright aims to protect the authors and their creations, as well as communicate knowledge in the Information Society. Despite of its goals, it is perceived as hard and prohibited. Thus, flexible alternatives rise, along with standardization and use by third parts, the named Creative Commons licenses, allowing the authors to chose the rules that govern how the work is used and publicized, making possible that general society shares and makes use of available digital work. The goal for this licenses is subsidize the organized usage, under the Law 9610 guidelines, which stablishes and regulates Copyright Ownership in Brazil. This work discusses if Creative Commons licenses can be used in substitution to an old law, based in some common activities used by the faculty members within the Information Society. The methods involved a systematic review and a proposal for actions that occur in the educational environment and which rights are involved. In conclusion, the current Authorship Law does not cover the needs from the users, and the Creative Commons licenses are a support and an alternative for author's protection and can bring a few rights, but these licenses should not be used to substitute the actual Law.

Keyword: Copyright. Creative Commons. Information Society.

a Universidade Federal de Santa Catarina (UFSC). E-mail: enrique.muriel@ufsc.br. ORCID: https://orcid.org/0000-0003-0969-9500. Currículo: http://lattes.cnpq.br/6493679032893430

b Universidade Federal de Santa Catarina (UFSC). E-mail: rebeca.moura.andrade@gmail.com. ORCID: https://orcid.org/0000-0002-3150-9032. Currículo: http://lattes.cnpq.br/7987637404192681

1 Introdução

O direito autoral sofre constantes mudanças ocasionadas pela transformação da própria sociedade, sociedade essa definida por Werthein (2000), como Sociedade da Informação (SI), que destaca que a expressão sociedade da informação passou a ser utilizada nos últimos anos deste século. Devido as transformações ocorridas, faz-se necessário que o direito autoral se adapte para que seja possível proteger as obras de maneira eficaz.

Coutinho e Lisbôa (2011) relacionam o conceito de SI ao de uma sociedade que vive em constante mutação ocasionada pelo avanço na ciência e na tecnologia.

A tecnologia é capaz de proporcionar maior possibilidade de acesso às informações e torná-las disponíveis a terceiros de maneira mais rápida e eficiente. Ao oferecer diversas possibilidades, seja no acesso ou no compartilhamento de informações, a tecnologia se torna cada vez parte integrante do dia a dia dos membros da sociedade da informação.

Pelo fato da tecnologia se fazer tão presente em nossas atividades diárias é possível considerar que o surgimento da internet reorganizou a forma de viver em sociedade e alterou a forma de comunicação drasticamente, transformando bruscamente a sociedade (BURCH, 2005).

O aumento exponencial de possibilidades de acesso à internet e de oferta de tecnologia contribuem com a divergência entre as necessidades demandadas pela população há 20 anos, quando a Lei brasileira de Direitos Autorais (LDA) foi promulgada, com as necessidades demandadas atualmente pela sociedade da informação, pois a tecnologia contribui para que o conhecimento flua e torne-se ultrapassado em velocidade muito maior que anteriormente.

Na atualidade, algumas correntes apontam que existe maior necessidade de proteção das obras ao considerarmos que elas são disponibilizadas e acessadas facilmente no ambiente digital. Desta forma, faz-se necessário que tanto as obras de autores que desejam compartilhá-las, como aquelas cujo autor não deseja tal difusão no ambiente digital, sejam resguardadas legalmente de modo a proteger os autores de utilização indevida de suas criações por terceiros.

O direito autoral é definido por Duarte e Pereira (2009) como: "[…] o poder que o autor, o criador, o tradutor, o pesquisador ou o artista tem de controlar o uso que se faz de sua obra. Basicamente os direitos autorais trabalham com a imaterialidade, sendo esta, a principal particularidade da propriedade intelectual."

No Brasil o direito autoral está consolidado à lei de nº 9.610, aprovada em 19 de fevereiro de 1998 (BRASIL, 1998), que surgiu para, conforme seu próprio preâmbulo, normatizar, consolidar e atualizar leis brasileiras já existentes. A lei específica que regula a matéria é fruto da evolução de diversas leis brasileiras e tratados internacionais, como apresentado no apêndice A.

Conforme Dias e Oliveira (2015) o direito autoral nasce exatamente no momento de criação da obra, ou seja, quando uma obra é cadastrada em suporte material em concomitância nasce também o direito autoral para proteger e garantir que todos os direitos sejam reservados ao autor.

O direito autoral busca proteger os autores, e frequentemente é interpretado como elemento restritivo. Na tentativa de solucionar essa perspectiva restritiva e buscar alternativas de flexibilização de uso das obras surgem as licenças Creative Commons.

As licenças Creative Commons configuram-se como uma camada de proteção sobre a LDA ao permitir a utilização de obras, protegidas por direito autoral, de maneira flexível oferecendo ao

autor o poder de escolher como compartilhar suas criações ao mesmo passo que explica aos usuários como utilizá-las respeitando as condições de uso impostas pela licença escolhida pelo autor.

Segundo Muriel-Torrado (2012) as licenças Creative Commons são as licenças mais conhecidas e desenvolvidas a nível internacional, além de buscar, como ideia principal, contribuir com o acesso e compartilhamento da informação ao público.

Importante destacar que as licenças Creative Commons indicam tipos diferentes de permissões de utilização das obras, ficando a critério do autor restringir mais ou menos a utilização da mesma por terceiros.

2 Objetivos

No presente artigo caracterizaremos a sociedade da informação, bem como o direito autoral e buscaremos alternativas flexíveis de uso das obras, através das licenças Creative Commons.

Como objetivo geral da pesquisa pretende-se identificar se algumas das principais atividades desenvolvidas pelos acadêmicos, que entram em conflito com os direitos autorais, poderiam ser sanadas com a utilização das licenças Creative Commons.

Busca-se também identificar se as licenças Creative Commons são suficientes para que os professores possam exercer essas atividades, substituindo assim a LDA ou se é necessário continuar modificando a lei para atender as demandas dos profissionais da docência.

3 Procedimentos Metodológicos

O procedimento metodológico é uma pesquisa bibliográfica, exploratória, qualitativa e descritiva. Começando pela elaboração de uma breve listagem atividades exercidas no ambiente educacional on-line pelos professores universitários (baseado em MURIEL-TORRADO, 2012), para posteriormente relacionar essas atividades exercidas nas atividades docentes com os direitos autorais que estão por trás e assim identificar se poderíamos considerar as licenças Creative Commons como substitutas da LDA, claramente desatualizada na sua aplicação no contexto da Sociedade da Informação.

4 Resultados

Entre as atividades docentes que desempenha um professor nas suas funções, podemos destacar (baseado em MURIEL-TORRADO, 2012): 1) Fazer upload de obras intelectuais no Moodle ou plataformas similares; 2) envio de artigos ou outras obras protegidas por e-mail para os alunos da turma ou companheiros; 3) Baixar obras da internet; 4) Fotocopiar ou digitalizar obras; 5) ou compartilhar fotocópias de obras com os alunos.

Segundo a Lei Brasileira de Direitos Autorais, para a primeira ação os direitos afetados seriam: reprodução e comunicação pública, já que primeiro subimos uma cópia da obra e depois a disponibilizamos para um conjunto de pessoas sem cópias físicas; no caso do envio de artigos por e-mail para uma turma, além da reprodução da obra efetuada para subir no e-mail, igual do que no anterior, se produz uma comunicação pública da mesma; para realizar um download de arquivos da internet afeta-se o direito de reprodução das obras; no caso de fotocopiar ou digitalizar arquivos tem-se o direito de reprodução afetado; e, por fim, para compartilhar

fotocópias de obras com a turma afeta-se o direito de distribuição, pois seria em um suporte físico tangível.

Para cada ação desenvolvida e seu direito afetado, apresentados acima, nota-se que só é possível realizá-la dentro das exceções e limitações apresentadas no art. 46 da LDA ou com a permissão do titular dos direitos. Estas possibilidades restringiriam significativamente a utilização, por exemplo, de obras completas, embora fosse para fins de estudo. Mas se essas mesmas obras estivem licenciadas com Creative Commons (com quaisquer das suas opções) não feriria os legítimos direitos dos titulares dos direitos. Desta forma, as obras poderiam ser compartilhadas, subidas no Moodle, baixadas, enviadas por qualquer meio digital ou fotocopiadas, isto é, utilizadas de maneira muito mais flexível, de acordo com a licença adotada pelo autor e sem precisar solicitar nenhuma permissão.

Cabe ressaltar que a lei brasileira de direitos autorais em seu art. 68 (BRASIL, 1998) esclarece que sem autorização prévia e expressa do autor suas criações não poderão ser utilizadas. Desta forma, a comunicação pública, seja ela no ambiente educacional ou não, depende de prévia autorização do autor ou titular da obra, caso contrário, há infração dos direitos de autor.

5 Conclusão ou Considerações Finais

Após análise é possível notar que a lei de direitos autorais brasileira, por si só, não contempla as necessidades demandadas pela atual sociedade da informação, particularmente no que se refere à reprodução, tradução e compartilhamento da informação científica no ambiente digital, nem mesmo mediante as exceções e limitações recolhidas no Capítulo IV da lei.

Por este motivo surgiram alternativas complementares que tornam possível a proteção dos autores e ao mesmo tempo que oferece aos usuários alguns direitos e flexibilidade na utilização das obras. Isto se articula principalmente mediante as licenças Creative Commons, que permitem que os autores possam compartilhar os direitos que considerem oportunos e se reservar outros, conforme sua própria escolha.

Embora as licenças Creative Commons sejam uma excelente ferramenta, devemos lembrar que a LDA protege às obras desde o ato de criação, não havendo exigência de que as obras sejam registradas para que sejam protegidas. Por outro lado, utilizar as licenças Creative Commons é um ato voluntário, aonde o autor precisa licenciar sua obra e decidir qual tipo de licença irá atribui-la. Embora as licenças sejam muito importantes, precisam obrigatoriamente de uma LDA para poder existir, e essa mesma lei precisa também de reformas adequadas para melhorar seus fins. Mas, as licenças oferecem uma flexibilidade fundamental para otimizar o trabalho de docentes e alunos, requerendo apenas um pequeno aprendizado para desfrutar das mesmas. Por outro lado, seria interessante uma estratégia conjunta de melhora da legislação para esses fins e a implantação de uma política pública no Ministério de Educação orientada à formação assim como uma aplicação padrão de licenças Creative Commons nos materiais utilizados no ensino no Brasil como um todo, para que professores e alunos possam utilizar materiais educativos no ambiente digital dentro da legislação.

Referências

BRASIL. **CONSTITUIÇÃO DA REPÚBLICA DOS ESTADOS UNIDOS DO BRASIL, DE 24 DE FEVEREIRO DE 1891.** Organiza um regime livre e democrático, 1891. Disponível em: <http://www.planalto.gov.br/ccivil_03/constituicao/constituicao91.htm>. Acesso em: 20 set. 2018.

BRASIL. **CONSTITUIÇÃO DA REPÚBLICA FEDERATIVA DO BRASIL, DE 05 DE OUTUBRO DE 1988.** Institui um Estado Democrático, 1988. Disponível em: <http://www.planalto.gov.br/ccivil_03/constituicao/constituicaocompilado.htm>. Acesso em: 10 set. 2018.

BRASIL. **DECRETO Nº 4.790, DE 2 DE JANEIRO DE 1924.** Regula os direitos autorais e dá outras providências., 1924. Disponível em:<http://www2.camara.leg.br/legin/fed/decret/1920-1929/decreto-4790-2-janeiro-1924-565512-republicacao-89686-pl.html>. Acesso em: 12 set. 2018.

BRASIL. **DECRETO Nº 75.699, DE 6 DE MAIO DE 1975.** Promulga a Convenção de Berna para a Proteção das Obras Literárias e Artísticas, de 9 de setembro de 1886, revista em Paris, a 24 de julho de 1971. Disponível em:<http://www.planalto.gov.br/ccivil_03/decreto/1970-1979/D75699.htm>. Acesso em: 12 set. 2018.

BRASIL. **LEI Nº 496, DE 01 DE AGOSTO DE 1898.** Define e garante os Direitos Autorais, 1898. Disponível em: <http://www2.camara.leg.br/legin/fed/lei/1824-1899/lei-496-1-agosto1898-540039-publicacaooriginal-39820-pl.html >. Acesso em: 20 set. 2018.

BRASIL. **LEI Nº 3.071, DE 01 DE JANEIRO DE 1916.** Código Civil dos Estados Unidos do Brasil,1916. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/L3071.htm>. Acesso em: 20 set. 2018.

BRASIL. **LEI Nº 5.988, DE 14 DE DEZEMBRO DE 1973.** Regula os direitos autorais e dá outras providências., 1973. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/L5988.htm>. Acesso em: 21 set. 2018.

BRASIL. **LEI Nº 9.609, DE 19 DE FEVEREIRO DE 1998.** Dispõe sobre a proteção da propriedade intelectual de programa de computador, sua comercialização no País, e dá outras providências., 1998. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/l9609.htm>. Acesso em: 10 set. 2018.

BRASIL. **LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998.** Altera, atualiza e consolida a legislação sobre direitos autorais e dá outras providências., 1998. Disponível em:<http://www.planalto.gov.br/ccivil_03/LEIS/L9 610.htm>. Acesso em: 10 set. 2018.

BURCH, Sally. **Sociedade da informação versus Sociedade do conhecimento.** In: Desafios de Palavras: Enfoques Multiculturais sobre as Sociedades da Informação, nov., 2005. Disponível em: < https://vecam.org/archives/article519.html>. Acesso em: 19 set. 2018.

COUTINHO, Clara; LISBÔA, Eliana. **Sociedade da Informação, do Conhecimento e da Aprendizagem: desafios para educação no século XXI.** 2011. Disponível em:<http://revista.educ.ie.ulisboa.pt/arquivo/vol_[XVIII_1/artigo1.pdf>. Acesso em: 17 set. 2018.

DIAS, Guilherme Ataíde. OLIVEIRA, Bernardina M. J. Freire de. **Informação, Direito Autoral e Plágio.** João Pessoa, 2015.

DUARTE, Eliane Cordeiro de Vasconcellos Garcia; PEREIRA, Edmeire Cristina. **Direito Autoral: Perguntas e Respostas.** Curitiba: UFPR, 2009.

DUDZIAK, Elisabeth Adriana. **Licenças Creative Commons: saiba mais sobre isso.** 2016. Disponível em: <http://www.sibi.usp.br/?p=5763> Acesso em: 20 set. 2018.

MURIEL-TORRADO, Enrique. **Los derechos de autor y la enseñanza en la universidad: el papel de la biblioteca universitaria.** 2012. Tese (Doctorado en Documentación) – Facultad de Comunicación y Documentación, Universida?

Apêndice A – Evolução das Leis de Direito Autoral no Brasil.

Lei	Abrangência
Constituição Federal de 1891	Foi a primeira legislação a tratar do tema de direito autoral e, mesmo tendo sido promulgada dois anos após o nascimento da República, já se preocupava com os direitos relacionados aos autores.
Lei nº 496 de 1898	Foi a primeira lei específica a regular a matéria e ela define e garante os direitos autorais no país. Posteriormente complementada com a Convenção de Berna que aconteceu em 1886.
Lei nº 3.071 de 1916 (Código Civil	Regulamentou o direito autoral nos arts. 649 a 673. Fez com que a lei nº 496 perdesse sua eficácia e fosse revogada por completo.
Decreto nº 4.790 de 1924	Esse decreto instituiu o direito autoral no Brasil, preocupando-se com composições teatrais e musicais.
Lei nº 5.988 de 1973	Regula direitos de autor e direitos que lhe são conexos e parte dessa legislação vigorou até 1998 com lei atual de direito autoral.
Decreto nº 75.699 de 1975	Ratifica a convenção de Berna (Suíça).
Constituição Federal de 1988	A CF expõe em seu art. 5º que aos autores pertence o direito exclusivo de utilização, publicação ou reprodução de suas obras, transmissível aos herdeiros pelo tempo que a lei fixar.
Lei nº 9.609 de 1998	Essa lei dispõe sobre a proteção da propriedade intelectual de programa de computador, sua comercialização no País. Sendo conferido às obras literárias pela legislação de direitos autorais e conexos vigentes no País.
Lei nº 9.610 de 1998	Essa lei, que se encontra atualmente vigente, veio para ampliar os direitos e garantias dos autores de obras.

Fonte: Elaborado pelos autores – 2018.

Vídeo da apresentação

Título: Direito Autoral + Creative Commons: uma solução para a academia na Sociedade da Informação?

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=14

Transcrição da apresentação

Olá eu sou Rebeca Silva Fernandes de Moura criei um artigo juntamente com o meu orientador professor Enrique Muriel Torrado, nós somos da Universidade Federal de Santa Catarina do programa de pós-graduação em ciência da informação e esse artigo foi intitulado Direito Autoral Creative Commons uma solução para a academia na Sociedade da Informação.

Primeiramente vou contextualizar um pouco do direito autoral da sociedade da informação para investigarmos das licenças propriamente ditas.

O direito autoral ele busca proteger o autor e suas obras a partir do momento que a obra é criada, porém ele é visto como a lei restritiva embora não tenha sido esse o intuito de sua criação ele é visto por impor apenas restrições de uso as obras é quando terceiros vão utilizá-las mais não é só com essa finalidade, ele nasceu então pra sanar a utilização das obras, porém por ser uma lei criada especificamente 1998 ela encontra-se desatualizada principalmente quando a gente considera esse ambiente da sociedade que a gente vive o que é denominada por diversos autores como a sociedade da informação, porque é uma sociedade que está rodeado pela tecnologia é uma sociedade que vive em constante mudança da sociedade que utiliza o ambiente digital tanto para compartilhar como pra baixar.

Utiliza-se esse ambiente fortemente nos seus estudos podemos dizer no seu dia a dia então pelo fato então dessa tecnologia se fazer tão presente na nossa sociedade da informação nós precisamos de uma lei que considera essa tecnologia e hoje a nossa lei de direito autoral não considera por ter sido uma lei criada na época pré Internet já que a internet também chega no Brasil em 98.

Duarte e Pereira (2009) definiu o direito autoral de uma forma muito clara que eu gostaria de destacar que é o direito autoral é o poder que o autor o criadouro tradutor o pesquisador ou um artista tem de controlar o uso que faz de sua obra.

Hoje o direito autoral basicamente se divide em dois direitos morais que é um direito que o autor tem a paternidade da obra que ainda é alienável o direito patrimonial que está ligado ao valor econômico que a obra já pode gerar e esse sim pode ser transferido, cedido doado, vendido a terceiros, se assim o autor desejar. Por isso que essa definição de Duarte e Pereira é tão clara quando ele fala que o ali tem o direito de controlar o uso que faz da sua obra.

Dias e Oliveira (2015) eles dispõe ainda que o direito autoral então surge quando a obra é cadastrada em suporte material, ou seja, nasce a obra nasce o direito autoral.

Como falei anteriormente, a lei de direito autoral por ser vista de maneira tão restritiva por impor muito mais obrigações podemos dizer assim dentro do que é livre utilização nasce então nessa perspectiva alternativa de flexibilização do uso das obras que seriam as licenças nesse caso específico falaremos das licenças Creative Commons.

Então essas licenças elas permitem utilizar as obras protegidas por direito autoral de maneira mais flexível e ao mesmo tempo ela oferece ao autor o poder de escolher como compartilhar suas criações, elas não nascem juntamente com a obra o autor precisa querer registrá-la, querer licenciar suas aulas através dessas licenças porém elas são mais flexíveis elas permitem flexibilidade.

Quem escolhe o nível de flexibilidade então é o autor ele pode flexibilizar mais ou menos a sua obra depende apenas dele.

Segundo Muriel Torrado (2012) ele expôs que as licenças Creative Commons elas são licenças mais conhecidas em desenvolvidas a nível internacional, além de buscar como ideia principal contribuir com o acesso e compartilhamento da informação ao público, ou seja, então elas indicam tipos diferentes de permissão de utilização das obras ela fica apenas como falei, no entanto, o autor defini-as.

Então essa pesquisa tem como objetivo geral identificar algumas das principais atividades desenvolvidas no meio acadêmico que entra em conflito com direitos autorais, se elas podem ser sanadas com a utilização dessas licenças e busca-se também identificar se a lei de direito autoral elas são suficientes pra sanar tudo que a lei de direito autoral hoje emprega e se elas podem substituir a lei ou se precisa ter uma lei e as licenças flexibilizando o uso

Então como procedimento metodológico da pesquisa foi utilizado a pesquisa bibliográfica exploratória qualitativa, descritiva.

Iniciou-se com breve listagem de atividades que são exercidas no ambiente educacional online e posteriormente foi relacionado essas atividades desenvolvidas com os direitos que elas afetam da seguinte forma: citarei apenas algumas, por exemplo, fazer upload de obras intelectuais no Moodle ou plataformas similares hoje um professor para disponibilizar uma obra ele acessa o Moodle que a nossa plataforma utilizada e ele faz o upload de uma obra de terceiros para os seus alunos essa ação então ela afeta o direito de reprodução quando a gente sobe é fazer o plantio dessa cópia e afeta também a comunicação pública porque disponibiliza-se para terceiros uma obra.

Outra ação seria enviar artigos ou obras protegidas por e-mail para os alunos, afeta-se também o direito de reprodução e cria-se uma comunicação, isso produz uma comunicação pública da obra, fotocopiar obras, por exemplo, afeta seu direito de reprodução então como a gente pode notar a cada atividade desenvolvida no ambiente educacional ela afeta um direito, porém é possível realizar dentro das exceções e limitações impostas a partir do artigo 46 da lei de direito autoral mas é preciso é solicitar permissão do autor, essa permissão então a gente sabe que é difícil de conseguir então se as obras estivessem cadastradas com licenças elas e o autor permitisse fotocopiar obra, por exemplo, não seria necessário pedir nenhuma autorização então seria o que seria muito mais flexível a utilização e fácil.

Então a gente nota que além de direito autoral por si só ela não contempla todas as demandas da nova sociedade da informação por não considerar principalmente ambiente digital e tal compartilhamento então essas licenças elas surgem como alternativas complementares para proteger as obras mais flexibiliza o uso.

E por fim então a gente conclui que as licenças apesar de auxiliar bastante no processo criativo através dessa flexibilização de uso elas precisam sim obrigatoriamente de uma lei de direito autoral e elas complementariam a lei de direito autoral então nossa lei de direito autoral precisa hoje de reformas adequadas para melhorar os seus fins e sim essas licenças que podem auxiliá-las.

Design audiovisual para sistemas generativos: um experimento de construção audiovisual personalizada

Rafael Moura Toscano da Nóbrega[a], *Valdecir Becker*[b], *Helder Bruno Alves Mendonça de Souza*[c] *e Marianna C. Teixeira*[d]

Resumo: A produção de conteúdos audiovisuais tem se tornado uma atividade cada vez mais complexa a medida que novos recursos de interação, compartilhamento, diferentes telas e formas de visualização vem se popularizando. Diante deste cenário, surge a Arquitetura do Design Audiovisual (DA) como um instrumento teórico-metodológico de análise e criação de sistemas audiovisuais. O propósito deste artigo é descrever o processo de construção de um sistema audiovisual baseado em dados dos indivíduos para estabelecer uma fruição de conteúdo personalizada. A construção do sistema revelou que os elementos disponíveis no DA como linhas de design, papéis e gatilhos são elementos potenciais para criação deste tipo de sistema.

Palavras-chave: Design Audiovisual. Generativo. Personalização.

Audiovisual design for generative systems: a customized audiovisual construction experiment

Abstract: The production of audiovisual content has become an increasingly complex activity as new features of interaction, sharing, different screens and forms of visualization are becoming popular. In view of this scenario, the Architecture of Audiovisual Design (DA) arises as a theoretical-methodological instrument of analysis and creation of systems. The purpose of this article is to describe the process of building an audiovisual system that is based on individuals' data to establish a personalized content enjoyment. The construction of the system revealed that the elements available in the DA as design lines, roles and triggers are potential elements for the creation of this type of system.

Keyword: Audiovisual Design. Generative. Customization.

a Universidade Federal da Paraíba (UFPB). E-mail: rafaelmtoscano@gmail.com. ORCID: https://orcid.org/0000-0003-1732-7600. Currículo: http://lattes.cnpq.br/2598640098965634

b Universidade Federal da Paraíba (UFPB). E-mail: valdecir@ci.ufpb.br. ORCID: https://orcid.org/0000-0002-0639-3875. Currículo: http://lattes.cnpq.br/0361321038384701

c Universidade Federal da Paraíba (UFPB). E-mail: brunoarpeggi@gmail.com. ORCID: https://orcid.org/0000-0001-6515-8253. Currículo: http://lattes.cnpq.br/0400991458412353

d Universidade Federal da Paraíba (UFPB). E-mail: mariannactx@gmail.com

1 Introdução

O desenvolvimento de conteúdos audiovisuais tem se tornado uma atividade cada vez mais complexa a medida que novos recursos de interação, compartilhamento, diferentes telas e formas de visualização vem se popularizando. A experiência audiovisual, antes majoritariamente ocupada pelo cinema e televisão, hoje torna-se mais abrangente, podendo envolver desde pesquisas na Internet a complexos algoritmos de recomendação, colaboração e adaptação de conteúdo. Uma característica deste cenário é a presença e o uso de softwares para compor a experiência de fruição das obras audiovisuais. A expansão do poder de processamento e o aumento do acesso a uma conexão de rede estável viabilizam um cenário em que produtores de conteúdo audiovisual estão cada vez mais próximos de programadores, designers de interação e cientistas de dados.

Um vídeo online, filme, jogo ou mesmo uma novela, são exemplos de como as mídias de representação (áudio e vídeo) podem ser empregadas na construção de uma experiência estética e comunicacional. Se por um lado, temos as discussões acerca das tecnologias de captura e representação promovidas pela Computação, do outro temos as discussões no campo da Comunicação e Artes sobre os valores e significados que podem ser gerados pelo conteúdo que está sendo exposto.

A partir deste contexto computacional e midiático complexo é possível identificar discussões e experimentos que dialogam com a capacidade de geração de narrativas audiovisuais a partir da coleta de dados da audiência. Se nas primeiras produções cinematográficas e televisivas era inviável pensar a construção de conteúdos adaptados a interesses individuais ou de pequenos grupos, devido ao alto custo de produção e distribuição, hoje, com o aumento do processamento computacional e alcance de rede, este cenário torna-se cada vez mais viável.

Diante deste contexto complexo da utilização de mídias audiovisuais, surge a discussão teórica-metodológica do Design Audiovisual (DA). Inicialmente proposta na pesquisa de Becker, Gambaro e Ramos (2017), o DA integra aspectos de Mídia e Recepção da Comunicação a ferramentas e conceitos da Interação Humano Computador (IHC), com o intuito de auxiliar na descrição, análise e criação de sistemas audiovisuais. Em uma segunda publicação o DA é caracterizado pelos autores como uma arquitetura de conteúdo e interação capaz de atender a contextos de historicidade e generatividade, isto é, cenários em que tanto a interação quanto os dados do usuário são utilizados pelo sistema na oferta de conteúdo (TOSCANO et al., 2017).

2 Objetivo

Com o intuito de avançar a proposição dos estudos citados, este trabalho propõem a aplicação experimental do Design Audiovisual como a arquitetura de um projeto generativo, ou seja, um sistema que integra dados do usuário e interação para a geração de conteúdo. Tal estudo está sendo realizado pelos pesquisadores do Grupo de Pesquisa Design Audiovisual (GPDA) junto ao Laboratório de Aplicações em Vídeo Digital (LAVID) no âmbito das atividades de um projeto destinado ao Tribunal de Contas do Estado da Paraíba.

3 Bases teóricas e conceituais

O desenvolvimento da capacidade de processamento computacional, bem como o surgimento de novos sensores permitiram aos softwares formas inovadoras de capturar e

interpretar dados, isto é, compreender melhor o que significa a informação que está sendo capturada, processada e reproduzida (HANJALIC; LI-QUN XU, 2005; HAVALADAR; MEDIONI, 2010; HUGHES et al., 2014; KYBARTAS; BIDARRA, 2017).

Em paralelo aos estudos da computação é possível identificar uma crescente discussão acerca de diferentes modos de interação e fruição, presente na comunidade de pesquisadores dos estudos de mídia. Um cenário de múltiplos meios e formas de recepção (JENKINS; FORD; GREEN, 2014); em que os sistemas também atuam como parceiros do discurso (MANOVICH, 2013); e revelam o surgimento de novos padrões e convenções no processo de comunicação, representação e fruição audiovisual (MURRAY, 2011).

Assim como os estudos computacionais aproximam-se do valor semântico de seus dados, produtores e artistas do meio audiovisual também vem incorporado na criação de conteúdo o uso de dados e contextos diversos de interação para aprimorar suas premissas narrativas e comunicacionais.

3.1 Customizar, adaptar e personalizar

Os termos customização, adaptação e personalização são retratados na literatura de modo ligeiramente distintos. A lógica da customização aparece em contextos de oferta de recursos aos indivíduos para que estes possam ajustar elementos pré-estabelecidos conforme seus interesses. Já o termo adaptação é retratado em sua maioria a contextos técnicos como adequação a requisitos de rede, dimensão de tela ou acessibilidade. Por fim, a ideia de personalização está normalmente associada a filtragem de informações sobre a audiência de tal modo a recomendar, reposicionar, inserir, excluir, exibir determinado conteúdo ou modo de interação (AMY SCHADE, 2014; BARBOSA; SILVA, 2010; ELMAGARMID, 1997; GUERRINI et al., 2017; MEIXNER, 2017; XU; JIN; LUO, 2008).

Tendo compreendido a ideia de personalização, se faz necessário entender o que pode ser personalizado. Kybartas e Bidarra (2017) conceituam que a geração de elementos para personalização da experiência narrativa audiovisual passam por níveis estruturais distintos. O elemento mais geral é a narrativa, que é exatamente a forma ou expressão encontrada para apresentar uma história. Já a história é conjunto de elementos que constituem uma relação linear. As histórias são compostas por tramas que por sua vez são compostas por eventos dramáticos.

Uma história pode ser contada a partir de diversas formas narrativas, do mesmo modo que uma mesma história pode ter tramas variáveis que permitam a audiência multi-tramas e percepções. Essa abordagem estruturalista apresentada por Kybartas e Bidarra (2017) nos ajuda a compreender os níveis em que a ação dos sistemas digitais podem atuar de modo a impactar o conteúdo e a fruição dos indivíduos.

4 Procedimentos Metodológicos

A arquitetura do Design Audiovisual é a base conceitual e metodológica deste estudo. O DA descreve essencialmente quatro funções, ou papéis, que os indivíduos podem assumir enquanto consomem conteúdo audiovisual: Audiência, que representa uma fruição passiva dos conteúdos; Sintetizador, onde os indivíduos organizam, compartilham e comentam conteúdos em redes sociais; Modificador, que corresponde às pessoas que se apropriam de conteúdos e os modificam;

e Produtor, que representa os indivíduos, empresas e software que geram conteúdos novos. Cada papel tem seus níveis elevados, descritos como Player, quando estes se envolvem e usam todos os recursos disponíveis, ou, ainda, alteram totalmente os propósitos do conteúdo e do sistema.

Para o Design Audiovisual as relações de interação inerentes a esses níveis ocorrem por meio de quatro Linhas de Design: (a) Conteúdo; (b) Identidade, que baseia a relação pessoal com o conteúdo; (c) Motivação, que leva ao engajamento; e (d) Experiência, que relaciona a fruição à utilização avançada de recursos, que devem proporcionar uma experiência prática ou simbólica com o conteúdo e interfaces (ver apêndice A).

As Linhas de Design tem o intuito de auxiliar o desenvolvedor do sistema audiovisual (conteúdo e software) na elaboração do projeto de interação, engajamento e conteúdo de sua produção a partir de variáveis que impactam a fruição dos indivíduos.

Outro conceito relevante para a arquitetura do DA é a criação de gatilhos, que surgem das Linhas de Design do projeto. Um gatilho é qualquer elemento adicionado ao longo da interação com o intuito de estimular ações dos indivíduos. Podem vir como elementos sonoros, visuais, de interface, interação ou mesmo chamadas de ação no próprio conteúdo.

O DA será utilizado como base de descrição e criação deste trabalho à medida que propõe um conjunto de variáveis ou camadas relacionais que devem ser consideradas por produtores de conteúdo dentro de um contexto de uso de mídia complexo. De modo geral, as etapas que compõem o desenvolvimento a partir da arquitetura do Design Audiovisual, são:

- Identificar objetivo, principais usos do sistema e personas;
- Delimitar Linhas de Design;
- Projetar Gatilhos e Affordances;
- Desenvolver sistema (conteúdo e interface)[61];
- Testar o sistema.

Nas seções seguintes detalha-se a aplicação destes conceitos na construção do sistema audiovisual generativo.

5 Resultados

O sistema apresentado neste trabalho compõe um projeto que integra estudantes da rede pública em um conjunto de atividades de produção, visita e acompanhamento das ações do TCE-PB. Neste cenário, alunos da rede pública são convidados pelos professores a produzir vídeos sobre casos de sucesso ou aspectos ineficientes de sua comunidade escolar.

O conteúdo audiovisual que resulta desta ação tem como destino uma página do TCE-PB na mídia social Facebook a partir do perfil de cada estudante. No ato da publicação do material, cada aluno descreve o nome de sua escola, cidade e uso de uma hashtag pré-determinada.

Após essa etapa, realizada pelos alunos, o professor responsável pela turma vai até um portal do TCE-PB, e com o seu login do Facebook tem a opção de revisar os conteúdos que foram identificados pelo sistema via a API GRAPH[62] conforme apresentado na figura 1.

61 Nesta etapa são utilizados processos e ferramentas comuns a produção de vídeo e engenharia de software.
62 API disponibilizada pelo Facebook para a utilização de informações do usuário em serviços web externos.

Essa coleta de dados (vídeo, nome do usuário e escola) serve a dois sistemas, são eles: sistema de visualização avançada e colaborativa via mapa da Paraíba; sistema de apoio a palestras, também denominado de gerador de vídeos personalizados.

Figura 1: Painel de Gerenciamento.

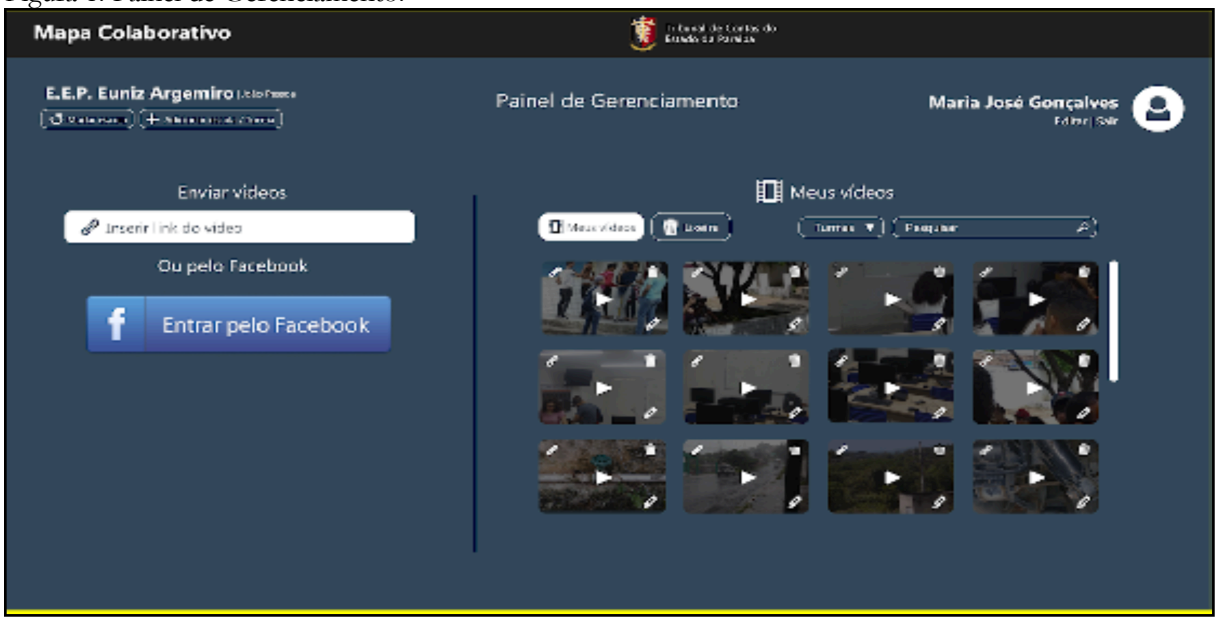

Dados da Pesquisa, 2018.

5.1 Sistema de vídeos personalizados

O TCE-PB recebe mensalmente estudantes da rede pública para conhecer sua estrutura física e atuação na sociedade. Como uma das estratégias de integrar esses visitantes na temática do controle social e educação fiscal, propõe-se então um sistema de apoio a palestras que tem o objetivo de integrar produtos audiovisuais institucionais a produção colaborativa dos estudantes, com o intuito de personalizar a experiência de cada turma que visita o TCE-PB.

Aplicando a arquitetura do Design Audiovisual na construção deste sistema temos a seguinte proposta: a partir de um vídeo institucional, que define a linha de Conteúdo, e que conceitua a importância da população nos atos de fiscalização e acompanhamento da gestão pública, os vídeos dos alunos são inseridos como elementos integrante a narrativa (Linha de Identidade e Motivação), conforme a figura 2. O vídeo personalizado, isto é, gerado com base nos dados dos estudantes dispõe da seguinte estrutura:

Parte 1: Contextualização sobre aspectos da má gestão e corrupção, e como a participação popular é importante para combater e acompanhar as falhas na gestão pública. Seguindo a arquitetura do DA, nesta etapa do vídeo devem ser trabalhados recursos narrativos (ritmo de edição, trilha sonora, formas de expressão, entre outros) que sejam coerentes com os estudantes de tal modo a estimular a atenção e interesse pelo tema.

Parte 2: Exemplos de atitudes de controle social a partir dos vídeos de alunos. Seguindo a arquitetura do DA, a utilização dos vídeos dos próprios alunos atua como um Gatilho da Inércia, um estímulo à atenção e formação de Identidade e afinidade com o conteúdo.

Parte 3: Especialistas explicam que os atos dos estudantes representam o controle social, sendo este fundamental para a sociedade. Seguindo a arquitetura do DA, nesta etapa do vídeo utiliza-se os princípios da Linha de Conteúdo e Identidade, uma vez que a participação dos alunos é tratada em nível de conteúdo como parceira do TCE-PB.

Parte 4: Crédito do filme com o nome dos participantes (especialistas, escola e alunos). Esta etapa é um Gatilho da Inércia, uma vez que atua como estímulo a atenção e formação de Identidade e afinidade com o conteúdo.

Parte 5: Disponibilização de QR code para compartilhamento do vídeo. Seguindo a arquitetura do DA, esta etapa atua como um Gatilho de Ação, que a partir da Identidade estimula o estudante (Audiência) a alternar o papel para Sintetizador, ao compartilhar o material em suas próprias mídias sociais.

Figura 2: Abstração da personalização narrativa

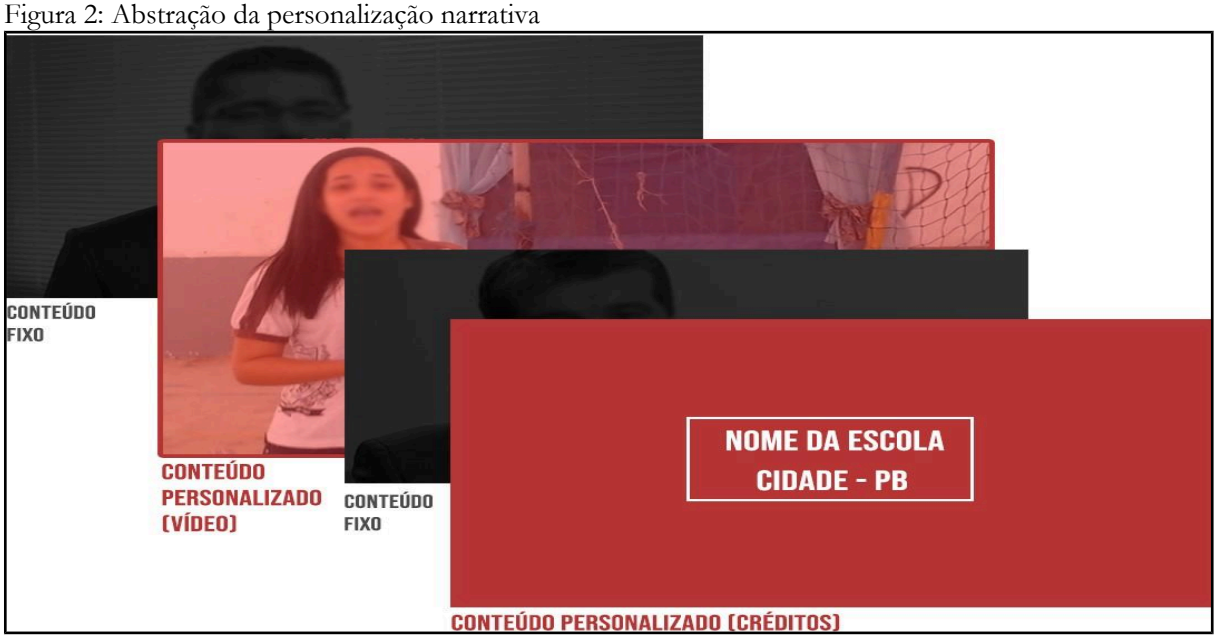

Dados da Pesquisa, 2018.

Outras linhas de design que podem ser impactadas pelo sistema são a Motivação e Experiência. Uma vez que este material personalizado a partir dos dados dos indivíduos é disponibilizado em um formato de arquivo compatível com mídias sociais (Youtube, Facebook ou Whatsapp) é possível viabilizar cenários em que os estudantes possam modificar, editar ou mesmo remixar o conteúdo.

Para garantir tal cenário de fruição e interação, foram delimitados os seguintes requisitos funcionais para o sistema: Estabelecer conexão com o Facebook via API Graph; Incorporar hashtag, vídeo, nome do estudante e escola a partir de uma postagem pública no Facebook; Inserir os dados importados dentro do projeto vídeo "Controle Social"; Renderizar todo o material (vídeos institucionais fixos, personalizáveis e dados) de modo a gerar um único arquivo de vídeo que seja compatível com HTML5 e serviços como youtube e vimeo;

6 Considerações Finais

Este trabalho se propôs experimentar a arquitetura do DA como base para a construção de um sistema generativo. A possibilidade de adaptar o conteúdo instaura um cenário emergente para os estudos de mídia, a criação de conteúdo para fruição individual ou social (pequenos grupos de pessoas) ao invés do tradicional modelo Broadcasting.

A pesquisa sobre a construção de sistemas audiovisuais generativos ainda encontra-se em andamento, tendo como próxima etapa a implementação dos requisitos, realização de testes com usuário para validação da usabilidade e engajamento. Todavia, até o presente momento foram aprendidas as seguintes lições:

As quatro linhas de Design e gatilhos do Design Audiovisual foram úteis no auxílio do levantamento de requisitos funcionais do conteúdo e interfaces de interação;

A personalização de trechos do vídeo apresenta-se como elemento potencial para projetar inércia e ação perante os níveis de engajamento e dispositivos ofertados.

Os impactos destes elementos ficam a cargo de estudos futuros, na continuação desta pesquisa.

Referências

AMY SCHADE. **Video Usability**. Disponível em: <https://www.nngroup.com/articles/video-usability>. Acesso em: 7 jul. 2018.

BARBOSA, S. D. J.; SILVA, B. S. DA. **Interação Humano-Computador**. 1. ed. Rio de Janeiro: Elsevier, 2010.

BECKER, V.; GAMBARO, D.; RAMOS, T. S. Audiovisual design and the convergence between HCI and audience studies. In: **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. [s.l: s.n.]. v. 10271p. 3–22.

ELMAGARMID, A. K. Smart Video Text : An Intelligent Video Database System. 1997.

GUERRINI, F. et al. Interactive Film Recombination. **ACM Transactions on Multimedia Computing, Communications, and Applications**, v. 13, n. 4, p. 1–22. 2017. HANJALIC, A.; LI-QUN XU. Affective video content representation and modeling. **IEEE Transactions on Multimedia**, v. 7, n. 1, p. 143–154, fev. 2005.

HAVALADAR, P.; MEDIONI, G. **Multimedia Systems: Algorithms, Standards, and Industry Pratices**. 1. ed. Boston, MA: Course Technology: CENGAGE Learnig, 2010.

HUGHES, J. F. et al. **Computer Graphics: Principles and Practice**. Third Edit ed. Ohio: Addison- Wesley, 2014.

KYBARTAS, B.; BIDARRA, R. A Survey on Story Generation Techniques for Authoring Computational Narratives. **IEEE Transactions on Computational Intelligence and AI in Games**, v. 9, n. 3, p. 239–253, 2017.

MEIXNER, B. Hypervideos and Interactive Multimedia Presentations. **ACM Computing Surveys**, v. 50, n. 1, p. 1–34, 2017.

TOSCANO, R. et al. Arquitetura de design colaborativo para imersão temporal e espacial em vídeos de altíssimas resoluções e HFR. In: **O futuro da videocolaboração: perspectivas**. Porto Alegre, RS: Sociedade Brasileira de Computação (SBC), 2017.

XU, M.; JIN, J. S.; LUO, S. Personalized video adaptation based on video content analysis. **Proceedings of the 9th International Workshop on Multimedia Data Mining held in conjunction with the ACM SIGKDD 2008 – MDM '08**, p. 26–35, 2008.

Apêndice A – Arquitetura do Design Audiovisual.

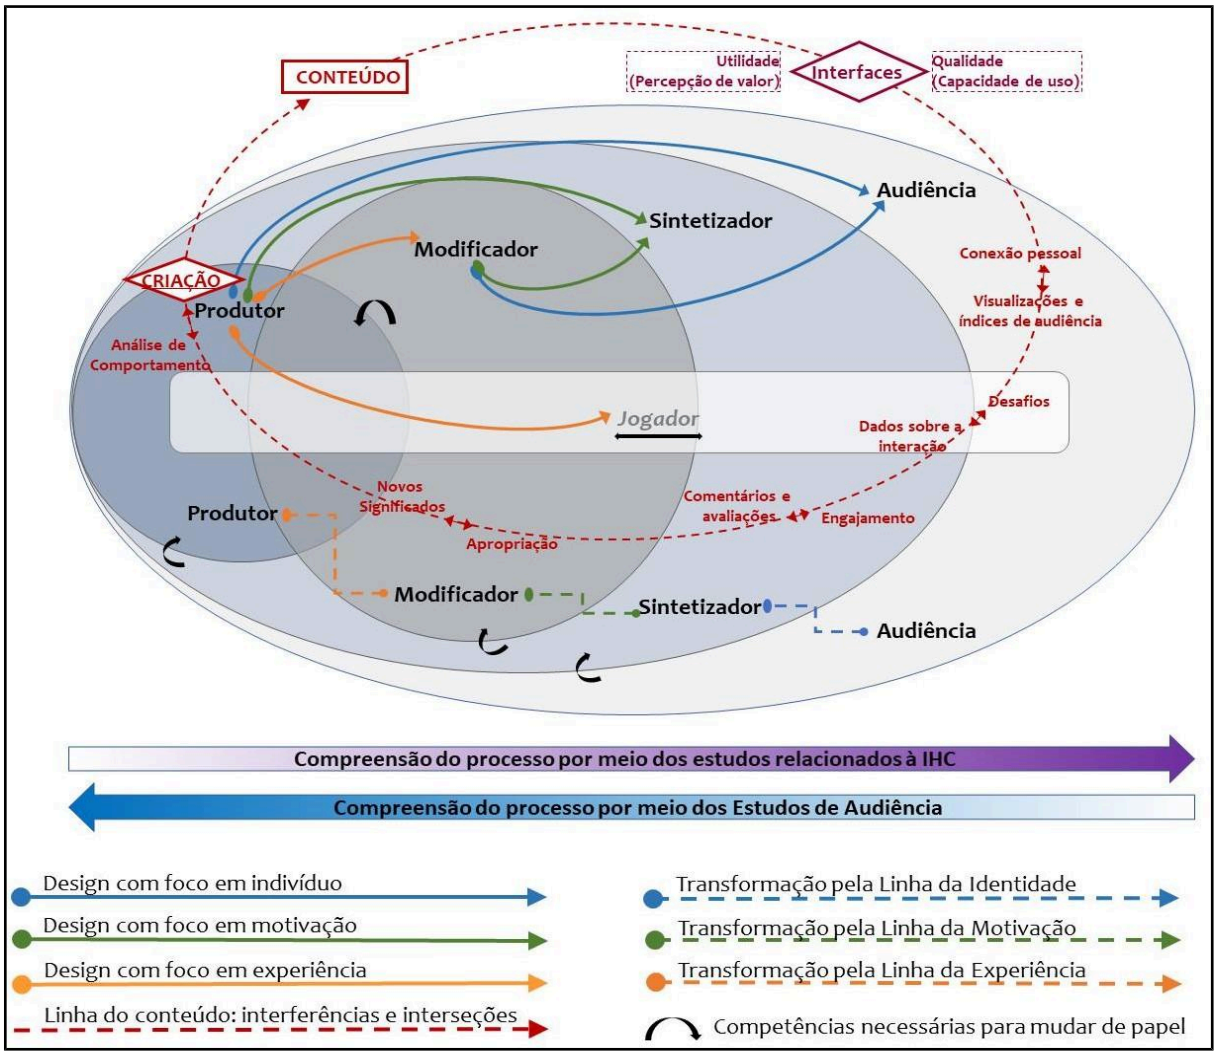

Fonte: (TOSCANO et al., 2017).

Vídeo da apresentação

Título: Design audiovisual para sistemas generativos: um experimento de construção audiovisual personalizada.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=15

Transcrição da apresentação

Olá meu nome é Rafael Toscano gostaria de saudar os colegas que estão participando deste Workshop de Informação, Dados e Tecnologia.

Sou estudante do programa de computação comunicação e artes aqui da UFPB e hoje eu vim apresentar um trabalho que está sendo desenvolvido pelo grupo de pesquisa design audiovisual em parceria com o laboratório de aplicações em vídeo digital para uma ação é para o tribunal de contas do estado da Paraíba.

O contexto que envolve a produção deste trabalho é a relação do audiovisual com o software. A produção audiovisual tem desenvolvido bastante ao longo dos anos e hoje ela torna sua atividade bastante complexa podendo envolver desde diversos esquemas de pós-produção até algoritmo da recomendação sistemas que são adequados a um dispositivo de visualização enfim a gente tem uma relação da tecnologia cada vez mais intensa no consumo e na produção de narrativas.

Dentro desse processo surge uma discussão sobre a geração de narrativos a partir dos dados do usuário especificamente neste projeto nesse trabalho a gente vai trabalhar as relações de customização adaptação e principalmente a personalização do conteúdo isto é a modificação do conteúdo para atingir um grupo pequeno de pessoas ou mesmo um único usuário.

Todo esse processo ele foi desenvolvido a partir da arquitetura e do design audiovisual. O design audiovisual foi que foi desenvolvido pelo nosso grupo ele integra os estudos de audiência a interação humano computador ao integrar essas duas áreas a gente consegue fazer uma análise ou a criação de sistemas complexos e entende que o indivíduo pode estabelecer diversos níveis de relação com o conteúdo que esses níveis de relação podem alternar estantes de tempo muito curtos, então uma hora eu estou com uma audiência recebendo tendo a relação com conteúdo a nível pessoal privado de repente eu crio uma identidade com esse conteúdo e aí eu desenvolvo eu vi um sintetizador depois eu modificador um produtor ou mesmo ao longo de todo esse processo eu posso vir a alcançar o estágio que nós denominamos de player que seria um estágio de competências e habilidades que ele é altíssimo em todos esses níveis quando o indivíduo atinge tudo o que foi pensado pelo criador ou mesmo subverte a ação subverte as relações com o conteúdo seja ele alcança alguma coisa que não foi prevista pelo criador do sistema o que ia todo esse processo é o que nós chamamos de linhas de design.

Então dentro do projeto de interação existem quatro linhas de design que vão influenciar a relação do indivíduo na sua fruição com o sistema, então a primeira linha é a linha do conteúdo e depois nós temos a experiência a motivação e a identidade. Essas quatro linhas de design de projeto da interação elas são manifestadas do que nós chamamos de gatilhos, ou seja, ao longo da experiência o criador do sistema tanto do conteúdo quanto o software ele vai criar a características que vão ser percebidos que vão gerar ações para estimular ou a inércia ou a atenção.

Esse projeto ele é capaz de criar uma relação de interação complexa. Então diante dessa estrutura do design audiovisual nós resolvemos aplicá-lo para a criação de um sistema personalizado todo esse trabalho nós desenvolvemos um sistema audiovisual que vai abordar

sobre a fiscalização e acompanhamento da gestão pública e este sistema este vídeo ele sofre modificações de conteúdo, ou seja, ele é personalizado de acordo com sua audiência.

O tribunal de contas do estado da Paraíba está desenvolvendo algumas ações para integrar estudantes da rede pública e da rede privada no seu dia a dia, então eles gostariam que estudantes entendessem o que é o tribunal, a sua visão, qual é a sua missão na sociedade e para isso ele criou uma série de recursos dentre eles nós podemos destacar os conteúdos em vídeo.

Então dentro de uma ação mais experimental nós resolvemos integrar a produção dos vídeos institucionais que o que nós também realizamos para este projeto a uma experiência mais interativa uma experiência personalizada, então basicamente nosso sistema está organizado da seguinte maneira: nós temos um conteúdo fixo que diante da relação do DA seria um conteúdo que tem que ser capaz de estimular o interesse e a atenção através dos recursos narrativos como edição como personagem, então nós temos um conteúdo fixo que vai falar um pouco sobre o que é essa o que essa corrupção o que é uma má gestão o que é essa fiscalização e bens públicos qual a importância da sociedade principalmente dos jovens participarem se aproximarem deste processo depois disso nós temos uma relação de conteúdo personalizado, ou seja, estes com esses estudantes que estão participando do projeto já fazem o produto já não vamos fazer uma produção de vídeo contando um pouco dos aspectos eficientes ineficientes da sua comunidade escolar.

Então eu estudante quando vou a uma sessão dentro do tribunal eu vou me deparar com um vídeo que começa com um apresentador, durante o vídeo ele vai integrar com uma fala minha e de um colega de sala aí depois no fim do vídeo volta e eu tenho os créditos dizendo o nome da minha escola o nome dos alunos que participaram com vídeo e principalmente eu tenho um QRCODE que me permite baixar este vídeo.

Esse vídeo que foi personalizado e compartilhado eu posso baixar e compartilhar whatsapp ou simplesmente compartilhar na mídia social então todo esse processo ele foi pensado na relação de produzir gatilhos de inércia, ou seja, criar mecanismo que atrai a atenção do usuário das crianças dos estudantes para o conteúdo e aí também estratégias como, por exemplo, gatilho de ação do QRcode é para estimular a ação eu saio desse perfil de audiência onde eu só recebo conteúdo e eu tenho a possibilidade de ir para o papel de sintetizador, onde eu pego esse conteúdo espalho nas minhas redes.

Toda essa configuração que está melhor detalhada no trabalho ela gerou pra gente alguns requisitos que esse sistema deveria ser capaz de atender a alguns requisitos é estabelecer a conexão com as APIs do Facebook e do Youtube e se esse sistema deveria ser capaz de incorporar esse material o hashtag o nome do estudante à escola a escola região está sendo postada um requisito importante pra esse sistema é capaz de integrar esse processo esses dados que estão sendo extraídos dentro de um único filme de um novo vídeo e também é importante ser capaz de salvar todo esse material em um arquivo de vídeo comum que possa ser compartilhado por Whatsapp ou qualquer mídia social como nós destacamos no trabalho é um projeto em andamento e aí depois já inclusive que foi submetido o trabalho nós conseguimos avançar algumas coisas então os requisitos alguns deles já foram apresentados no trabalho que

nós já desenvolvemos o painel de administração onde vai sendo reconhecido os vídeos que já vão sendo catalogados por escolas nós temos também a relação de um painel que gera esses vídeos.

Então nós escolhemos a escola especificamente nós criamos três requisitos para serem validadas agora a criação de uma única playlist a sobreposição de conteúdos e a transformação gráfica esse conteúdo é gerado depois disso eu posso baixar e compartilhar. Então esses requisitos básicos do sistema foram desenvolvidos.

Por fim foi possível entender o que foram aprendidas algumas lições nesse processo as quatro linhas de design e a perspectiva de projetar um sistema pensando em gatilhos de inércia e ação foi extremamente útil para a criação desse sistema então realmente ajudou é a entender a complexidade do sistema e aí os requisitos básicos que o sistema incorpora que o sistema deveria atender e aí outra relação que nós conseguimos já perceber nesse processo é que a personalização desses trechos ela é extremamente é um recurso potencial para engajar e então ao ver um vídeo personalizado isso atua como um gatilho né ao me ver dentro do vídeo é um gatilho que estimula uma identidade uma motivação eu estou ali também naquele conteúdo e isso pode ser um recurso é utilizado recurso narrativo utilizado para aumentar a relação do indivíduo com o conteúdo com a narrativa.

Bom gostaria de agradecer a atenção de vocês espero que tenham gostado do trabalho.

Desafios tecnológicos no processo de recepção normativa: adequação e conformidade na perspectiva da Lei de Proteção de Dados Pessoais

Andrea Carmo Name Willemin[a]*, Geralda Magella de Faria Rossetto*[b] *e Cláudio José Amante*[c]

Resumo: A Lei de Proteção de Dados, recém-editada no Brasil, tem a marca de resguardar, proteger e cuidar dos dados – entendidos estes pertinentes à inovação e tecnologia, de cunho sensível, privado e pertinentes à pessoa – com a medida do zelo e da segurança que até então não foram reservados pela legislação. A pesquisa levada a termo pretende ser exploratória, qualitativa e que terá como base uma proposta de resolução de problemas. Neste sentido, a adequação tecnológica e organizacional requer a indicação de um "modelo de processo de resolução de problemas", cujo fundamento deve prestar ao regramento normativo, cumplicidade e conformidade até então inexistente. Assim, processo na esfera de proteção de dados requer procedimentos que busquem inovação e configuração tecnológica apta ao desempenho seguro de dados pessoais.

Palavras-chave: Lei de Proteção de Dados Pessoais. Privacidade. Inovação. Política Nacional de Ciência. Tecnologia e Inovação.

Technological challenges in the normative reception process: adequacy and compliance from the perspective of the Law of Protection of Personal Data

Abstract: The Data Protection Law, recently published in Brazil, has the mark of safeguarding, protecting and taking care of the data – understood as pertinent to innovation and technology, sensitive, private and pertinent to the person – with the measure of zeal and security that were not previously reserved by law. The research carried out to term is intended to be exploratory, qualitative and based on a proposal for problem resolution. In this sense, the technological and organizational adequacy requires the indication of a "problem resolution process model", the foundation of which should be to regulate law, complicity and compliance that did not exist until then. Indeed, process in the sphere of data protection requires procedures that seek innovation and technological configuration for the safe performance of personal data.

Keyword: Law of Protection of Personal Data. Privacy. Innovation. National Policy on Science. Technology and Innovation.

a Universidade Federal de Santa Catarina (UFSC). E-mail: andrea.willemin@gmail.com. Currículo: http://lattes.cnpq.br/8293839890171163

b Universidade Federal de Santa Catarina (UFSC). E-mail: geraldamagella@gmail.com. ORCID: https://orcid.org/0000-0003-2333-5439. Currículo: http://lattes.cnpq.br/4370737434277404

c Universidade Federal de Santa Catarina (UFSC). E-mail: claudio020461@gmail.com. ORCID: https://orcid.org/0000-0002-3032-3164. Currículo: http://lattes.cnpq.br/4072691666603411

1 Introdução e Metodologia

Com os dados ganhando destaque e espaço na cena internacional e brasileira, saber interpretar e aplicar as diferentes leis que dispõe sobre Proteção de Dados Pessoais é essencial para atuar neste novo cenário regido pela confluência do universo jurídico e tecnológico. A GDPR, Lei Europeia de Proteção de Dados Pessoais, e a brasileira, no caso a Lei de Proteção de Dados Pessoais LPDP – Lei 13709, de 14 de agosto de 2018, possuem inúmeros desafios de caráter tecnológico e jurídico.

Vários pontos da lei chamam particularmente a atenção em razão do caráter inovador e desafiador que trarão quanto a sua integração nos diferentes sistemas de informação e organizacionais gerados pelas novas exigências legais. Várias nações regularam a proteção de dados pessoais há décadas atrás. Hoje, por exemplo, a Europa possui uma legislação forte que impõe diferentes metodologias nas quais a proteção de dados pessoais é pensada desde a concepção de sistemas, práticas comerciais, projetos, produtos ou qualquer outra solução que envolva o manuseio de dados pessoais.

O Brasil aprovou recentemente sua Lei de Proteção de Dados Pessoais. Trabalhar com os dados pessoais agora exige especial desafio para que a proteção dispensada pela lei seja realizada sem que com isso se perca o caráter inovador e realizador buscado pelas novas tecnologias em desenvolvimento. Por inovação, entende-se a atividade de caráter científico, tecnológico, organizacional, financeiro ou comercial proposta e executada com o objetivo de obter produtos, processo tecnológico e serviços totalmente novos ou melhorados, que pode se dar em regime de transação comercial ou não. Inovação é definida como resultado da introdução de novo conhecimento ou tecnologia econômica e socialmente útil (o sentido do novo se aplica ao local onde é introduzido e não possui sentido universal). (BRASIL, 2018).

Para tanto é necessário criar processos que permitam as organizações integrarem dentro de suas estruturas as novas regras legais. Os desafios são inúmeros e em diferentes aspectos. A figura do apêndice A demonstra, de forma exemplificava, as três dimensões (organizacionais, tecnológicas e humanas) necessárias de figurarem de forma harmônica no sistema de informação possibilitando assim as soluções de negócios desejadas. Neste estudo serão levantados alguns dos desafios de dimensões tecnológicas impostos pela lei geral de proteção de dados pessoais que precisarão ser implantados nas diferentes organizações a partir de janeiro de 2020. A complexidade do desafio trazido pela LPDP exige num primeiro ponto que se identifique o que é necessário ser feito. Pois são muitas as novidades introduzidas pela lei e que passarão a ser cobradas. Assim sendo convém a apresentação às organizações de um panorama geral do que está sendo solicitado em termos de adaptações tecnológicas para que daí se estabeleçam processos de adequação das diferentes implementações exigidas pela lei.

No tocante aos procedimentos metodológicos do presente estudo, trata-se de uma pesquisa exploratória, que aborda certos desafios tecnológicos encontrados quando da integração com os novos dispositivos legais trazidos pela lei de proteção de dados pessoais. Da mesma forma pode ser entendida como uma pesquisa qualitativa e de natureza básica que terá como base o passo 01 (um) "modelo do processo de resolução de problemas" (LAUDON; LAUDON, 2014, p. 20).

2 Objetivos

O objetivo geral deste estudo é identificar os desafios tecnológicos no processo de recepção normativa da Lei de Proteção de Dados Pessoais relacionando aos principais desafios de dimensões tecnológicas decorrentes da Lei 13709/2018, para a criação de um "modelo de processo de resolução de problemas" (LAUDON; LAUDON, 2014, p. 20).

Este estudo é a primeira etapa necessária para se "entender e solucionar problemas organizacionais por meio dos sistemas de informação" (Apêndice B), que poderá ser aplicado dentro das diferentes organizações que terão o desafio, até janeiro de 2020, de implantarem a nova Lei de Proteção de Dados Pessoais brasileira. Para que se possa resolver problemas, neste caso, particularmente os referentes as exigências legais, é necessário, primeiramente, que exista consenso sobre sua existência, suas causas e o que pode ser feito quanto a eles, levando-se em conta os recursos limitados que as organizações dispõe (LAUDON; LAUDON, 2014, p. 20) e a necessidade das organizações se adaptarem. A identificação de alguns dos desafios tecnológicos da Lei de Proteção de Dados Pessoais nos sistemas de informação poderá, com o auxílio da ferramenta do modelo de "processo de resolução de problemas" (Apêndice C) num primeiro plano, auxiliar a evidenciar os pontos que necessitam serem trabalhados, para que se possa, depois estabelecer diferentes propostas; avaliar e escolher as propostas e implantar as melhores soluções nas organizações públicas e privadas de forma a se cumprir as novas exigências tecnológicas impostas pela lei.

3 Ciência da Informação e Proteção de Dados

Foi uma longa gestação, da pedra ao byte, e da descoberta e reconhecimento quanto a importância da seleção, arquivamento, transmissão e o próprio aprendizado, entre prática e teoria até dar o passo do reconhecimento da Ciência da Informação.

Na história humana, tudo começou com a oralidade, depois vieram os registros. Rudimentares aos olhos atuais, mas de significado incomensurável para a humanidade. Cita-se, o Cilindro de Ciro "o Grande", primeiro rei da Pérsia, que em 539 a.c conquistou a Babilônia, e recomendou o vetusto registro que é reconhecido como a 1ª. Carta de Direitos Humanos (BRASIL, 2018). Também a Pedra da Roseta, decifrada recentemente, entre 1802 a 1822, por Chanpollion, e sua inscrição registra um decreto do rei Ptolomeu V, promulgado em 196 a.C., na cidade Mênfis. É certo que o desejo político, no caso, a necessidade do registro e a transmissão às gerações fizeram de "dados" como este, e os milhares que se seguiram, uma qualidade e condição de seu armazenamento e transmissão, quer pelo trabalho, como também, pela própria necessidade humana de organização.

Os primeiros cientistas da informação, conforme revela Araújo (2018), tiveram reconhecimento somente no Século XX, de forma que de 1920 a 1940, da Inglaterra até aos EUA e em outros países, os cientistas puderam abastecer seus colegas – com os Science Services – em suas respectivas áreas de estudos, com índices, resumos, canais, arquivos. Assim, os "ex" químicos, físicos, engenheiros e outros cientistas alçaram a condição de cientistas da Informação, saíram da prática para o universo da institucionalização.

De forma concreta, em 1968, o American Documentation Institute, dos Estados Unidos, mudou seu nome para American Society for Information Science, tornando-se a primeira instituição de Ciência da Informação do mundo. Contribuíram também para sua formação, primeiro a Inglaterra, com a realização da Royal Society Scientific Information Conference, em 1948, e a criação, em 1958, do Institute of Information Scientist. Pouco depois, na União Soviética, foi criado o Viniti, Vserossiisky Institut Nauchnoi i Tekhnicheskoi Informatsii, vinculado à Academia de Ciências. E, a seguir, em 1958, ocorreu nos Estados Unidos a International Conference on Scientific Information, quando, a Ciência da Informação alça a condição de ciência dedicada à informação em ciência e tecnologia, com a preocupação de base dessas ações: não mais a necessidade de se ter a posse dos documentos, mas a prioridade dada à sua circulação, ao seu fluxo, e ao atendimento das necessidades dos cientistas, inclusive com a vertente póscustodial de Documentação, até que, em 1962 foi publicado um estudo, de autoria de Machlup, voltado a produção e distribuição de conhecimentos. Em 1963, um relatório de Weinberg apontou que as agências de governo fomentadoras de pesquisa científicas deveriam também assumir a responsabilidade pela transferência do conhecimento gerada nas pesquisas. (ARAÚJO, 2018).

Aqui tem-se a ponta de lança, na medida em que vários pesquisadores passam a estudar o processo da "comunicação da informação científica": o estudo dos vários registros do cientista, da ideia na sua cabeça (relatórios, seminários, apresentações em eventos, artigos em periódicos, livros, citações ao trabalho, menções em livros-textos e enciclopédia), até as suas características, vantagens e desvantagens, tempo médio de produção, entre outros aspectos, inclusive, amparar e buscar os dados, estejam estes em bibliotecas, em arquivos, em museus, em bases de dados, em artigos de periódicos, onde estiver, um estudioso da ciência da informação estará de "olhos abertos" e dedos disponíveis para catalogá-los. Qual seja, a "comunicação informal" passa a consolidar a concepção da Ciência da Informação e seu objeto de estudo – dos fluxos, dos caminhos percorridos pela informação, sua materialização em diferentes produtos e serviços – passa a ser uma importante lição e fundamentação à legislação, da qual a nova LPDP, é, sem dúvida, uma destacada resposta.

Lei de Proteção de Dados Pessoais: considerações e desafios: Devem ser destacados na LPDP alguns aspectos vinculados às tecnologias e que são por ela normatizados.

Estes pontos foram identificados como desafios tecnológicos a serem suplantados em razão da necessidade das novas exigências legais, de forma a se integrarem ou coexistirem com os sistemas de informação atuais e, neste aspecto, anunciar o estado da arte.

4.1 Anonimização (art. 11, § 3º, da Lei 13709/2018)

O processo de eliminação ou modificação da informação pessoal existente numa base de dados, com o objetivo de dificultar ou impedir a identificação unívoca dos indivíduos.

A referida lei dispõe sobre padrões e técnicas utilizados em processos de anonimização e regulamenta as possíveis verificações acerca de sua segurança. O grande desafio tecnológico ainda é como utilizar os dados mesmo que anonimizados, por exemplo, no processo de busca de determinados dados sem comprometer a anonimização

De acordo com a utilização de técnicas e o alcance dos objetivos, podem ser considerados três divisões: de-identificação, anonimização e pseudonimização.

A de-identificação é o processo de remoção ou ofuscação de toda a informação pessoal de uma base de dados, com o objetivo de impedir a identificação dos indivíduos. É possível reverter a de-identificação através de uma tabela de mapeamento (ligando os registros originais aos registros de-identificados). Ela suprime todos os atributos identificadores e também modifica os "quasi-identifiers", mediante processos de generalização.

Um nível mais elevado da de-identificação é a anonimização, quando a pretensão é tornar impraticável, ou até mesmo impossível (com o uso de todos os meios considerados razoáveis) a re-identificação. Este processo impossibilitaria inclusive o próprio técnico que realizou a operação inicialmente de reverter o procedimento. Merece destaque o fato da definição ser adaptável ao contexto tecnológico do momento: "todos os meios considerados razoáveis". A afirmativa leva à ponderação de quais seriam os recursos necessários, o custo do processo e o conhecimento necessário para realizar uma re-identificação.

Já a pseudonimização objetiva substituir todos os identificadores pessoais por palavras ou códigos gerados artificialmente, os quais poderão funcionar como representações mascaradas dos dados originais. Uma pseudonimização relevante possui uma preocupação adicional relacionada com a incidência sobre os atributos "quasi-identifiers" (por exemplo a data de nascimento), e que a atribuição de códigos seja realizada de forma aleatória e independente dos valores originais (muito embora podendo ocasionalmente continuar relacionados entre si).

Infelizmente, diversos casos têm evidenciado as falhas em processos de anonimização. Estas situações têm evidenciada a necessidade do envolvimento de especialistas nos processos de anonimização, já que qualquer erro poderá gerar repercussões na imagem da organização.

A simples remoção de atributos identificadores (nome, telefone, etc.) nunca será suficiente para eliminar os riscos de quebra de privacidade. Por outro lado, é constante a possibilidade de um hacker acessar outras bases de dados externas, possibilitando o cruzamento dessa informação com os dados que se pretendam anonimizar (Pinho, 2017).

4.2 Direito ao esquecimento (art. 16, Lei 13709/2018).

O direito ao esquecimento diz respeito aos direitos privativos da personalidade, corolário do direito à intimidade, à privacidade, à honra e à imagem, e, na sociedade da informação, apesar de conservar a pertinência com o princípio da dignidade do ser humano, diz respeito às inúmeras notícias disseminadas pelos meios de comunicação e tem vínculo com a proteção de dados, pessoais e sensíveis, de onde decorrem inúmeros problemas de violação da personalidade acarretada pela perpétua exposição de dados.

Nesse contexto, os dados pessoais serão eliminados após o término de seu tratamento, no âmbito e nos limites técnicos das atividades, autorizada a conservação para algumas finalidades. Existem dificuldades técnicas para o seu cumprimento dada a grande quantidade de replicações e cópias de dados.

Os controladores são obrigados a fornecer relatórios de tratamento quando requisitados pelos titulares, sendo exigido não só uma plataforma de atendimento a essas requisições como também uma organização dessas informações internamente pelas instituições (art. 18).

Não só é necessário que a instituição consiga estruturar os dados requisitados de maneira que possa haver a portabilidade: ela deve prover os recursos técnicos e manter contato com outras instituições para que os canais de portabilidade funcionem corretamente (art. 18, inciso V).

4.3 Transferência internacional de dados (art. 33, Lei 13709/2018)

A transferência internacional de dados pessoais é permitida nos seguintes casos: a) para países ou organismos internacionais com grau de proteção de dados pessoais; b) quando o controlador apresentar garantias de cumprimento dos princípios, dos direitos e do regime de proteção de dados; c) quando a transferência for necessária para a cooperação jurídica internacional entre órgãos públicos de inteligência, de investigação e de persecução; d) quando a transferência for necessária para a proteção da vida ou da incolumidade física do titular ou de terceiro; e) quando a autoridade nacional autorizar a transferência e esta resultar em compromisso assumido em acordo de cooperação internacional; g) quando a transferência for necessária para a execução de política pública ou atribuição do serviço público; h) quando o titular tiver fornecido o seu consentimento específico para a transferência, com informação prévia sobre o caráter internacional da operação; i) quando necessário para atender as hipóteses seguintes: -para o cumprimento de obrigação legal ou regulatória pelo controlador; - para a execução de contrato ou de procedimentos preliminares relacionados a contrato do qual seja parte o titular, a pedido do titular dos dados; e para o exercício regular de direitos em processo judicial, administrativo ou arbitral. Cumpre também destacar que, nos termos da Lei nº 12527/2011, as pessoas jurídicas de direito público, na esfera de suas competências e atividades, poderão requerer à autoridade nacional a avaliação do nível de proteção de dados pessoais dispensados pelo país ou organismo internacional.

No mesmo sentido da portabilidade, a transferência internacional de dados é um desafio para as instituições que necessitem/desejem efetuar a transferência não só pelos requisitos autorizados pela Lei quanto pelas dificuldades técnicas em efetuar essa empreitada.

4.4 Decisões automatizadas: (Art. 20, da Lei 13709/2018)

O titular dos dados tem direito a solicitar revisão, por pessoa natural, de decisões tomadas unicamente com base em tratamento automatizado de dados pessoais que afetem seus interesses, inclusive de decisões destinadas a definir o seu perfil pessoal, profissional, de consumo e de crédito ou os aspectos de sua personalidade. A possibilidade de rever decisões automatizadas será um grande desafio para as instituições que trabalham com significativos volumes de dados – em qualidade e quantidade – pois seus sistemas terão que conter informações suficientes que justifiquem a decisão para que a mesma possa ser revista, se for o caso. Em larga escala, o atendimento a essas demandas também terá que ser incorporado aos sistemas utilizados. Esse parece ser um desafio enorme para instituições que não tem a preocupação de segurança em tecnologia de Big Data.

4.5 Relatórios de impacto (Art. 38, Lei13709/2018).

A autoridade nacional poderá determinar ao controlador que elabore relatório de impacto à proteção de dados pessoais, inclusive de dados sensíveis, referentes as operações de tratamento de dados, observados os segredos comercial e industrial das relações de negócios, e especialmente o sigilo e a confidencialidade entre pessoas e gestão.

As instituições deverão ter conhecimento e auditar seus sistemas para que os relatórios de impacto possam ser construídos, decorrentes de processos e procedimentos para o caso de vazamento de dados.

4.6 Boas práticas de segurança (Art. 46, Lei 13709/2018).

Os agentes de tratamento devem adotar medidas de segurança, técnicas e administrativas aptas a proteger os dados pessoais de acessos não autorizados e de situações acidentais ou ilícitas de destruição, perda, alteração, comunicação ou qualquer forma de tratamento inadequado com vistas a impedir a configuração de ilicitudes.

Para tanto, as atividades de tratamento de dados pessoais, inclusive as relativas aos dados sensíveis, devem primar pela observância do princípio da boa-fé, bem como, caracterizada, sua finalidade, adequação, necessidade, livre acesso, qualidade dos dados, transparência, segurança, prevenção, não discriminação; responsabilização e prestação de contas, no caso, a adoção de medidas eficazes e capazes de comprovar a observância e o cumprimento das normas de proteção de dados pessoais e, inclusive, da eficácia dessas medidas.

É certo que pelo § 1º do art. 46 da LGPD, a autoridade nacional poderá dispor a respeito de padrões técnicos mínimos, visando tornar aplicáveis as disposições contidas no seu caput, para o qual levará em conta as seguintes situações: a natureza das informações tratadas, as características específicas do tratamento e o estado atual da tecnologia, especialmente.

Embora ainda não estejam regulados pela autoridade, as instituições deverão atender a padrões técnicos para o tratamento de dados pessoais. Pela lei, entende-se que a autoridade irá apontar regularmente as revisões em virtude da evolução da tecnologia e de novos padrões de segurança (Apêndice D).

4.7 Privacidade por default e por design

Art. 46, § 2º, Lei As medidas de que trata o caput deste artigo deverão ser observadas desde a fase de concepção do produto ou do serviço até a sua execução.

Tanto na concepção dos sistemas que fazem tratamento de dados quanto na sua execução, deverão ser observadas as garantias, prerrogativas e diretrizes da lei para o tratamento de dados pessoais. Isso significa uma revisão completa dos sistemas que fazem esse tipo de tratamento, assim como uma preocupação para os sistemas que estão em desenvolvimento e que virão a ser desenvolvidos. Em sistemas mais antigos e integrados em diferentes plataformas, isso pode significar uma revisão completa ou até mesmo uma necessidade de reestruturação de sistemas inteiros, em virtude da complexidade de se ter um sistema com proteção de privacidade desta forma.

4.8 Vazamento de dados

Art. 48. O controlador deverá comunicar à autoridade nacional e ao titular a ocorrência de incidente de segurança que possa acarretar risco ou dano relevante aos titulares.

A construção dos relatórios de vazamento deverá ser pautada em informações acerca dos mesmos e nos riscos que eles representam, além das medidas que foram tomadas e serão tomadas acerca dos incidentes. Isso representa uma enorme mudança técnica no tratamento de dados pessoais das empresas, uma vez que a identificação de um vazamento, suas soluções técnicas imediatas e as mudanças que deverão decorrer em virtude dos mesmos representam um desafio tanto jurídico quanto tecnológico, pautando-se na segurança da informação.

5 Resultados

Verifica-se que os objetivos propostos para o presente estudo foram atingidos uma vez que alguns dos principais problemas tecnológicos da lei foram elencados permitindo que se possa avançar, num futuro estudo, para a etapa dois, ou seja, para o "modelo de processo de resolução de problemas" (LAUDON; LAUDON, 2014, p. 20), pertinentes à implantação dos desafios tecnológicos nas organizações.

6 Conclusão

A identificação de alguns dos principais pontos dos desafios tecnológicos impostos pela Lei 13709/2018, permite a identificação de diferentes problemas que precisam ser resolvidos, e desta forma caracteriza a etapa 1 necessária para o "modelo processo de resolução de problemas" que poderá auxiliar as organizações a implantarem soluções adequadas e que satisfaçam as exigências legais de proteção de dados pessoais. Este primeiro passo é o ponto de partida para se criar um caminho rumo ao encontro das melhores soluções para a implantação da nova normatização de proteção de dados pessoais nas organizações.

Referências

ARAÚJO, Carlos Alberto Ávila. **O que é Ciência da Informação?** Disponível em http://www.uel.br/revistas/uel/index.php/informacao/article/view/15958/14205> Acesso em 15 nov 2018.

ASSOCIAÇÃO BRASILEIRA DE AGÊNCIAS DE PUBLICIDADE. **Cartilha Institucional de Segurança da Informação e Prevenção a Fraudes**. São Paulo. Disponível em < http://www.abap.com.br/pdfs/seguranca_informacao.pdf>. Acesso em 27/09/2018.

BRASIL. **Cilindro de Ciro.** Disponível em http://www.dhnet.org.br/direitos/anthist/marcos/cilindro/index.htm> Acesso em 15 nov 2018.

BRASIL. **Lei n. 13709, de 14 de agosto de 2018**. Disponível em <http://www.planalto.gov.br/ccivil_03/_Ato2015-2018/2018/Lei/L13709.htm >. Acesso em 27/09/2018.

BRASIL. Descritores em Ciências da Saúde. Disponível em http://decs.bvs.br/cgi-bin/wxis1660.exe/decsserver/> Acesso em 08/10/2018.

BRASIL. Tribunal de Contas da União. Cartilha de boas práticas em segurança da informação – 4ª Edição. Brasília. Disponível em <https://portal.tcu.gov.br/biblioteca-digital/cartilha-de-boas-praticas-em-seguranca-da-informacao-4-edicao.htm >. Acesso em 07/10/2018.

CAVOUKIAN, Ann; JONAS, Jeff. **Privacy by design in the age of big data**. Ontário. Disponível em: <https://jeffjonas.typepad.com/Privacy-by-Design-in-the-Era-of-Big-Data.pdf>. Acesso em 07/10/2018.

ELMASRI, Ramez; NAVATHE, Shamkant B. **Sistemas de banco de dados**. Tradução de Daniel Vieira. São Paulo: Pearson, 2011.

HARBOUR, Pamela Jones. **Privacy by design in law, policy and practice: a white paper for regulators, decision-makers and policy-makers**. Ontário. Disponível em <http://www.ontla.on.ca/library/repository/mon/25008/312239.pdf >. Acesso em 07/10/2018.

LAUDON, Kenneth C.; LAUDON, Jane P. **Sistemas de Informação Gerenciais**. Tradução de Célia Taniwaki. São Paulo: Pearson Education do Brasil, 2014.

LOVELUCK, Benjamin. **Redes, liberdades e controle: uma genealogia política da internet**. Tradução de Guilherme João de Freitas Teixeira. Petrópolis: Vozes, 2018.

MARTINS, Claudia Aparecida et al. **Uma Experiência em Mineração de Textos Utilizando Clustering Probabilístico e Clustering Hierárquico.** São Carlos: Icmc, 2003.

PINHO, Frederico António Sá Oliveira. **Anonimização de bases de dados empresariais de acordo com a nova regulamentação europeia de proteção de dados**. Dissertação (Mestrado em Segurança Informática. Departamento de Ciência de Computadores. Faculdade de Ciências. Universidade do Porto. Porto, 2017.

PROVOST, Foster; FAWCETT, Tom. **Data Science para negócios**. Tradução de Marina Boscatto. Rio de Janeiro: Alta Books, 2016.

Sheshasaayee, Ananthi; Bhargavi. K. **A study of automated decision making systems**. Disponível em: < http://www.researchinventy.com/papers/v7i1/E07012831.pdf>. Acesso em 07/10/2018.

WIHLBORG, Elin; LARSSON, Hannu; HEDSTRÖM, Karin. **"The Computer Says No!":** A Case Study on Automated Decision-Making in Public Authorities. Disponível em: <https://www.researchgate.net/publication/290303337_The_Computer_Says_No_--

_A_Case_Study_on_Automated_Decision-Making_in_Public_Authorities >. Acesso em 07/10/2018.

Apêndice A -

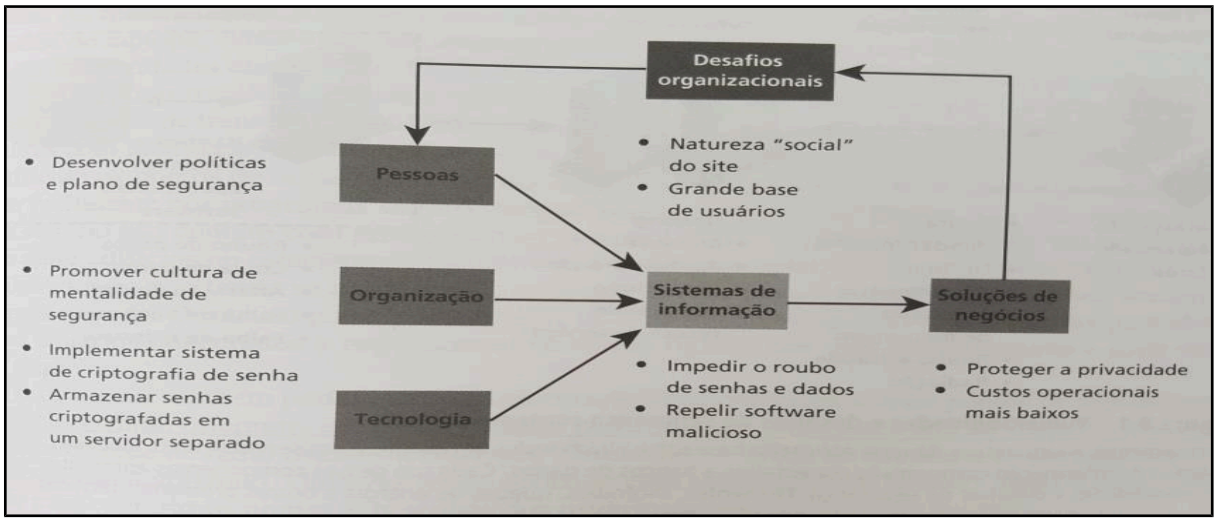

Fonte: Sistemas de Informação Gerenciais, (LANDON; LANDON, 2014, p.255).

Apêndice B -

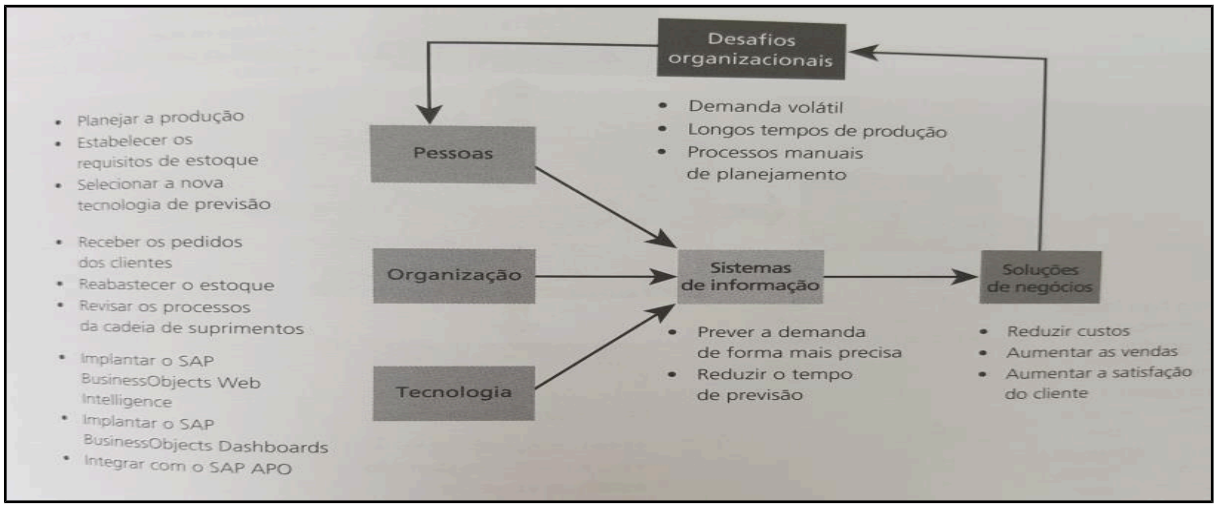

Fonte: Sistemas de Informação Gerenciais, (LANDON; LANDON, 2014, p. 20).

Apêndice C -

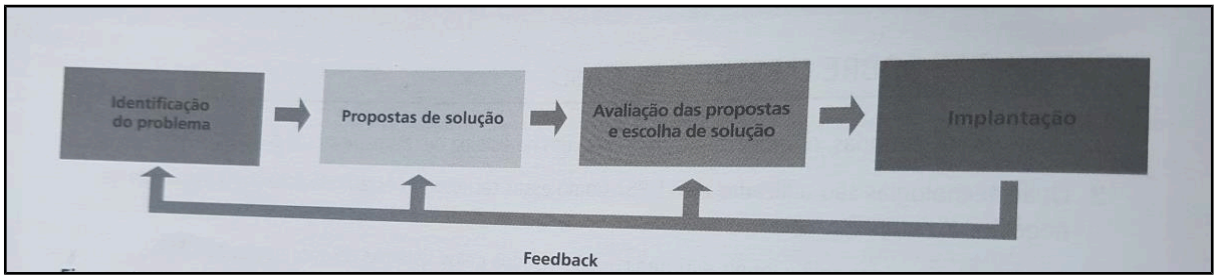

Fonte: Sistemas de Informação Gerenciais, (LANDON; LANDON, 2014, p. 20).

Apêndice D -

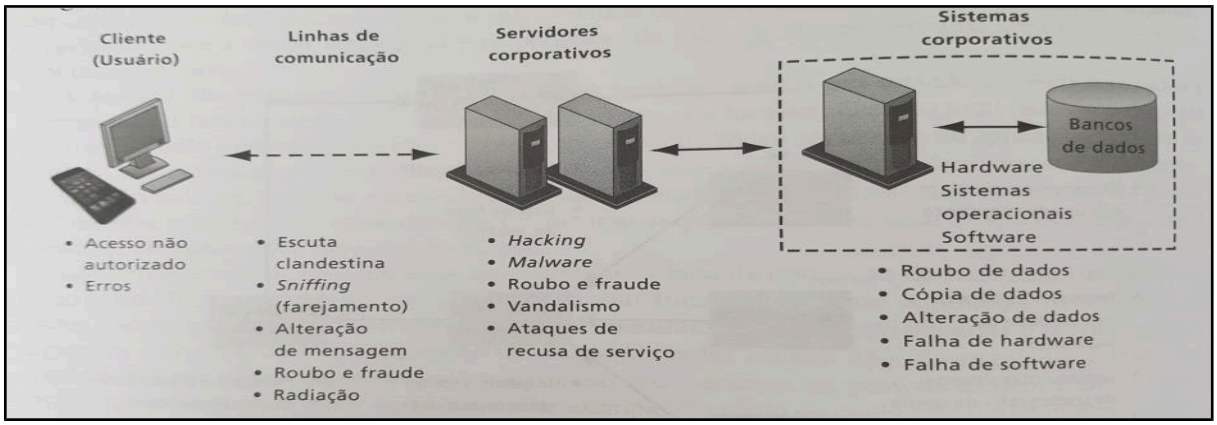

Fonte: Sistemas de Informação Gerenciais (LANDON; LANDON, 2014, p. 256).

Vídeo da apresentação

Título: Desafios tecnológicos no processo de recepção normativa: adequação e conformidade na perspectiva da Lei de Proteção de Dados Pessoais.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=16

Transcrição da apresentação

Bom dia, gostaria de agradecer a oportunidade de participar do 1º Workshop de Informação, Dados e Tecnologia, quero falar alguma coisa a respeito dos autores deste trabalho Andreia Willemin ela possui uma vasta experiência na área jurídica em proteção de dados.

Atualmente faz pós-graduação em nossa universidade na área de tecnologia da informação, doutora Geralda de Faria é procuradora Federal junto à Universidade Federal eu sou Cláudio, atualmente coordenador em exercício do programa de pós-graduação em administração universitária dessa cidade.

O título do nosso trabalho é desafios tecnológicos no processo de recepção normativa adequação e conformidade na perspectiva de lei de proteção de dados pessoais os dados pessoais estão ganhando destaque no âmbito nacional e internacional saber interpretar e aplicar as diferentes leis que dispõe sobre a proteção de dados pessoais é essencial para atuar nesse novo cenário regido pela confluência do universo jurídico e tecnológico.

A lei europeia de proteção de dados e a lei de proteção de dados no Brasil possui inúmeros desafios de caráter tecnológico e jurídico o Brasil aprovou recentemente a sua lei de proteção de dados pessoais trabalhar com os dados pessoais agora exige especial desafio para a sua para que a proteção dispensada pela lei seja realizada sem que com isso se perca o caráter inovador e realizador buscado pelas novas tecnologias em desenvolvimento.

A complexidade do desafio trazido pela lei de proteção de dados pessoais exige um primeiro ponto que se identifique o que é necessário ser feito pois são muitas novidades introduzidas pela lei e que o passarão a ser cobradas de toda a sociedade.

Para tanto é necessário criar processos que permitam às organizações integrarem dentro das suas estruturas as novas regras legais para tanto faz-se necessário desenvolver políticas e planos de segurança promover a cultura e mentalidade de segurança implantar sistema de criptografia armazenar senhas criptografadas em um servidor separado segundo Laudon e Laudom (2014).

Os procedimentos metodológicos deste trabalho do ponto de vista do seu objetivo um trabalho exploratório sob o ponto de vista da abordagem do problema qualitativo do ponto de vista de sua natureza na pesquisa básica.

O objetivo deste desse estudo e identificar os desafios tecnológicos no processo de recepção normativa da lei de proteção de dados pessoais relacionando as principais desafios de dimensões tecnológicas decorrentes da lei 3709 de 2018 para a criação de um modelo de processo de resolução de problemas.

Este estudo é a primeira etapa necessária para que entender e solucionar problemas organizacionais por meio dos sistemas de informação este modelo poderá ser aplicado dentro das diferentes organizações que o terão um desafio até 2020 implantarem a nova lei de proteção de dados pessoais brasileira.

A identificação de alguns desafios tecnológicos a lei de proteção de dados pessoais nos sistemas de informação poderá num primeiro plano auxiliar a evidenciar os pontos que necessitam serem trabalhados para que se possa depois estabelecer diferentes propostas.

Em relação à ciência da informação e proteção de dados ela tem uma longa trajetória na vida humana da pedra ao byte a descoberta ao reconhecimento contudo os primeiros cientistas da

informação tiveram somente reconhecimento no século 20 um exemplo a pedra da Rozeta decifrada entre 1802 a 1822 por Chanpollion ela traz uma inscrição registrando um decreto do rei Ptolomeu V promulgado em 196 antes de Cristo na cidade de Menfins.

Em relação ainda a lei de proteção de dados considerações desafios dela deve ser destacados na lei de proteção de dados pessoais alguns aspectos vinculados às tecnologias que são por ela normatizados.

Esses pontos foram identificados como desafios tecnológicos a serem suplantados em razão da necessidade das novas exigências legais de forma a se integrarem o coexistirem com os sistemas de informações atuais.

Desafios: primeiro a anonimização, o que dizer o objetivo é dificultar ou impedir a identificação unívoca dos indivíduos esse fato é muito importante direito ao esquecimento segundo desafio tem vínculo com a proteção de dados pessoais e sensíveis e onde decorre em inúmeros problemas de violação da personalidade acarretada pela perpétua exposição de dados.

Outro desafio transferência internacional de dados para que isso aconteça para que seja permitido alguns critérios na nossa lei foram incluídos dentro deles países ou organismos internacionais com grau de proteção de dados é necessário está estabelecido lá também quanto o controlador apresentar garantias de cumprimento dos princípios dos direitos e do regime de proteção de dados quando a transferência foi necessária para cooperação jurídica internacional para a proteção à vida para execução de políticas públicas e o titular acima de tudo ter fornecido o seu consentimento, isso são dados importantes para que se possa ter uma transferência internacional de dados.

O quarto desafio decisões automatizados o titular dos dados têm o direito a solicitar revisão por pessoa natural de decisões tomadas unicamente com base em tratamentos automatizados de dados pessoais que afete seus interesses isso requer muita tecnologia. Quinto desafio, relatórios de impacto a autoridade nacional poderá determinar ao controlador que elaborem relatório de impacto a proteção de dados pessoais.

Sexto desafio boas práticas de segurança a adotar medidas de seguranças técnicas e administrativas aptas a proteger os dados pessoais de acesso não autorizados privacidade default ou por design deverão ser observadas as garantias prerrogativas e diretrizes da lei para o tratamento de dados pessoais isso significa uma revisão completa dos sistemas que fazem esse tipo de tratamento. Oitavo desafio privacidade por deixou o design o controlador deverá comunicar à autoridade nacional e ao titular a ocorrência de incidente e segurança que possam acarretar risco ou dano relevante aos titulares assim após análise dessa conjuntura verifica-se que os objetivos propostos para o presente estudo foi atingido uma vez que alguns dos principais problemas tecnológicos da lei foram elencados permitindo assim que se possa avançar no futuro estudo para a segunda etapa, ou seja, para o modelo de processo de resolução de problemas pertinentes à implantação dos desafios tecnológicos nas organizações.

Concluindo a identificação de alguns dos principais pontos do desafio tecnológico impostos pela lei 13.709 de 2018 permite apontar diferentes problemas que precisam ser resolvidos etapa 1 este modelo poderá auxiliar as organizações a implantar soluções adequadas e que satisfaçam as exigências legais de proteção de dados pessoais e assim esse primeiro passo é o ponto de partida

para se criar um caminho ao encontro das melhores soluções para a implantação da nova normatização de proteção de dados pessoais nas organizações.

Assim sendo agradeço a oportunidade em nome da Andréia da Geralda eu agradeço essa oportunidade está participando e divulgando um pouco no nosso estudo frente a normatização dessa lei nas organizações em especial nas universidades também, muito obrigado.

Slides da apresentação

Título: Desafios tecnológicos no processo de recepção normativa: adequação e conformidade na perspectiva da Lei de Proteção de Dados Pessoais.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=16

As licenças Creative Commons e Software Livre como formas de proteção na sociedade da informação compartilhada

Maria Carolina Zanini Ferreira[a], Clarissa Stefani Teixeira[b] e Enrique Muriel-Torrado[c]

Resumo: O presente estudo possui a finalidade de entender de que formas as licenças creative commons e software livre são uma alternativa de proteção ao capital intelectual em uma sociedade da informação compartilhada. Por meio de um estudo bibliográfico de caráter descritivo exploratório, buscou contextualizar a sociedade da informação que trouxe como consequência um mundo mais conectado e principalmente colaborativo. Logo, discussões começaram a ser realizadas acerca da proteção da propriedade intelectual, nas quais obras intelectuais, novas tecnologias, estão sendo compartilhadas, desenvolvidas de forma coletiva e ainda distribuídas em um mundo digital, que a princípio poderia ferir os direitos que são assegurados ao autor desses ativos. Como resultado, mecanismos de licenciamento começaram a ser encarados como uma maneira que assegura os direitos do autor, mas, ao mesmo tempo, permite o compartilhamento das obras autorais desde que sejam respeitadas algumas condições. Com isso, mostra que os direitos autorais em um mundo conectado e colaborativo pode ser revisto em padrões que não infrinjam suas próprias regras e ainda por cima contribuir para que uma forma mais segura e colaborativa possa se dar em um mundo digital com uma vasta rede de dados sendo usadas, reusadas e distribuídas.

Palavras-chave: Licenças. Creative Commons. Software Livre. Sociedade da Informação.

The Creative Commons and Free Software Licenses as forms of protection in the shared information society

Abstract: The purpose of this study is to understand the ways in which creative commons and free software licenses are an alternative to protect intellectual capital in a shared information society. Through a bibliographic study characterized as exploratory descriptive, it sought to contextualize the information society that brought as a consequence, a more connected and mainly collaborative world. Therefore, discussions began to take place about protection of intellectual property, in which intellectual works, new technologies, are being shared, developed collectively and even distributed in a digital world, which in principle could violate the copyright. As a result, licensing mechanisms have begun to be seen as a security option to copyright, but at the same time allowing the sharing of copyright works, provided that certain conditions are respected. In this way, it shows that copyright in a connected and collaborative world can be reviewed in patterns that do not violate its own rules and, moreover, contribute to a more secure and collaborative way in a digital world with a vast network of data being used, reused and distributed.

Keyword: Licenses. Creative Commons. Free Software. Information Society.

a Universidade Federal de Santa Catarina (UFSC). E-mail: mariacarolina.zanini@gmail.com. Currículo: http://lattes.cnpq.br/7956892598008518

b Universidade Federal de Santa Catarina (UFSC). E-mail: clastefani@gmail.com. ORCID: https://orcid.org/0000-0002-6922-8877. Currículo: http://lattes.cnpq.br/6668948766545628

c Universidade Federal de Santa Catarina (UFSC). E-mail: enrique.muriel@ufsc.br. ORCID: https://orcid.org/0000-0003-0969-9500. Currículo: http://lattes.cnpq.br/6493679032893430

1 Introdução

A globalização trouxe a informação e o conhecimento como os principais ativos do século, onde as práticas sociais estão sendo examinadas e (re)formadas constantemente. A entrada de informações que alteram não somente o indivíduo ou um grupo específico, mas toda a comunidade global é impulsionada cada vez mais pela evolução crescente das tecnologias de informação e comunicação (TICs), onde tudo está conectado e interligado (GIDDENS, 1990; KAWAMURA, 2007).

Estudos recentes sobre esse ativo que é a informação e a sua transformação em conhecimento de alto valor agregado como vetor para a inovação, são ressaltados por Carmeli, Gelbard e Reiter-Palmon (2013) como um processo essencialmente colaborativo e comunicativo, fruto do fluxo contínuo de informação com o entorno produtivo e a sociedade, criando ambientes que potencializam a criatividade e novos mecanismos de compartilhamento.

Isso naturalmente leva a uma série de perguntas sobre as questões e riscos do uso sobre o compartilhamento de obras intelectuais, novas tecnologias como software que atualmente trazem consequências na esfera dos direitos autorais, arcabouço legal que assegura ao autor a proteção de direitos sobre a sua obra automaticamente obtida com a sua criação (BÉRANGER; RAVIX, 2013, EVENS, 2015).

O resultado dessas discussões levou ao surgimento de novos mecanismos legais que buscam assegurar os direitos intelectuais ao mesmo tempo em que permitem acesso público e o uso da informação contidas nas obras, sendo conhecidos hoje como licenças de software livre e creative commons (YANG; MASKUS, 1999; XUE, 2014).

Logo, por se tratar de um tema atual e que ainda necessita de maior compreensão, o presente trabalho busca contribuir para a discussão acerca da proteção intelectual frente a uma sociedade da informação de caráter colaborativo.

Pretende-se, portanto, não exaurir o tema, mas apresentar uma alternativa para agregar a discussão existente sobre a propriedade intelectual e o compartilhamento da informação, temas que regularmente são tratados como antagônicos (YANG; MASKUS, 1999; XUE, 2014).

2 Objetivos

A proposta do presente estudo é compreender como as licenças creative commons e software livre podem ser uma opção de proteção em uma sociedade da informação de caráter colaborativo.

3 Procedimentos Metodológicos

O procedimento metodológico da pesquisa se caracteriza como descritiva exploratória, a partir de uma contextualização geral que buscou evidenciar a sociedade da informação em um mundo globalizado onde novos paradigmas emergem frente a uma dinâmica colaborativa derivada do desenvolvimento das TICs. Dentre as diversas discussões oriundas desse cenário, serão ressaltadas as questões relacionadas a propriedade intelectual, mais precisamente no campo dos direitos autorais, onde novos mecanismos legais de proteção e licenciamento denominadas como licenças creative commons e software livre são apresentadas (MARCONI; LAKATOS, 2003).

Logo, foram utilizadas técnicas padronizadas de coleta de dados e observação sistemática, utilizando fontes e dados secundários obtidos por meio de pesquisa documental provindos da legislação brasileira relacionado a direitos autorais, bancos de dados tais como scopus, web of science, filtrando estudos que possuíssem informações referentes aos temas estudados (sociedade da informação, direitos autorais, creative commons e software livre) assim como fontes provenientes de organizações e instituições de ensino e pesquisa que pudessem auxiliar a proposta do referente tema (PRODANOV; FREITAS, 2013).

De modo a atender o objetivo, o estudo foi compreendido em três fases: (i) contextualizar a sociedade da informação e suas as implicações contidas no âmbito dos direitos autorais e; (ii) apresentar as licenças de software livre e creative commons como forma de proteção da informação em mundo colaborativo.

4 Resultados

O mundo contemporâneo tem mudado rapidamente a realidade, orientado tecnologicamente para um ambiente totalmente virtual de armazenamento de dados e informações. Tal percepção do "ciberespaço" tende a desregulamentar barreiras de acesso a informação e conhecimento por meio de um ambiente altamente colaborativo e compartilhado (LEVIN, 2014).

Apesar de o tema não ser novo, as formas de compartilhamento de conhecimento e informação mudaram drasticamente, e com isso trouxeram diversos questionamentos para a sociedade global, fruto da quantidade crescente de informações disponíveis, da sua transformação em um ativo especial, a efetiva combinação e a utilização das demais informações e da tamanha complexidade que essas relações acabaram trazendo na conjuntura prática da sociedade da informação em um mundo globalizado (SOUSA; AMARAL, 2012).

Com a expansão da internet em meados dos anos 90, iniciou-se uma dinâmica de compartilhamento de conhecimento e sobretudo acesso universal a recursos informacionais, potencializando um grande canal de comunicação no que concerne a produção científica por meio revistas eletrônicas, repositórios acadêmicos, bibliotecas digitais, entre outros. Esse cenário permitiu que novos recursos de conhecimento fossem disponibilizados para acesso público ou em consumo público em larga escala, geralmente sem qualquer impedimento de taxa de assinatura ou taxas de acesso, originando assim o movimento de acesso aberto (UNESCO, 2015).

Essa reprodução e a distribuição de obras digitais possuem um capital intelectual que é protegido pela lei dos direitos do autor, acarretando questionamentos e mudanças sobre a efetivação da tutela jurídica que acaba sendo afetada por essas novas formas de interação e tecnologias (ARAYA; VIDOTTI, 2011).

O direito autoral faz parte do que se conhece hoje como propriedade intelectual, isto é, uma proteção dada a todas as criações decorrentes do espírito humano de caráter científico, literário, artístico ou industrial (DUARTE; PEREIRA, 2009).

Pode-se dizer que o direito autoral tem como objetivo conceder proteção legal a uma vasta variedade de obras literárias, como é o caso de livros, revistas, jornais, música, pinturas, fotografias, esculturas, entre outros. Essa proteção tem uma duração limitada o qual permite que o autor explore patrimonialmente a sua obra, por qualquer forma "direta ou indireta" (INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL, 2013).

No Brasil a legislação que regula os direitos do autor é a Lei 9610/98. A proteção da obra intelectual permanece durante toda a vida do autor sendo transmissível por mais de 70 anos e independe de registo. A sua redistribuição depende inteiramente de autorização do autor da obra (BRASIL, 1998). A legislação brasileira poderia ser considerada, pela sua data de promulgação e pelo seu conteúdo, como uma legislação pré-internet que não contempla muitas das interações e transformações digitais ocorridas ao longo dos anos.

Com isso, discussões acerca da disponibilização e compartilhamento de obras de caráter intelectual para terceiros no meio virtual, principalmente no que se concerne a "novas" obras intelectuais, como é o caso do software, começam a entrar na pauta da proteção intelectual.

De acordo com Muriel-Torrado e Fernández-Molina (2014), o desajuste da legislação vigente e as mudanças proporcionadas pelo ambiente digital, ainda é grande e impedem que as atividades possam decorrer com normalidade e segurança devida. Muitas pessoas ainda não sabem que ao compartilhar uma obra, automaticamente estará refrigindo os direitos autorais daquele que o possui, salvo em caso de autorização prévia ou licenciamento.

Em decorrência de tais discussões, iniciativas como as licenças creative commons e software livre (caracterizadas como copyleft) começaram a estender a liberdade de compartilhar ou reutilizar ativos como obras intelectuais e softwares por meio de proteção de direitos autorais (UNESCO, 2015).

O movimento do software livre foi iniciado com Richard Stallman que trazia em seu discurso o livre acesso ao software em uma época na qual algumas empresas, como a Microsoft, começaram a pressionar as autoridades governamentais, para torná-lo passível de patente (STALLMAN, 2015).

O pontapé inicial foi o desenvolvimento de um sistema operacional completamente livre em 1983, chamado GNU que fora compartilhado por uma licença chamada general public license (GPL), que usava o próprio regime dos direitos do autor para restringir a capacidade de outras pessoas de usá-lo, distribuí-lo, copiá-lo ou desenvolver outro sistema a partir deste,) a qual posteriormente, tornou-se a principal referência para a criação de diversas licenças de código aberto e a formação da Free Software Foundation, organização que prega o livre acesso ao software com novas licenças de distribuição e compartilhamento desde que sejam respeitadas as quatro liberdades principais; a de execução; modificação; redistribuição e distribuição de versões modificadas (STALLMAN, 2015).

Porém, a preocupação sobre questões autorais não estava somente relacionada ao software. As obras intelectuais maciçamente compartilhadas, como já mencionadas, em bibliotecas digitais, canais de comunicação e produção online começaram a levantar questionamentos sobre a distribuição de obras autorais. Por conta disso em 2002, inspirado no movimento do software livre, Lawrence Lessig elaborou licenças públicas padronizadas, chamadas creative commons, estabelecendo direitos concedidos a obras intelectuais entre elas livros, artigos, filmes, músicas, entre outros. Com isso, pretendia-se tornar mais fácil a organização, o acesso, o compartilhamento e modificação dessas obras em rede (BRANCO, BRITTO, 2013; LIU, 2014).

Ao todo, são seis licenças creative commons padronizadas, com variação da mais permissiva a mais restritiva, onde a primeira possibilita a distribuição, remixagem, adaptação ou criação de

obras derivadas, mesmo que seja para fins comerciais, contando que seja dado crédito pela criação original. Já a segunda, permite que terceiros possam remixar, adaptar e criar obras derivadas ainda que para fins comerciais, contanto que o crédito seja atribuído ao autor e que essas obras sejam licenciadas sob os mesmos termos. Indo para a terceira, é permitido a redistribuição e o uso para fins comerciais desde que a obra seja redistribuída sem modificações e completa, creditando o autor. A quarta, autoriza a criação de obras derivadas sobre a obra licenciada assim como remixagem e adaptação, porém proíbe o uso tanto da obra como novas obras derivadas fins comerciais. A próxima licença possibilita que outros também remixem, adaptem e criem obras derivadas sobre a obra original sob a condição que não seja comercializado, atribuam crédito ao autor e que licenciem as novas criações da mesma maneira. Por último, a mais restritiva, permitindo que outros apenas façam download e compartilhem as obras licenciadas, entretanto, não poderá modificar a obra de nenhuma forma, muito menos utilizá-la para fins comerciais (BRANCO; BRITTO, 2013).

Esses mecanismos trouxeram importantes reflexões sobre a necessidade de oferecer um arcabouço legal por meio de um licenciamento, que pudessem expressar o compartilhamento sem negligenciar os direitos do autor. Essas licenças oferecem uma convergência entre a proteção e a rede colaborativa incluindo ferramentas necessárias para desenvolver e distribuir programas e obras sem fronteiras ao mesmo tempo que obriga que todos os licenciados façam referência ao autor da obra e alguns casos até utilizem o mesmo modelo de licenciamento nas suas redistribuições inclusive em suas versões derivadas (MONIZ; CERDEIRA, 2004; LEMOS; BRANCO JÚNIOR, 2006).

Em vez de permitir que um trabalho seja totalmente disponibilizado em domínio público, onde não existe nenhuma restrição de direitos imposta, podendo correr o risco inclusive de ter sua obra ou derivação desta protegida posteriormente por questões autorais, essas licenças permitem ao autor, impor algumas restrições aqueles que queiram utilizar seu trabalho mas que seja também permitido o compartilhamento e distribuição destes.

Apesar de já haver estudos e pesquisas apontando para modificações na própria lei dos direitos do autor, tal pauta ainda encontra-se em discussão, sendo que enquanto isso, a utilização das licenças vem crescendo ao longo dos últimos anos (ROSA, 2014). De acordo com os dados da Federação das Indústrias do Estado de Santa Catarina – FIESC ([201-]) uma das grandes macrotendências no setor da tecnologia da informação e comunicação atual são as plataformas abertas de software, onde, apenas no Brasil, 73% das empresas brasileiras utilizam softwares livres. Ainda, segundo dados da própria comunidade Creative Commons, ([201-]), mais de 1,6 bilhão de obras intelectuais vem sendo compartilhadas por meio dessas licenças. Perceber a ascensão do tema é essencial para que possa não somente abrir maiores estudos e compreensão, mas também como utilizá-las de forma adequada e responsável (CHAVES, PEREZ, CHAVES, 2013). Espera-se, portanto, que ao expor a discussão, estudos mais aprofundados sejam realizados futuramente.

5 Conclusão ou Considerações Finais

Em uma sociedade da informação altamente colaborativa, percebe-se que as pessoas não trabalham mais exclusivamente sozinhas. Há autores que escrevem livros contando com a

contribuição dos leitores, usuários da internet que criam diariamente obras derivadas e programas de computador de forma coletiva e que ao mesmo tempo comercializam seus produtos oriundos desses ativos.

Nesse sentido, o estabelecimento de movimentos como software livre e creative commons permite que por meio de licenças permissivas seja criado um mecanismo flexível que ao mesmo tempo que facilita o compartilhamento, a reutilização e a derivação de um conteúdo intelectual em domínios profissionais e a comunidade como um todo, traz consigo o direito de autor que defende algumas regras que devem ser respeitadas, como a referência de seu trabalho a obras de terceiros, assim como em alguns casos, a obrigação de compartilhar a obra nos mesmos formatos licenciados.

Enquanto ainda não são definidas políticas mais efetivas em relação a proteção de direitos autorais no meio cibernético, as licenças vêm como uma alternativa de reflexão de acesso, modificação e distribuição de ativos de altíssimo valor agregado protegidos por um mecanismo legal já estabelecido.

Referências

ARAYA, Elizabeth Roxana Mass; VIDOTTI, Silvana Aparecida Borsetti Gregorio. Web colaborativa: inovação na criação, proteção e uso legal de informação. **DataGramaZero – Revista de Ciência da Informação**, Rio de Janeiro, v.12 n.4, ago. 2011.

BÉRANGER, Jérôme; RAVIX, Valéry. Une société consumériste d'information orientée vers une infosphere éthique. **La Revue canadienne des sciences de l'information et de bibliothéconomie**, Toronto, v. 37. n. 4, p. 253-266, 2013. Disponível em:<http://www.adel-label.com/wp-content/uploads/2016/05/24eme-article-beranger.pdf>. A cesso em: 29 mar. 2018.

BRANCO, Sérgio; BRITTO, Walter. **O que é Creative Commons? Novos Modelos de direito autoral em um mundo mais criativo**. Rio de Janeiro: Editora FGVm 2013. 176p. Disponível em: <http://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/11461/O%20que%20%C3%A9%20Creative%20Commons.pdf>. Acesso em: 29 mar. 2018.

BRASIL. Lei n. 9.609, de 19 de fevereiro de 1998b. Dispõe sobre a proteção da propriedade intelectual de programa de computador, sua comercialização no País, e dá outras providências. **Diário Oficial [da] República Federativa do Brasil**, Brasília, DF, 19 fev. 19 fev. 1998. Disponível em:<http://www.planalto.gov.br/ccivil_03/leis/L9609.htm>. Acesso em: 17 fev. 2018.

CARMELI, Abraham; GELBARD, Roy; REITER-PALMON, Roni. Leadership Creative Problem – Solving, Capacity and Creative Performance: The importance of knowledge sharing. **Human Resource Managment,** v. 52, n.1, p. 95-122, jan/fev. 2013. Disponível em: <https://en-coller.tau.ac.il/sites/nihul_en.tau.ac.il/files/RP_237_Carmeli.pdf>. Acesso em: 17 nov. 2018.

CHAVES, Flávia Gonçalvez; PEREZ, Nuria Rojo; CHAVES, Paula Gonçalves**. A importância do uso de softwares livres na formação acadêmica**. [S.l], 2013. Disponível em:<ueadsl.textolivre.pro.br/2013.1/papers/upload/34.pdf>. Acesso em: 03 jul. 2018.

CREATIVE COMMONS**. Our Movement around the World**. [S.l.], [201-]. Disponível em: <https://stateof.creativecommons.org/>. Acesso em: 10 jun. 2018.

DUARTE; Eliane Cordeiro de Vasconellos Garcia; PEREIRA, Edmeire Cristina. **Direito autoral: perguntas e repostas**. Curitiba: UFPR, 2009. 164 p. Disponível em: <http://www.cipead.ufpr.br/wpcontent/uploads/2015/03/LivroDireitoAutoral.pdf>. Acesso em: 20 mar. 2018.

EVENS, Tom. Creative Commons licenses in cultural heritage institutions in Flanders. **Journal of Librarianship and Information Science**, v. 48, n. 2, p. 209-217, 2015.

FIESC. Federação das Indústrias do Estado de Santa Catarina.Tendências. [S.l.]; [201-]. Disponível em: <http://portalsetorialfiesc.com.br/grafico-tendencias>. Acesso em: 15 nov. 2018.

GIDDENS, Anthony. **The Consequences of Modenity**. Califórnia: Standford University Press, 1990. 188 p.

INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL. INPI. **Expressão criativa: uma introdução ao direito de autor e aos direitos conexos para pequenas e médicas empresas**. Rio de Janeiro: INPI, 2013. 88 p.

KAWAMURA, Takaya. Managing networks of communities of practice for organizational knowledge creation: a knowledge management imperative in the era of globalization.**Annales Des Télécommunications**, v. 62, n. 7-8, p. 734-752, 2007.

LEMOS, Ronaldo; BRANCO JÚNIOR, Sérgio Vieira. Copyleft, Software Livre e Creative Commons: A Nova Feição dos Direitos Autorais e as Obras Colaborativas. **Revista de Direito Administrativo**, Rio de Janeiro, v. 243, p. 148-167, jan. 2006. Disponível em:<http://bibliotecadigital.fgv.br/ojs/index.php/rda/article/view/42557/41318>. Acesso em: 17 Nov. 2018.

LEVIN, Ilya. Cultural Trend in a Digital Society.IN: TMCE, 10, 2014, Budapest, Hungria. **Anais…** Budapeste, 2014. 21p.

LIU, Chen-Chung et al. Online knowledge sharing experience with Creative Commons. **Online Information Review**, v. 38, n. 5, p. 680-696, 2014.

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Fundamentos de metodologia científica**. São Paulo: Atlas, 2003. 312 p. Disponível em:

<https://docente.ifrn.edu.br/olivianeta/disciplinas/copy_of_historia-i/historia-ii/china-e-india>. Acesso em: 3 abr. 2018.

MONIZ, Pedro de Paranaguá; CERDEIRA, Pablo de Camargo. Copyleft e software livre: uma opção pela razão – eficiências tecnológica, econômica e social. **Revista da ABPI**, n. 70, p. 65-70, 2004.

MURIEL-TORRADO, Enrique; FÉRNADEZ-MOLINA; J. Carlos. Enseñanza digital versus derechos de autor: el papel de la biblioteca universitária em apoyo de professores y alumnos. **Revista eletrônica de Biblioteconomia e Ciência da Informação**, v. 19, n. 39, p. 205-226, jan. /abr., 2014.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de Freitas. **Metodologia do trabalho Científico: métodos e técnicas da pesquisa e do trabalho acadêmico.** Novo Hamburgo: Feedvale, 2012, 276 p. Disponível em: <http://www.feevale.br/Comum/midias/8807f05a-14d0-4d5b-b1ad-1538f3aef538/Ebook%20Metodologia%20do%20Trabalho%20Cientifico.pdf>. Acesso em: 25 mar. 2018.

ROSA, Flávia. O direito autoral e o acesso aberto. In: SILVA, Rubens Ribeiro Gonçalves da (Org.). **Direito autoral, propriedade intelectual e plágio**. Salvador: EDUFBA, 2014, 214p. Disponível em:<https://repositorio.ufba.br/ri/bitstream/ri/15656/3/direito_autoral_propriedade_intelectual_plagio_RI.pdf>. Acesso em: 17 de nov. 2018.

SOUSA; Antônio José Figueiredo Peva de; AMARAL, Sueli Angélica do. Impacto do Compartilhamento da Informação e do Conhecimento para o Desenvolvimento de Inovações em Grandes Organizações. **Perspectivas em Gestão & Conhecimento**, João Pessoa, v. 2, Número Especial, p. 12-26, out. 2012. Disponível em: <http://periodicos.ufpb.br/ojs2/index.php/pgc>. Acesso em: 20 março. 2018.

STALLMAN, Richard. **Free Software, Free Society: Selected Essays of Richard M. Stallman**. Free Software Foundation: 3 ed Boston, 2015. 305 p. Disponível em: <https://www.gnu.org/doc/fsfs3-hardcover.pdf>. Acesso em 12 nov. 2018.

UNESCO. **Introduction to Open Acess**. Paris: UNESCO, 2015. 82p. Disponível em:<http://unesdoc.unesco.org/images/0023/002319/231920E.pdf>. Acesso em: 15 nov. 2018.

XUE, Nie. Research on Intellectual Property Protection under network information sharing environment**. Applied Mechanics and Materials**, v. 687, p. 191-194, 2014.

YANG, Guifang; MASKUS, Keith E. Intellectual Property Rights, licensing and innovation in an endogenous product –cycle model. **Journal of International Economics**, v. 53, p. 169-187, 1999.

Vídeo da apresentação

Título: As licenças Creative Commons e Software Livre como formas de proteção na sociedade da informação compartilhada.

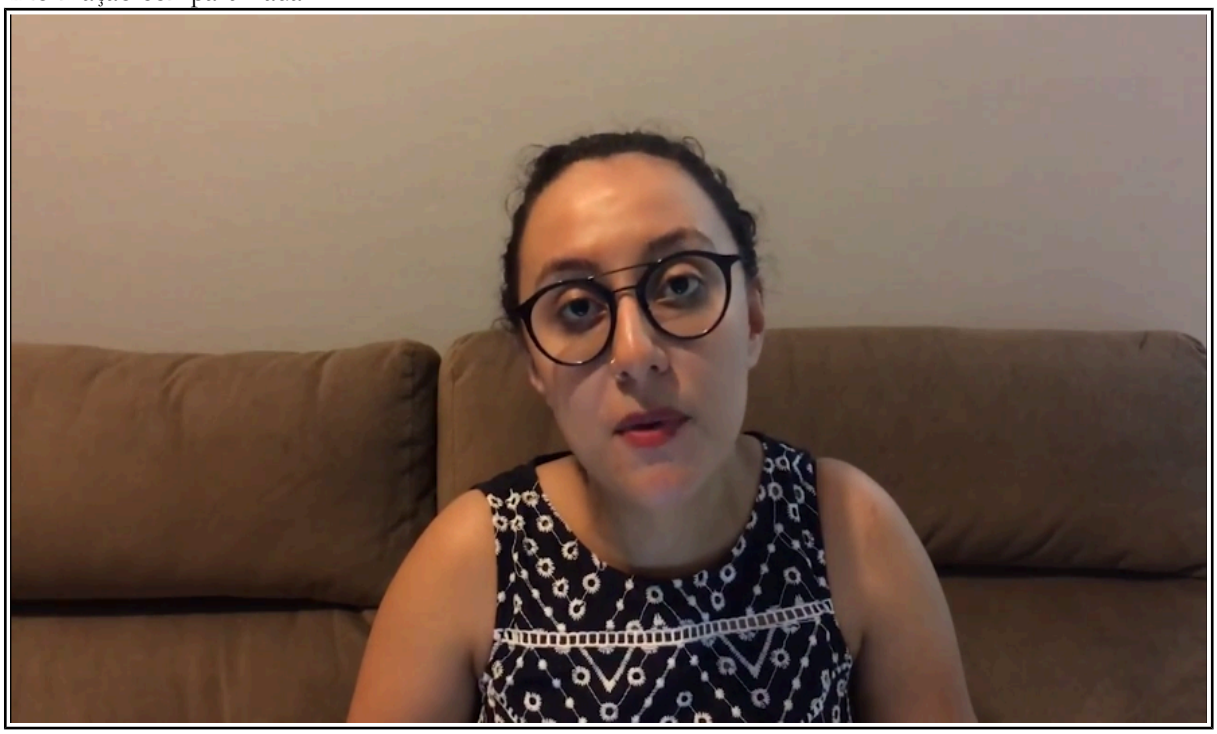

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=17

Transcrição da apresentação

Olá tudo bem meu nome é Maria Carolina Zanini Ferreira sou do programa de pós-graduação em propriedade intelectual e transferência de tecnologia para inovação (PROFNIT) na Universidade Federal de Santa Catarina a UFSC e venho por meio desse vídeo abordar um pouco sobre o artigo que eu submeti para o 2º Workshop de Informação, Dados e Tecnologia (WIDAT) 2018 que acontecerá na Universidade Federal da Paraíba.

O tema do meu artigo que eu submeti é sobre as licenças creative commons e software livre como forma de proteção da sociedade da informação compartilhada eu realizei essa pesquisa que é uma das partes é um dos temas da minha dissertação de mestrado com os meus orientadores.

Então a professora doutora Clarissa Stefani Teixeira do programa de pós-graduação em engenharia do conhecimento da UFSC e o professor doutor Henrique Muriel Torrado que é do programa de pós-graduação da ciência da informação.

Então basicamente o presente artigo o presente tema vai abordar de que forma essas licenças mais especificamente o Creative Commnons e Software Livre elas são alternativas de proteção intelectual em uma sociedade da informação compartilhada né então hoje em dia a gente começa a ter uma sociedade que ela é rica em conhecimento ela é rica em informação e não somente isso a descentralização e o compartilhamento desses artigos eles acabam trazendo novos fluxos informacionais e principalmente novas configurações culturais hoje em dia todo mundo está conectado todo mundo tem conhecimento e informação de uma maneira muito fácil, muito volátil muito rápida com o advento das tecnologias da comunicação e da informação hoje a gente conhece a globalização onde todo mundo está conectado não existem mais fronteira para o conhecimento para informação.

Hoje o acesso a todos esses ativos que são de altíssimo valor agregado eles são muito rápidos e acessíveis para todos por meio de uma pesquisa descritiva exploratória eu busco através de uma revisão sistemática através de uma revisão bibliográfica identificar quais são as características da nossa sociedade hoje a nossa sociedade é uma sociedade onde um indivíduos grupo específico como eu já falei ele pode ter um acesso à informação acesso à informação de um riquíssimo banco de dados do mundo inteiro e pode se conectar ele pode se ligar com todo mundo e com isso acabam sendo desenvolvidas novas tecnologias novas formas de interação novas formas de comunicação que trouxeram novos paradigmas frente a nossa sociedade como a gente conhecia.

Então não somente isso mas a gente começa a questionar vários pontos e até apontar alguns riscos do uso desses dessas informações desse conhecimento que acabam resvalando se inserindo no campo dos direitos autorais, então que é um arcabouço legal que assegura o autor daquela obra intelectual daquele conhecimento, proteção de direitos sobre a sua obra, automaticamente obtido com a sua criação e não somente isso novas tecnologias elas começam a ser inseridas no campo dos direitos autorais no campo desse arcabouço legal é um exemplo de software.

Então lembrando lembro novamente direitos autorais foi uma legislação que veio pra internet mas isso começou a gerar vários questionamentos não somente aqui em âmbito nacional mas como âmbito internacional é um pontapé o movimento do software livre daí a gente começa a ter um pouquinho mais o software está envolvido com direitos autorais ele foi iniciado pelo xeque Salman e ele transita em seu discurso o livre acesso ao código do código fonte do software

o mundo de uma época ao mesmo tempo você tinha essa mudança de pensamento de compartilhar de colaborar você tinha é pessoas como Bill Gates da Microsoft que defendia que o software deveria ser protegido.

Ele deveria ser passível de patente então foi nessa onda que Richard não concordou quando eu não concordo com isso acho que a gente tem que deixar o código aberto quanto mais pessoas desenvolver, quanto mais a gente saber o que as pessoas estão produzindo, mais nossa comunidade ela vai crescer, então e se desenvolver conhecimento vai ser compartilhado.

Então ele acaba criando em 1983 mais ou menos um sistema operacional completamente livre chamado GNU o que foi posteriormente compartilhado por uma licença chamada de GPL. Ela foi uma das primeiras licenças que usou o direito autoral para compartilhar, ou seja, uma licença que você respeitaria o direito do autor.

Mas não somente respeitar o direito do autor, você tem que dar ciência ao autor mas que também o autor estaria compartilhando com você de uma maneira totalmente aberta o seu código, e que você também deveria compartilhar e continuar compartilhando software de uma forma aberta com o código fonte aberto, então essa foi uma primeira licença que teve o pensamento do copyleft o que é que a gente conhece, que o Copyright que são os direitos do autor que a gente disse que o copyleft que vem contra essa questão de restringir de proteger de deixar em sigilo algumas informações esse movimento começou a ganhar mais corpo com a criação Free Software Foundation uma organização criada pelo próprio Stallmam, que tem ainda como principal objetivo de promover nessa cultura do software livre e também dessa cultura de compartilhamento de colaboração frente do que a gente conhece hoje, de patentear o software então ele vem com essa ideia de compartilhar software com isso foram criadas diversas licenças, depois softwares livre, totalmente livres que também possuíam licenças mais permissiva, licenças também que assegurava o seu código fonte com isso.

Com essa onda também tinha um lado a onda do compartilhamento de obras literárias e revistas artigos científicos fotografias filmes enfim então a gente começou também ter essa nova onda e com isso o professor Laércio inspirado na lei também pela iniciativa do Stallmam ele acaba criando seis licenças chamadas Creative Commons voltadas para obras literárias então são licenças públicas padronizadas que estabelece direitos concedidos as obras intelectuais elas vão das mais permissivas as mais restritivas onde você também tem o seu direito do autor assegurado você coloca que você a minha obra pode ser compartilhada desde que seja né é deus seja referenciado e também por algumas outras regras, alguns outros direitos, que vai variar de licença para licença.

Ao todo essas são seis licenças do Creative Commons. Essas licenças, como vocês podem ver, elas trouxeram importantes reflexões, não somente uma necessidade da gente rever mesmo o direito autoral nessa legislação que a gente tenha hoje, ela de fato vai ao encontro dessas novas tecnologias que é um software ou através desse compartilhamento das obras literárias.

Hoje a gente está tendo uma discussão sobre a mudança da legislação sobre novas formas de você compartilhar, mas que estão ainda em andamento e as licenças elas também são uma forma de prática de mostrar o que já está tentando ser feito pra tentar remediar, e também que você

continue compartilhando essas obras mas que não direitos autorais, porque ela usa do arcabouço legal dos direitos autorais para compartilhar, para licenciar seus trabalhos.

É de uma percepção de direito do autor você tem que dar crédito às pessoas, mas que você possa compartilhar sobre determinadas regras geralmente têm uma divergência ao falar de propriedade intelectual como a gente conhece, e essas licenças elas acabam sendo uma forma de você inserir e de você unir tanto a proteção intelectual ao fato direito autor, mas que esse autor também possa compartilhar com os seus usuários, com os seus, enfim, os seus leitores, desenvolvedores, seja um público-alvo sem que isso tira seus direitos.

Então é interessante a gente observar que essas licenças ela meio que acaba unindo essa nova realidade da sociedade da informação compartilhada mas que também tem o envolvido ele seu capital intelectual que por si só está protegido sobre leis de propriedade intelectual mais precisamente os direitos autorais e que por isso precisam umas regras precisam ser respeitadas.

Então a gente tá aí toda essa com essa reflexão do meu trabalho esse trabalho que eu submeti no WIDAT é um pedaço da minha dissertação de mestrado que está sendo desenvolvido aqui na Universidade Federal de Santa Catarina e que eu tento trazer um pouco para discussão essas questões que são tão atuais hoje em dia que estão sendo protagonista nesses grandes congressos que a gente tem de direitos autorais de propriedade intelectual no que se refere à sociedade da informação, acesso de dados e até maisa fundo na inteligência artificial Big Data e tudo mais.

Enfim eu agradeço a oportunidade pelo WIDAT por gravar esse vídeo está disseminando esse conhecimento é um assunto particularmente eu gosto bastante é meu tema de dissertação do mestrado então aqui vai ficar os contatos é tanto o meu tanto dos meus orientadores.

Para mais informações e trabalhos em conjunto de ideias críticas enfim tudo que possa agregar conhecimento é sempre muito bem-vindo, muito obrigado, e até mais.

Arbovis: uma aplicação de visualização de dados sobre Arboviroses

Talitha Alessandra Medeiros Ribeiro[a], Larissa de Sousa Moreira Gusmão[b] e Damires Yluska de Souza Fernandes[c]

Resumo: O volume de informações em saúde, em especial no cenário das arboviroses, cresceu juntamente com os desafios para trabalhar com os dados de forma que análises úteis possam ser feitas e usadas para apoiar a tomada de decisões. Este artigo apresenta a Arbovis, uma aplicação para análise visual de dados sobre arboviroses no estado da Paraíba. A arbovis disponibiliza visões interativas e customizadas sobre os referidos dados, baseadas em filtros que podem ser aplicados para gerar gráficos. Os dados apresentados foram obtidos através da Secretaria de Saúde do Estado da Paraíba e do IBGE. Como resultados iniciais, foram desenvolvidos gráficos de barras, barras horizontais e de linhas. Através da visão interativa, é possível identificar quais municípios possuem maior incidência de casos das doenças, por meio do cruzamento entre quantidade de habitantes e de casos, e também em quais houve maior quantidade de casos registrados. Dessa maneira, a Arbovis apresenta impacto positivo na gestão e na prevenção de doenças e epidemias, contribuindo para estudos e análises de pesquisadores, profissionais da saúde, gestores e da população em geral.

Palavras-chave: Arboviroses. Análise de dados. Visualização de dados. Aplicação web.

Arbovis: a data visualization application on Arboviruses

Abstract: The volume of health information, particularly in the arboviruses scenario, has grown along with the challenges of working with data in such a way that useful analyzes can be produced and used to support decision making. In this light, this paper presents Arbovis, an application for visual analysis of data on arboviruses. Arbovis provides interactive and customized views of the data, based on filters that can be applied to generate graphs. The data presented were obtained from the Department of Health of the State of Paraíba and also from the IBGE. As initial results, bar graphs, horizontal bars and lines were developed. Through an interactive view, it is possible to identify which cities have a higher incidence of arboviruses cases. This is obtained by crossing and integrating data from some data sources with registered cases. Thereby, Arbovis provides a positive impact on the management and prevention of diseases and epidemics, thus contributing to studies and analyzes of researchers, health professionals, managers and the population in general.

Keyword: Arboviruses. Data analytics. Data visualization. Web application.

a Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB). E-mail: medeirostalitha@gmail.com. Currículo: http://lattes.cnpq.br/7858413579199040

b Universidade Federal da Paraíba (UFPB). E-mail: larissamgusmao@gmail.com. Currículo: http://lattes.cnpq.br/7243590982999871

c Instituto Federal de São Paulo (IFSP) e Universidade Estadual Paulista (UNESP). E-mail: damires@ifpb.edu.br. Currículo: http://lattes.cnpq.br/9411293540915384

1 Introdução

A demanda por informações em saúde cresce a cada dia juntamente com os desafios para que sua utilização possa trazer resultados úteis à população. Em especial, o cenário associado às doenças transmitidas pelo mosquito Aedes aegypti (arboviroses) tem causado necessidades específicas de estudos e definições de políticas públicas. Diante disso, diversos órgãos institucionais, além de pesquisadores e profissionais de saúde, trabalham gerando dados sobre arboviroses.

À medida que os dados se tornam mais volumosos, com estruturas heterogêneas e com alta velocidade de produção, como é o caso de dados em massa, ou big data (GANDOMI; HAIDER, 2015), a complexidade nas tarefas de análise de dados aumenta. Isso se deve a fatores como o próprio volume de dados, a quantidade de atributos a serem gerenciados e interpretados (variedade de dados) e também a aspectos da qualidade dos dados (THABET; SOOMRO, 2015). Nesse sentido, estratégias de ETL (Extração, Transformação e Carga) e de visualização da informação podem ajudar (BANSAL; KAGEMANN, 2015).

Estratégias de ETL referem-se a processos que permitem extrair dados de diferentes fontes, transformá-los para atender as necessidades de padronização e uso, e carregá-los em repositórios de destino. Com os dados extraídos, o próximo passo é visualizá-los. A visualização da informação pode ser definida como o uso de representações visuais interativas de dados abstratos para amplificar a cognição (SHNEIDERMAN; PLAISANT; HESSE,

2013). Está associada à transformação de dados abstratos em, por exemplo, gráficos e imagens, denominados visualizações (VIEIRA; CORREA, 2011).

Nesse contexto, surge o termo "análise visual de dados" que busca integrar técnicas de visualização da informação com as de análise de dados. Mais precisamente, o termo Visual Analytics ou Análise Visual foi introduzido por Thomas e Cook (2005) quando se percebeu que a representação visual utilizando apenas técnicas de visualização de informação não era suficiente para viabilizar a análise de dados em massa (CARMO, 2015). Técnicas de interação e manipulação direta foram associadas à atividade de análise de modo que o usuário (que tem o papel de analista de dados) pudesse ser o centro e o coordenador da atividade. Estratégias que incluem a aplicação de filtros nos dados, operações de seleção de objetos visuais, navegação, exploração por zoom, construção de representações visuais podem ampliar as possibilidades das tarefas analíticas (FEKETE, 2013). Tais estratégias podem facilitar a personalização das tarefas de análises de dados e torná-las mais intuitivas.

Nessa perspectiva, este artigo propõe a aplicação Arbovis[63], que visa apresentar dados sobre arboviroses, no estado da Paraíba, por meio de visualizações interativas. A versão apresentada neste trabalho é uma extensão da aplicação de Santiago et al. (2018), que não incluía opções de interatividade e análises visuais construídas dinamicamente. Como resultado, o ambiente de análise de dados se torna mais rico, interativo e as informações geradas são mais compreensíveis.

63 http://arboviz.siderg.com.br/

2 Objetivos

O objetivo da Arbovis é mostrar visões significativas sobre arboviroses, distribuindo filtros de apresentação de forma que o usuário possa montar visualizações específicas dos dados de acordo com suas necessidades. Desse modo, as visualizações pretendem contribuir para análise visual de dados sobre arboviroses por meio de recursos de interatividade como filtros nos dados, operações de seleção de objetos, navegação e exploração em representações gráficas diferentes.

3 Trabalhos Relacionados

Alguns exemplos de aplicações serviram como base para compor a abordagem proposta por este trabalho. A VisPublica (RIBEIRO et al., 2012) apresenta técnicas de visualização da informação (InfoVis) que são aplicadas para facilitar a transparência de dados públicos. Esta aplicação permite que os usuários utilizem as técnicas e tecnologias mostradas no catálogo para gerar as visualizações dos seus próprios dados.

A Vis-Saúde (KAIESKI, 2014) é um sistema de código aberto, no qual os registros de saúde pública são usados para fornecer análises. A aplicação propõe uma metodologia de análise e visualização da correlação entre as variáveis associadas à ocorrência de uma enfermidade em uma região.

A DataViva[64] é uma plataforma de pesquisa com dados abertos que tem como objetivo fornecer dados estatísticos sobre saúde, transporte público, economia, educação e outros domínios de dados associados a várias cidades brasileiras. Recentemente, a DataViva incluiu dados fornecidos pelo DATASUS, o órgão público da saúde do governo brasileiro.

4 Procedimentos Metodológicos

Para viabilização do desenvolvimento da aplicação, foram realizadas reuniões com gestores da Secretaria de Saúde do Estado da Paraíba. O levantamento dos requisitos foi feito por meio de entrevistas, em que foram identificados os aspectos que os gestores consideram relevantes para a análise dos dados e que gostariam de visualizar na aplicação.

Por meio dessas reuniões, foram obtidas planilhas em formato CSV com os dados sobre as arboviroses. Os municípios e os dados sobre o quantitativo de habitantes foram obtidos através do IBGE[65]. Para embasamento técnico, foram realizados testes com tipos de gráficos diferentes utilizando as linguagens de programação Python[66] e JavaScript[67], o objetivo era identificar qual apresentação e tecnologia seriam mais eficazes para o desenvolvimento da análise interativa visual. Como mostra a Figura 1, para a implementação da aplicação, primeiramente foi feito o pré-processamento dos dados obtidos. Após isso, os dados foram convertidos para o formato JSON[68], foram integrados e persistidos na base de dados MongoDB[69]. Em seguida, a aplicação foi implementada utilizando Python juntamente com o microframework Flask[70]. A integração entre o

64 http://dataviva.info/pt/
65 https://www.ibge.gov.br/geociencias-novoportal/organizacao-do-territorio/estrutura-territorial/15761-areas-dos-municipios.html?=&t=downloads
66 https://www.python.org/
67 https://www.javascript.com/
68 http://www.json.org/
69 https://www.mongodb.com/
70 http://flask.pocoo.org/

Python e o MongoDB foi feita através da distribuição PyMongo[71]. Por fim, foi iniciada a plotagem dos gráficos com a biblioteca JavaScript Chart.js[72].

A Figura 1: Mostra o processo empregado para o desenvolvimento da aplicação.

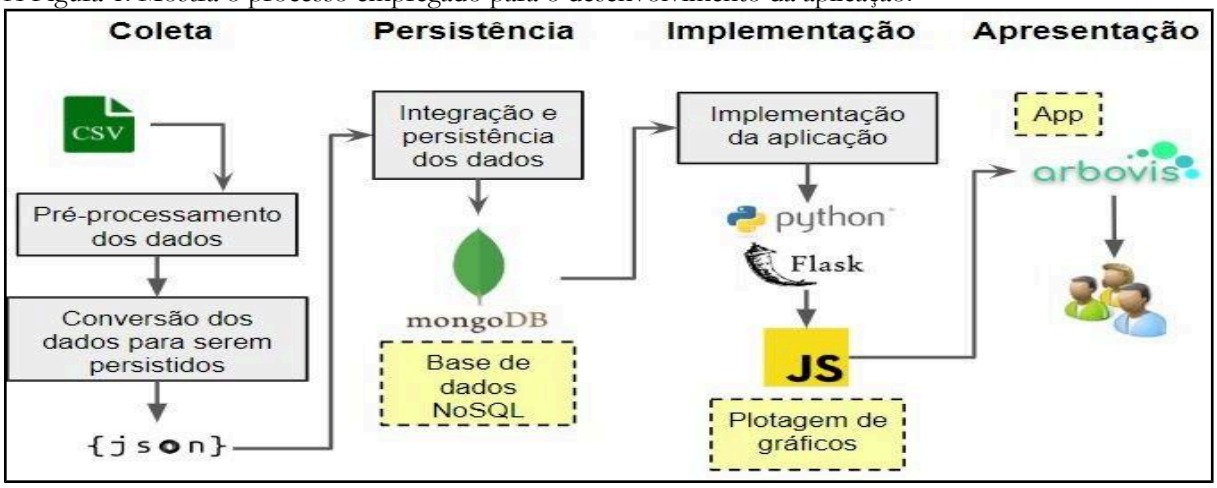

Fonte: Os autores.

5 Arbovis: abordagem e implementação

A Arbovis foi desenvolvida com foco em apresentar informações sobre as arboviroses de maneira clara e interativa para gestores, profissionais de saúde e para a população em geral.

5.1 Abordagem e funcionalidades

As principais funcionalidades da aplicação são i) filtrar dados, ii) selecionar gráfico e iii) selecionar visualização. De acordo com a pesquisa montada pelo usuário, a consulta é realizada no banco de dados e o resultado é retornado para o usuário. Uma visão geral da abordagem da Arbovis é apresentada na Figura 2.

Figura 2: Abordagem da Arbovis.

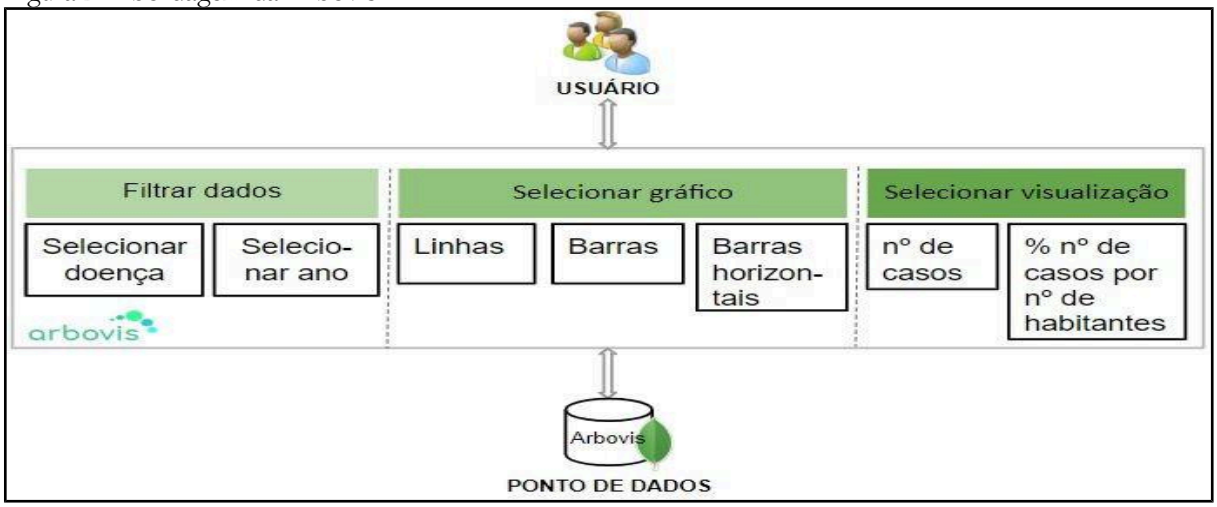

Fonte: Os autores.

71 https://api.mongodb.com/python/current/
72 https://www.chartjs.org/

5.2 Implementação e cenário de uso

Com o objetivo de facilitar o acesso as visualizações, a seção de indicadores foi evidenciada no painel da página principal, na barra de navegação e no rodapé. A Figura 3 mostra a tela principal da aplicação, com destaque para a opção de montar o gráfico de acordo com os filtros disponibilizados. Além das funcionalidades principais, o usuário também é informado sobre a sintomatologia das arboviroses, há também uma breve descrição sobre as doenças (Figura 4).

Figura 3: Página principal da Arbovis.

Fonte: Arbovis.

Figura 4: Página principal da Arbovis.

Fonte: Arbovis.

A página de indicadores contém a visualização dos dados sobre as doenças. Esta seção é composta por filtros que o usuário pode selecionar de acordo com o objetivo da sua pesquisa, as opções selecionadas geram o gráfico dinamicamente (Apêndice A). Os filtros apresentados são i) Selecionar doença; ii) Selecionar ano; iii) Selecionar tipo de gráfico; iv) Selecionar tipo de visualização.

Considerando um cenário no qual no filtro de doença é selecionada a chikungunya, no filtro de ano de ocorrência é selecionado o ano de 2017, o gráfico apresentado é o de linhas, que por padrão já é selecionado, e número de casos absolutos (Apêndice B), é possível perceber que o município mais representativo, com 4556 casos registrados, é João Pessoa. Entretanto, se for aplicada a visualização por porcentagem do número de casos por número de habitantes, como mostrado no Apêndice C, o município de São Bentinho se destaca entre os outros, com 5.35% de casos por número de habitantes.

Outro cenário pode ser visto no Apêndice D, em que são selecionados a doença dengue e o ano de 2016 com gráfico de barras e número de casos absolutos registrados por município. Neste contexto, o município com mais registros é João Pessoa, com 7701 casos. Já no cenário de porcentagens do número de casos pelo número de habitantes, como mostrado no Apêndice E, o município mais significativo é Juripiranga, com 27.58% de casos por número de habitantes.

Através das visões apresentadas, é possível identificar quais são os municípios que necessitam de maior atenção do governo, por possuírem maior incidência de casos das doenças. Dessa forma, as visualizações disponibilizadas pela Arbovis possibilitam ações mais assertivas por parte dos gestores.

5.3 Avaliação da Arbovis

Com o objetivo de analisar aspectos da Arbovis como a usabilidade na utilização e apresentação dos indicadores, foi realizada uma avaliação inicial com um gestor da Secretaria de Saúde da Paraíba.

No aspecto da utilização da Arbovis, o gestor considerou a aplicação fácil de usar e também indicou que ela o ajudou a encontrar informações importantes sobre as arboviroses.

Outro aspecto apontado é a apresentação dos indicadores, em que o usuário considerou os filtros adequados para a realização das consultas e que tornaram a aplicação interativa. Além disso, informou que a aplicação apresenta praticidade nos resultados apresentados. Como sugestão de melhoria, foi sugerido acrescentar índices de infestação predial por município junto às taxas de incidência dos agravos, estes são dados que serão futuramente integrados à base existente.

6 Considerações Finais

A Arbovis é pautada em um problema social e possibilita o uso de dados reais em um cenário de demandas concretas a esses dados. Os resultados obtidos com esta aplicação possuem impacto especial na gestão em relação a prevenção de doenças e epidemias causadas pelo Aedes aegypti.

Pesquisadores, professores, gestores ou quaisquer interessados poderão consultar os dados de forma integrada e analisá-los de acordo com suas necessidades. Para os gestores, a aplicação é significativa pois os resultados obtidos através das visões customizadas podem contribuir para a tomada de decisão. Entretanto, para expandir as possibilidades de análise dos gestores esperamos incluir em trabalhos futuros o uso de mapas e averiguar a eficácia dessa visualização na gestão.

Também podem ser identificadas necessidades específicas de diferentes perfis, para contribuir em maior profundidade em seus estudos e análises. Um perfil que se destaca para ser explorado é o profissional de saúde.

Referências

BANSAL, S.; KAGEMANN, S. Integrating Big Data: A Semantic Extract-Transform-Load Framework. **Computer**, vol.48, n.3, p. 42-50, 2015.

CARMO, A.. **Exploração e análise de dados coletados pelo Sistema Integrado de Monitoramento Ambiental utilizando técnicas de Visual Analytics**. 2015. Dissertação de Mestrado. Faculdade de Ciências e Tecnologia (FCT), Presidente Prudente, 2015. Disponível em: <https://repositorio.unesp.br/handle/11449/138391>. Acesso em: 04 ago. 2018.

FEKETE, J. Visual Analytics Infrastructures: From Data Management to Exploration. **Computer**, Institute of Electrical and Electronics Engineers, Visual Analytics: Seeking the Unknown, vol.46, n.7, p.22-29, 2013.

GANDOMI, A.; HAIDER, M. Beyond the hype: Big data concepts, methods, and analytics. **International Journal of Information Management**, Ontario, v.35, p.137-144, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0268401214001066>. Acesso em: 05 out. 2018.

KAIESKI, N. **Vis-Saúde – Uma metodologia para visualização e análise de dados de saúde pública**. 2014. Dissertação de Mestrado (UNISINOS), São Leopoldo, 2014. Disponível em: <http://www.repositorio.jesuita.org.br/handle/UNISINOS/3619>. Acesso em: 04 ago. 2018.

RIBEIRO, F. et al. VisPublica: uma proposta para aprimorar a transparência de dados públicos. In: **VIII Simpósio Brasileiro de Sistemas de Informação**, 2012, São Paulo. p. 480-491.

SANTIAGO, M., ALENCAR A., FERNANDES, SOUZA, D. (2018). A Semantic-based Approach for Facilitating Arbovirus Data Usage. 20º International Conference on Enterprise Information Systems (ICEIS), Funchal, 2018.

SHNEIDERMAN, B., PLAISANT, C., HESSE, Improving health and healthcare with interactive visualization methods. **Computer**, vol. 46, n. 5, p. 58-66, 2013.

THABET, N.; SOOMRO, T. Big Data Challenges. **Journal of Computer Engineering & Information Technology**. Dubai, 2015. Disponível em:

<https://www.researchgate.net/publication/282281171_Big_Data_Challenges>. Acesso em: 04 out. 2018.

THOMAS, J. J.; COOK, K. A. (2005). Illuminating the Path: The Research and Development Agenda for Visual Analytics. [S.l.]: National Visualization and Analytics Ctr. Paperback. ISBN 0769523234.

VIEIRA, J., CORREA, R. Visualização da Informação na construção de interfaces amigáveis para Sistemas de Recuperação de Informação. **Encontros Bibli: revista eletrônica de biblioteconomia e ciência da informação**, Florianópolis, v. 16, n. 32, p.73-93, out. 2011. ISSN 1518-2924. Disponível em: <https://periodicos.ufsc.br/index.php/eb/article/view/1518-2924.2011v16n32p73>. Acesso em: 04 ago. 2018.

Apêndice A – Filtros selecionados para visualização customizada.

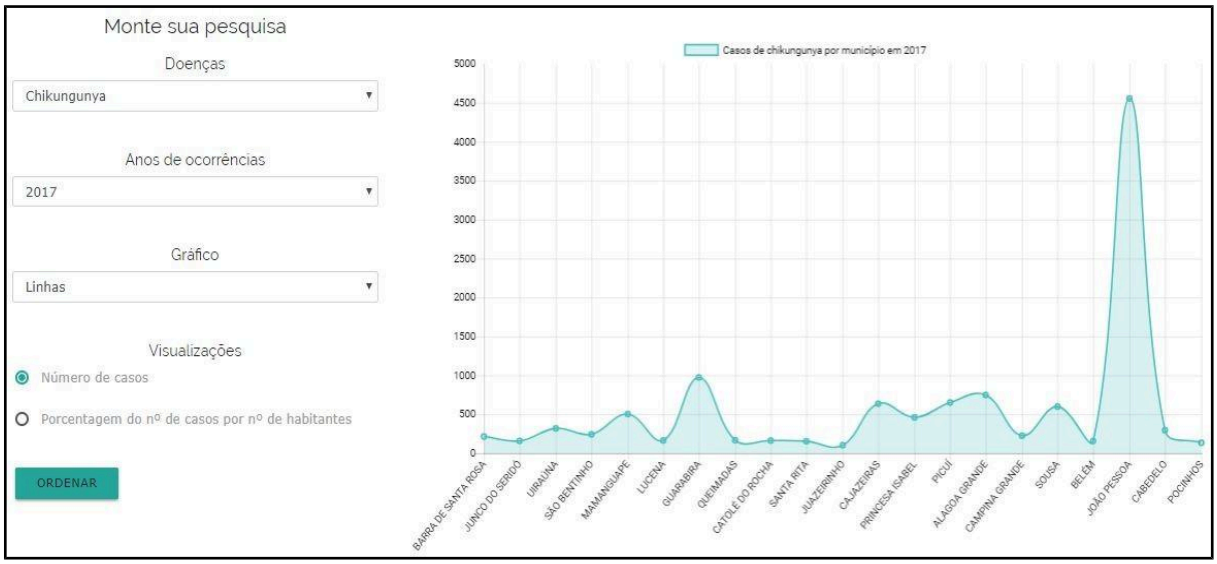

Fonte: Arbovis.

Apêndice B – Gráfico de linhas com casos de chikungunya por município em 2017 com número de casos totais.

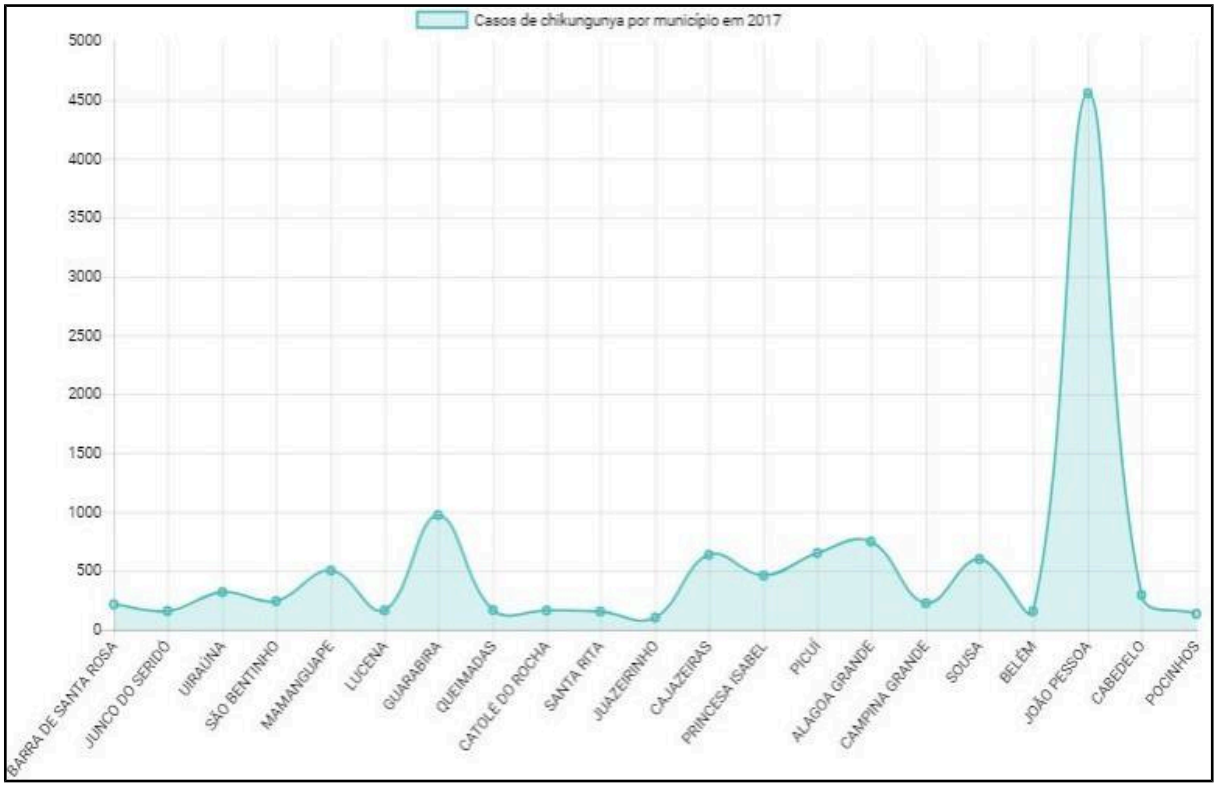

Fonte: Arbovis.

Apêndice C – Gráfico de linhas com casos de chikungunya por município em 2017 com porcentagem de casos por número de habitantes.

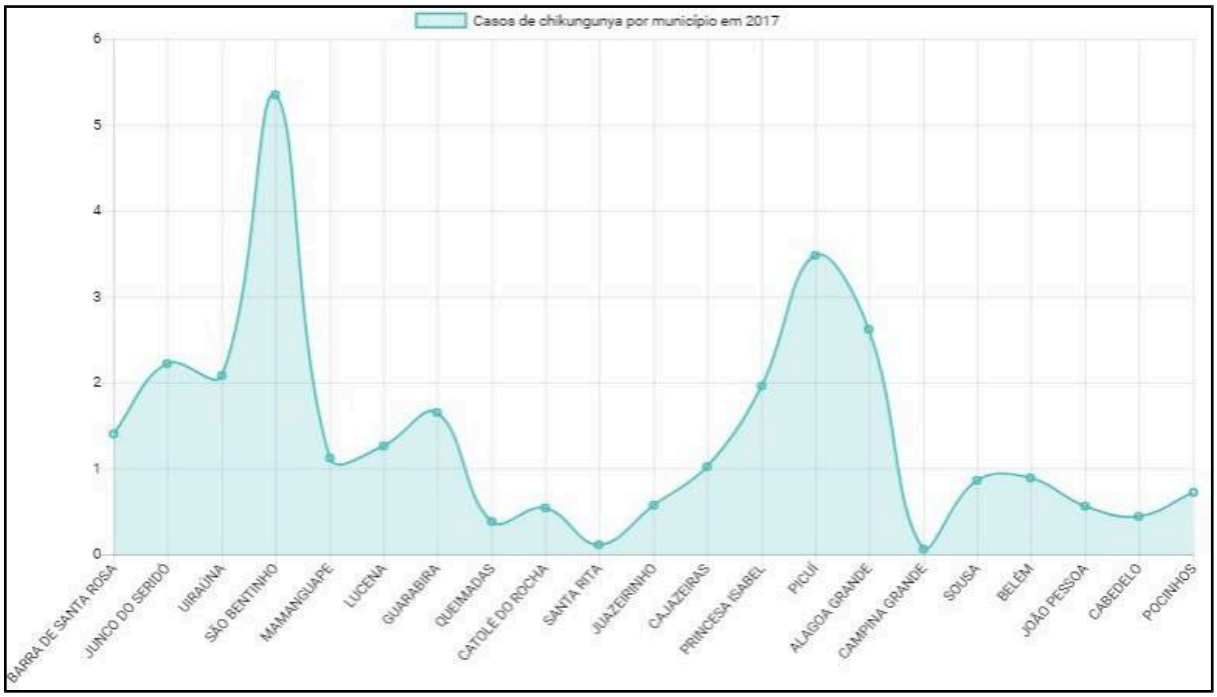

Fonte: Arbovis.

Apêndice D – Gráfico de barras com casos de dengue por município em 2016 com número de casos totais.

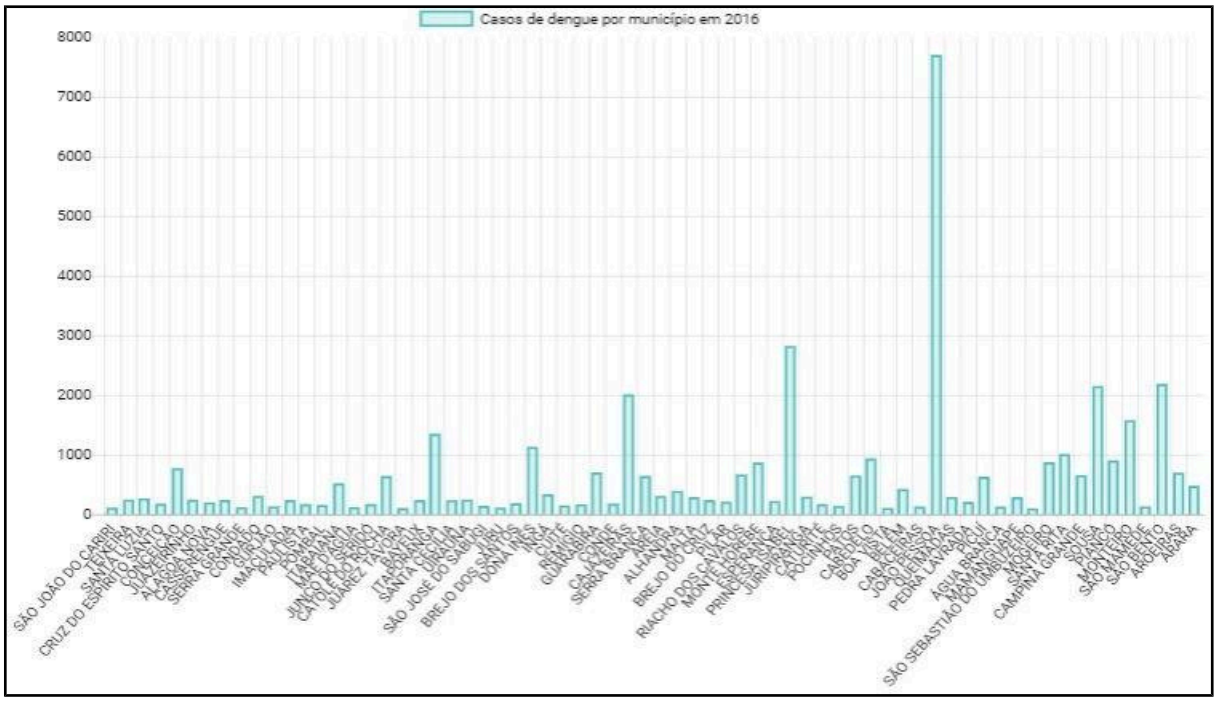

Fonte: Arbovis.

Apêndice E – Gráfico de barras com casos de dengue por município em 2016 com porcentagem de casos por número de habitantes.

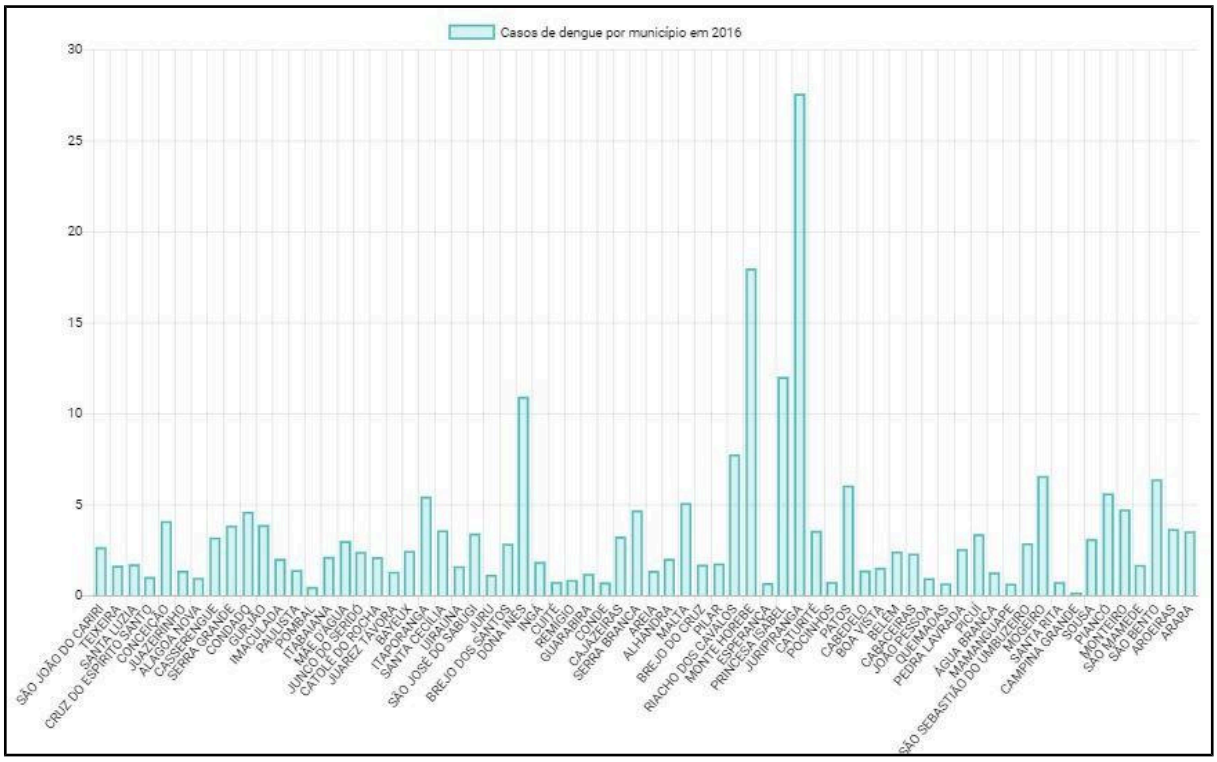

Fonte: Arbovis.

Vídeo da apresentação

Título: Arbovis: Uma aplicação de visualização de dados sobre Arboviroses.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=18

Transcrição da apresentação

Olá, eu me chamo Talita Medeiros e eu me chamo Larissa Moreira. Nós somos do curso de Sistemas para internet do Instituto federal de educação ciência e tecnologia da Paraíba, campus de João Pessoa, e somos pesquisadores da área da Ciência da computação. Nossa orientadora é a professora do curso de Sistemas para Internet, Damires Sousa.

O objetivo deste vídeo é apresentar nosso projeto para o 2º Workshop de Informação, Dados e Tecnologia.

Este evento tem como intuito de unir através de abordagens interdisciplinares as comunidades acadêmicas e industriais que trabalham com dados no Brasil.

O nosso projeto consiste é uma aplicação de visualização de dados sobre a arboviroses no estado da Paraíba. A arboviroses são as doenças causadas pelo mosquito Aedes aegypti como Chikungunya, Dengue e Zika.

Esses dados foram obtidos através de uma parceria com a secretaria de saúde do estado da Paraíba.

O objetivo do nosso trabalho é prover visões interativas que facilitem informações sobre essas doenças e também que auxiliem os gestores da saúde em sua tomada de decisão.

Essa é a Arbovis. Arbovis é uma aplicação de visualização de dados sobre a arboviroses no estado da Paraíba. Nela podemos ver quais são os sinais, sintomas, origens locais de notificação, indicadores associados às doenças causadas pelo Aedes aegypti.

Arbovis contém dados de Chikungunya, Dengue e da Zika dos municípios da Paraíba nos anos de 2015 a 2017. Nessa sessão Arbovis apresenta uma campanha contra o mosquito Aedes aegypti contendo vídeos informativos sobre o mosquito e as doenças que ele causa.

Arbovis tem como parceiros a secretaria de saúde do estado da Paraíba que foi como obtemos os dados sobre as arboviroses; o grupo de pesquisa SIDE; o curso de Sistemas para internet e o IFPB.

Na seção de doenças Arbovis apresenta um quadro de sintomas das arboviroses onde podemos ver quais são os sintomas mais recorrentes de cada doença. Mais abaixo podemos visualizar breves descrições sobre as doenças. Na página de sobre é falado sobre o que é Arbovis e qual é a equipe de desenvolvimento. Nos indicadores podemos montar a nossa pesquisa: primeiro selecionamos a doença; aqui são mostrados os anos de ocorrências, queremos ver no caso os dados de 2015 de dengue.

Aqui está sendo apresentado uma visualização dos casos de Dengue por mês no ano de 2015. O mês que apresentou mais casos em 2015 foi maio com 5.795 casos de dengue.

Podemos também ter outras visualizações dos casos. Por exemplo podemos ver o número de casos por município. O município que apresentou maior número de casos em 2015 foi João Pessoa com 5.204 casos no ano de 2015.

Podemos também ordenar esses dados do menor para o maior para visualizarmos de forma mais fácil qual foi o município que apresentou maior número de casos. Além disso podemos visualizar esses dados em outros tipos de gráficos como barra, barras horizontais e mapa.

Uma outra forma de visualização que Arbovis apresenta é a porcentagem do número de casos por número de habitantes onde podemos ver proporcionalmente qual município apresentou o maior número de casos de acordo com o número de habitantes.

Agora vamos ver casos de outra doença. Chikungunya, selecionamos o ano 2016, o tipo de visualização que desejamos ver, o número de casos absolutos e o tipo de gráfico. Então aqui são apresentados os casos de Chikungunya por município em 2016.

Também podemos ver os de Zika, por exemplo em 2017, casos de Zika por município em 2017, botão do tipo de gráfico, ordenar os dados, e por último a visualização com o mapa.

Essa é a Arbovis, obrigada por assistir esse vídeo.

Slides da apresentação

Título: Arbovis: uma aplicação de visualização de dados sobre Arboviroses.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=18

Análise de sentimentos: identificando sentimentos em comentários da Rede Humaniza SUS

Eduardo Alves Silva[a] *e Luis Felipe Rosa de Oliveira*[b]

Resumo: A análise de sentimentos e áreas correlatas ao processamento de linguagem natural tem-se tornado cada vez mais comuns em diversos contextos, seja no empresarial ou acadêmico. Esse tipo de análise facilita a compreensão a respeito de opiniões e sentimentos de diferentes indivíduos em relação a determinado produto ou temática. Ao levar em consideração a crescente difusão das redes sociais e a interação entre usuários nessas redes, a captação de dados para análise de sentimento se tornou mais simples do que era anos atrás, onde frequentemente eram utilizados questionários ou formulários para captar a opinião de uma pessoa a respeito de algo. Com esse intuito e com a alta densidade de informação da rede humaniza SUS (RHS), a primeira rede social brasileira criada a partir de uma política pública, voltada para o tema da humanização da saúde. A rede humaniza SUS torna-se um ambiente de estudo promissor para análise de sentimentos, fazendo-se uso de uma abordagem não supervisionada que visa o uso de um dicionário ou léxico de sentimentos criado com palavras em Português, e com a possibilidade de aplicação utilizando a linguagem de programação python, para apresentar a classificação de sentimentos dos comentários feitos pelos usuários da rede.

Palavras-chave: Rede Humaniza SUS. Análise de Sentimentos. Léxico de Sentimentos. Processamento de Linguagem Natural.

Sentiment Analysis: identifying sentiment in comments on Humaniza SUS network

Abstract: The sentiment analysis and areas related to the natural language processing has become increasingly common in several contexts, be it business or academic. This type of analysis facilitates the understanding of the opinions and feelings of different individuals regarding a given product or thematic. By taking into account the growing diffusion of social networks and the interaction among users in these networks, capturing data for feeling analysis has become simpler than it was years ago, where questionnaires or forms were often used to capture a person's opinion about something. With this intention and with the high density of information of the humaniza SUS network (RHS), the first Brazilian social network created from a public policy, focused on the humanization of health. The humaniza SUS network becomes a promising study environment for analysis of feelings, making use of an unsupervised approach that aims to use a dictionary or sentiment lexicon created with words in Portuguese, and with the possibility of application using the programming language python, to present the classification of feelings of the comments made by the users of the network.

Keyword: Humaniza SUS Network. Sentiment Analysis. Sentiment Lexicon. Natural Language Processing.

a Universidade Nova de Lisboa (NOVAIMS). E-mail: easilva91@gmail.com
b Universidade Federal de Goías (UFGO). E-mail: luisprf@gmail.com. Currículo: http://lattes.cnpq.br/6498992926514286

1 Introdução

A crescente popularização das redes sociais, blogs e plataformas que incentivam a participação e colaboração de usuários, tornou-se comum permitindo o compartilhamento de mensagens que refletem suas opiniões e por vezes sentimentos a respeito de determinada temática ou produto.

Nesse sentido, a análise de sentimentos, ou mineração de opinião, corresponde ao problema de tentar identificar ou extrair emoções, opiniões ou pontos de vista expressados em um texto (DUARTE, 2013).

Liu (2012) menciona que esse tipo de análise está ligado a linguística e ao processamento de linguagem natural (PLN), gerando grande impacto nessa área do conhecimento, podendo ter grandes reflexos também em estudos sobre ciências políticas, economia, e ciências sociais, uma vez que são afetados pela opinião das pessoas.

O uso da análise de sentimentos é extenso, sendo usado para verificar o quanto um produto é bem aceito, de acordo com as opiniões de usuários, ou para compreender o sentimento gerado por uma publicação no Facebook, ou uma hashtag no Twitter. Essa variabilidade torna o uso da análise de sentimentos e opinião, um amplo campo de estudo.

Para a definição de sentimentos em um texto, normalmente é utilizado um léxico de sentimento, servindo como um dicionário de polaridade (FREITAS; VIEIRA, 2015), que agrega palavras que comumente expressam sentimentos positivos ou negativos (LIU, 2012). Atualmente os léxicos e modelos de análise de sentimento na língua inglesa são bastante comuns e assertivos em relação a análise de opinião e sentimento, no entanto, em Português são conhecidos quatro léxicos: OpLexicon, SentiLex, Brazilian Portuguese Linguistic Inquiry and Word Count (LIWC) e Onto.PT (FREITAS; VIEIRA, 2015).

O presente trabalho, tem por objetivo identificar os sentimentos expressados por comentários, fazendo uso do OpLexicon, da primeira rede social do Brasil criada no âmbito de uma política pública. Trata-se da rede humaniza SUS (RHS)1 que se encontra em atividade desde o ano de 2008, atualmente com mais de 30 mil usuários por todo o Brasil, onde muitos são responsáveis pelas mais de 14 mil publicações existentes na rede e os quase 40 mil comentários, existentes nessas publicações.

A rede humaniza SUS, traz consigo uma temática bastante específica, a humanização da saúde. Nesse sentido, foi verificado que tipo de sentimentos/opiniões os usuários da rede expressam a partir dos comentários, servindo também como um experimento para o uso de análise de sentimentos em Português.

2 Análise de Sentimentos

A análise de sentimento é, talvez, a aplicação mais popular da análise de texto, com um grande número de tutoriais, sites e aplicativos que se concentram em analisar o sentimento de vários recursos textuais, desde pesquisas corporativas até análises de crítica de filmes (SARKAR, 2016).

Em sua utilização a análise de sentimento tem uma série de fatores a serem considerados para que se consiga resultados que possam ser considerados coerentes, passando pela fase de pré-

processamento do texto, até o uso de abordagens para identificação de sentimentos, potencialmente utilizando métodos supervisionados que envolvem aprendizado de máquina e não supervisionados, que faz uso de bancos de dados, ontologias ou léxicos de sentimento.

Um dos principais objetivos da análise de sentimentos é analisar um determinado gênero de texto para compreender o que ele expressa. Nesse sentido alguns fatores devem ser considerados, como a polaridade do sentimento e sua subjetividade, de acordo com Sarkar (2016) a análise de sentimentos funciona melhor em textos que têm um contexto subjetivo (opiniões) do quem em textos objetivos (fatos).

Vale ressaltar que, a simples busca por palavras como "bom" ou "ruim" não é o suficiente para expressar o sentimento em um texto (DOSCIATTI; FERREIRA, 2013).

2.1 Léxico de Sentimento

Um léxico de sentimento pode ser um dicionário, vocabulário ou conjunto de palavras que tem uma polaridade positiva ou negativa atribuída (SARKAR, 2016). Para o presente trabalho foi utilizado um método não supervisionado. Sendo assim utilizado o léxico OpLexicon.

O OpLexicon é constituído de um total de 32.191 itens (24.475 adjetivos e 6.889 verbos, Tabela 1), tendo sua construção feita com base em textos jornalísticos e resenhas de filmes escritas em Português do Brasil, além do uso de tesauros e a tradução do léxico de opinião em inglês (SOUZA et al, 2012).

Tabela 1 – Quantidade de palavras por tipo OpLexicon.

Tipo	**Quantidade**
adjetivo (adj)	24.475
verbo (vb)	6.889
hashtag	471
vb (verbo) det (determinante) n (nome) prp (preposição)	103
vb (verbo) n (nome) prp (preposição)	91
vb (verbo) adj (adjetivo)	74
emoticons	66
vb (verbo) adv (advérbio)	22

Fonte: OpLexicon v3.0.

3 Procedimentos Metodológicos

O primeiro passo para se atingir o objetivo proposto foi captar os comentários da RHS em um recorte de 9 anos, a partir do banco de dados foram extraídos comentários de 2008 até o fim de 2017, o que gerou um total de 36.346 comentários.

Após essa etapa, foi iniciado o tratamento do texto dos comentários, utilizando a linguagem de programação python, juntamente com as etapas de sumarização e normalização de texto.

Segundo Sakar (2016) a normalização de texto é um processo de limpeza, normalização e padronização de dados com técnicas de remoção de símbolos e caracteres especiais, remoção de tags HTML (Hypertext Markup Language), remoção de stop words (preposições, pronomes,

artigos), correção de grafia, stemming (reduzir palavras ao seu radical) e lematização (reduzir a flexão das palavras).

Os itens de normalização utilizados neste trabalho foram:

1. Remoção de tags HTML.
2. Remoção de símbolos e caracteres especiais.
3. Remoção de palavras irrelevantes (Stopwords).
4. Lematização.

Uma vez que os comentários da RHS seguem um padrão de escrita compreensível e coerente, itens como a correção gráfica não se mostra de extrema importância nessa análise, por outro lado, os comentários têm inúmeras tags HTML que foram tratadas durante o processo (Apêndice A).

Por sua vez, seguindo as outras etapas da normalização, como a remoção de caracteres especiais que removem itens como (“”, ?, !, /, ;, :), e a remoção de palavras irrelevantes, que é feita a partir de um dicionário de artigos, preposições, pronomes (a, e, é, ali, uns), entre outros, com isso o texto passa a ser transformado novamente, como é demonstrado no Apêndice B.

Vale mencionar que as stopwords, podem seguir determinados padrões, nessa análise foi usado um padrão comum da língua portuguesa e foram adicionados alguns termos que se encontravam nos comentários e não agregavam valor para a análise final.

A lematização por sua vez, se trata do da remoção de afixos das palavras, fazendo com que essa palavra volte para sua base raiz (SARKAR, 2016), levando em consideração a parte do discurso em que a palavra se encontra, ou seja, caso a palavra se encontre na posição de verbo dentro de um texto, ela será lematizada de uma forma, caso seja um adjetivo será de outra forma e assim por diante.

Uma vez que para a lematização é necessário identificar a que parte do discurso a palavra pertence e após isso lematizar a palavra, é possível fazer o uso de diferentes bibliotecas e ferramentas do python para essa tarefa, neste trabalho foi utilizada a biblioteca Spacy2, que trabalha com uma variedade de idiomas incluindo o Português.

A lematização se faz importante pois, como demonstrado o léxico utilizado tem um número relevante de palavras que são representadas como parte do discurso, como adjetivos e verbos, conseguir lematizar o texto impacta no resultado final de identificação do sentimento de cada comentário.

Para identificar os sentimentos, foi utilizada uma abordagem similar ao utilizado para verificação de sentimentos com o léxico de opinião (HU;LIU, 2004), que se trata de um léxico com palavras positivas (1) e negativas (-1), entranto, o OpLexicon traz palavras neutras (0), ao adaptar o script da biblioteca NLTK3 que faz uso do léxico de opinião foi possível identificar o sentimento dos comentários.

De forma geral, o script acessa cada um dos comentários, separa as palavras, verifica se essa palavra se encontra no dicionário léxico e qual sua polaridade, após esse processo, é feita uma contagem e caso existam mais palavras positivas no comentário, o mesmo é considerado positivo e assim por diante.

4 Resultados

O trabalho com texto gera resultado diversos, que vão além da identificação de sentimentos, dessa forma foi feita uma verificação nos textos e palavras que geraram uma visão descritiva dos dados. Como por exemplo as palavras mais comuns encontradas nesses mais de 36 mil comentários (Apêndice C).

Além das palavras mais comuns é possível visualizar a interação em relação ao número de palavras utilizadas nos comentários e qual seria a média padrão de palavras.

De forma geral, foram encontrados mais de 25 mil comentários que foram classificados como positivos, 4,594 negativos e em torno de 4.692 comentários considerados neutros.

Faz-se importante ressaltar que o resultado final não apresenta indicadores de um modelo de aprendizado de máquina como, accuracy, f1-score, entre outros pelo fato de todo o trabalho ter sido desenvolvido em volta de um léxico de sentimento, o que foi feito em si representa a identificação de sentimentos nos comentários de acordo com palavras que estão presentes no léxico de sentimento, não sua classificação, a partir desse trabalho o treino de um classificador de sentimentos se dá em uma etapa posterior.

5 Considerações Finais

O estudo de identificação de sentimentos nos comentários da rede humaniza SUS, apresenta um resultado que demonstra estar de acordo com aquilo que a rede se propõe, que seria a colaboração entre os usuários em torno de uma temática específica.

Identificar sentimentos positivos em sua grande maioria pode ser visto como um incentivo para que o trabalho de desenvolvimento da rede tenha continuidade, foi possível perceber durante o estudo que o teor dos comentários em sua maioria, são de mensagens de agradecimento, por divulgação de encontros ou iniciativas relacionadas a humanização da saúde no Brasil, gerando um assim um ambiente de aprendizado e gratidão por todos aqueles que estão envolvidos nesse processo.

Os resultados obtidos em relação a esse estudo demonstram uma abordagem inicial em relação a tudo aquilo que pode ser produzido a partir do uso da análise de sentimentos e processamento de linguagem natural. A rede humaniza sus é um ambiente próspero para a possível criação de um léxico de sentimento relacionado a saúde e a humanização da saúde.

Essa mesma abordagem gera caminhos para que, a partir dos resultados desse estudo, seja criado um classificador de sentimentos utilizando métodos supervisionados e aprendizado de máquina, o que daria um contexto mais abrangente para os resultados, bem como para o uso dos dados da RHS.

Por fim, este trabalho agrega um valor experimental para o desenvolvimento de análises de sentimento utilizando o Português brasileiro, com ênfase em um método não supervisionado e com a possibilidade de construção de dados para sua posterior aplicação em algoritmos e classificadores de aprendizagem de máquina.

Referências

DOSCIATTI, M. M.; FERREIRA, E. C. L. P. C. Identificando emoções em textos em português do Brasil usando máquina de vetores de suporte em solução multiclasse.In: **ENIAC-Encontro Nacional de Inteligência Artificial e Computacional.** Fortaleza, Brasil, 2013.

DUARTE, E. S. **Sentiment analysis on twitter for the portuguese language.** Tese (Doutorado) — Faculdade de Ciências e Tecnologia, 2013.

FREITAS, L. d; VIEIRA, R. Exploring resources for sentiment analysis in portuguese language. In: IEEE. In: 2015 **Brazilian Conference on Intelligent Systems**. BRACIS. [S.l.], 2015. p. 152–156.

HU, M; LIU, B. Mining and summarizing customer reviews. **Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery & Data Mining**, Seattle, Washington, p.168-177, 2004

LIU, B. **Sentiment Analysis and Opinion Mining: Synthesis Lectures on Human Language Technologies. Morgan & Claypool Publishers, 180p., 2012.**

SARKAR, D. **Text Analytics with Python**: **A Practical Real-World Approach to Gaining Actionable Insights from Your Data**. Library of Congress Control Number, Apress, 385p., 2016.

SOUZA, M.; VIEIRA, R.; BUSETTI, D.; CHISHMAN, R. e ALVES, I. M. Construction of a Portuguese Opinion Lexicon from multiple resources. In: **8th Brazilian Symposium in Information and Human Language Technology**, 2012.

Apêndice A – Exemplo de remoção de tags HTML.

```
<P>Excelente post, Mariella!<P>
<P>Acho que você e o Bruno poderão e deverão ter um papel
fundamental nesta Rede, orientando-nos em relação a como
redigir um post<P>
<P>Precisaremos, certamente, de um "manual de redação"!</P>
<P>Um abraço,</P>
<P>Ricardo<BR></P>

Excelente post, Mariella! Acho que você e o Bruno poderão e deverão
ter um papel fundamental nesta Rede, orientando-nos em relação a
como redigir um post. Precisaremos, certamente, de um "manual de redação"!
Um abraço, Ricardo
```

Fonte: Dados da pesquisa, 2018.

Apêndice B – Exemplo de remoção de símbolos e caracteres especiais e stopwords.

```
excelente post mariella acho bruno poderão deverão
papel fundamental rede orientando-nos redigir post
precisaremos certamente manual redação abraço ricardo
```

Fonte: Dados da pesquisa, 2018.

Apêndice C – 30 palavras mais comuns nos comentários.

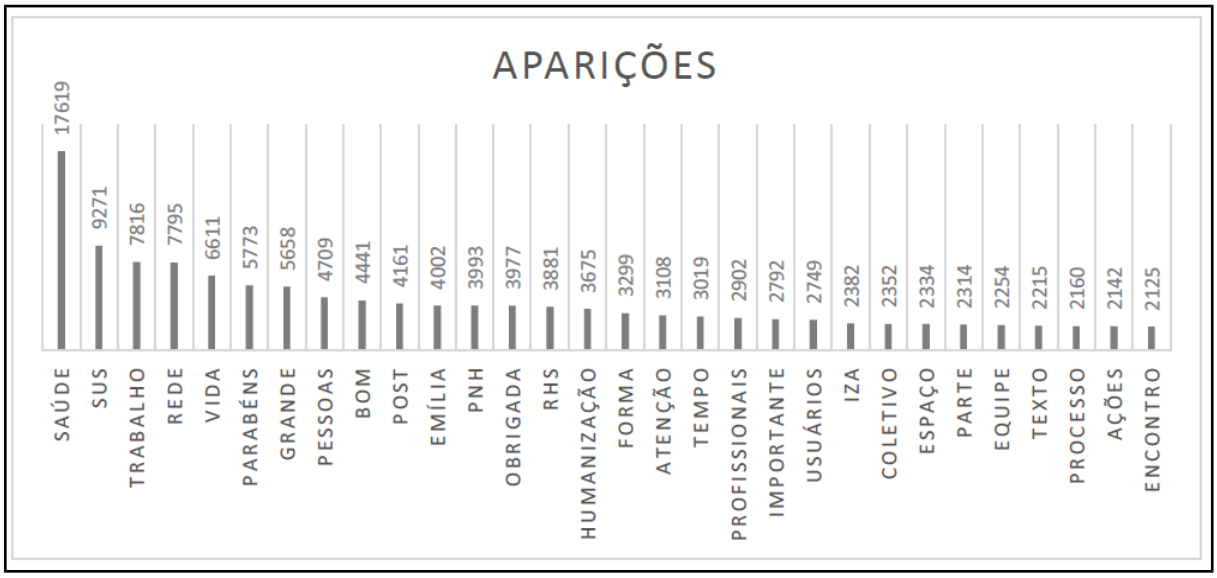

Fonte: Dados da pesquisa, 2018.

Vídeo da apresentação

Título: Análise de sentimentos: Identificando sentimentos em comentários da Rede Humaniza SUS.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=19

Transcrição da apresentação

O meu é Eduardo esse vídeo é uma apresentação sobre o trabalho que foi enviado para o Workshop de Informação, Dados e Tecnologia, que ocorre na Universidade da Paraíba entre os dias 27/11 e 29/11 de 2018.

O trabalho em questão tem o nome de ANÁLISE DE SENTIMENTOS: Identificando sentimentos em comentários da Rede Humaniza SUS o trabalho foi produzido por mim Eduardo Silva e pelo meu colega Luiz Felipe Rosa.

O trabalho em questão tem como objetivo identificar sentimentos nos comentários da rede humaniza sus é uma rede social que têm atividade desde o ano de 2008 permeia assuntos relacionados ao sistema único de saúde brasileiro, ou seja, o SUS.

Atualmente a rede tem cerca de 30 mil usuários 14 mil publicações e em torno de 35 mil a 40 mil comentários. Para análises de sentimentos da rede dos comentários da rede nós fizemos o uso de mineração de dados ou mineração de texto nesse caso aplicando alguns conceitos de processamento de linguagem natural tudo utilizando a linguagem de programação python os dados foram coletados utilizando um banco de dados da rede após a coleta dos dados nós passamos a um tratamento desses dados usando algumas metodologias de análise de texto e processamento de linguagem natural.

O texto em si vinha com linha com uma sujeira, ou seja, nesse contexto a sujeira são, por exemplo, caracteres assim que não foram bem identificados como a "Ç", o "ÃO" entre outros caracteres.

Para além disso alguns comentários vinham com tags HTML, ou seja, apresentava as tags de parágrafos quebra de linha entre outros utilizando a linguagem de programação python fizemos limpeza desses dados e a sua normalização, ou seja, os dados passaram a ser normalizados sem sujeira todos os comentários com letras minúsculas.

Para identificação de sentimentos ou em alguns casos a sua classificação que não é bem esse caso podemos utilizar o aprendizado de máquina ou um léxico de sentimento uma vez que o intuito do trabalho para identificação e não a classificação nós utilizamos um léxico sentimento, o léxico é um com um dicionário com um conjunto de palavras ou textos que tenha atribuído a essas palavras uma polaridade essa popularidade pode ser positiva negativa ou neutra no caso do estudo nós utilizamos um léxico de sentimento chamado o OpLéxicon que é produzido pela PUC-RS baseado em texto jornalístico e em algumas outras fontes que eles utilizaram para produzir.

O OpLéxicon contém cerca de 32191 itens, ou seja, 32191 palavras dentre elas temos 24485 objetivos e 6889 verbos.

Nesse caso é preponderante o número de adjetivos e verbos uma vez que na língua portuguesa para definir um sentimento normalmente são esses dois tipos de palavras que são utilizados mas o léxico ainda tem hashtags determinantes preposições adjetivos e emoticons para dar segmento à metodologia o que fizemos foi a parte do léxico do sentimento criar uma metodologia de comparação das palavras que existe no comentário e que aparece no léxico, ou seja, se uma sentença tem 20 palavras e 10 das palavras aparecem no léxico de sentimento nós iremos armazenar os valores da polaridade dessas palavras e se encontram tanto no léxico quanto

no comentário em questão a partir disso nós usamos uma metodologia de verificação e cálculo para definir quais os sentimentos aquele comentário que apresenta para tal nós tivemos como base os estudos feitos por autores que criaram um léxico de opinião o único de mineração de opinião da língua inglesa a partir do código que faz o uso desse léxico, nós fizemos uma adaptação com o léxicon a partir disso conseguimos verificar quais eram as popularidades das palavras e assim sendo vai ficar com a popularidade do comentário, ou seja, se o comentário era positivo negativo ou neutro de acordo com o número de palavras positivas negativas ou neutras que apareciam nesse comentário.

Feito isso nós replicamos esse processo para todos os quase 40 mil comentários gerando assim a identificação de sentimentos de cada um deles.

A partir da identificação da popularidade nós podemos perceber que existe uma quantidade maior de comentários positivos e neutros do que negativos.

Talvez isso ocorra por conta do tipo de rede social ao qual estamos lidando é uma rede um pouco mais controlada e focado em um tema específico então as pessoas nos comentários tendem a ser mais assertivas em termos de não dar comentários negativos mas sim comentários positivos de apoio ou então mensagens mais simples como bom dia gostei muito da postagem da publicação e comentários nessa linha

Dessa forma o resultado final que nós tivemos além da popularidade dos sentimentos a verificação das palavras mais comumente utilizadas em todos os comentários sendo que a palavra saúde como esperado parece em sua maioria assim como SUS entre outras relacionadas a esse contexto da saúde.

Foi possível também averiguar algumas questões mais minuciosos que se tratam de uma análise um tanto quanto descritiva como, por exemplo, qual a frequência de comentários por mês por ano e assim por diante. Mas o resultado final a que nos interessava e que foi alcançado era definir ou identificar os possíveis sentimentos de cada um dos comentários pode se dizer que de certa forma nós estamos criando um dataset que posteriormente pode ser utilizado para classificar novos comentários então é importante ressaltar que o trabalho não se trata da classificação utilizando aprendizado de máquina mas sim da identificação utilizando um léxico a partir desse ponto é possível fazer uma comparação com outros léxicos de sentimento da língua portuguesa para verificar quais deles têm uma taxa de acerto maior em relação à identificação de sentimentos, no entanto, uma vez que foi feito uso apenas do OpLéxico.

Nós tivemos como resultado final somente esses dados de identificação do sentimento agradeço a atenção daqueles que ler um artigo ou que estão apenas vendo o vídeo de apresentação muito obrigado e até mais.

Análise da relação entre perfil e desempenho acadêmico dos alunos matriculados na disciplina de Introdução à Programação utilizando algoritmos de classificação

Roberto Silva de Oliveira Júnior[a], Douglas Valentim de Almeida Cardins[b], Wenddell Juler Pereira de Lima[c], Thereza Patrícia Pereira Padilha[d] e Vanessa Farias Dantas[e]

Resumo: Ao ingressar na Universidade, a maioria dos alunos enfrenta dificuldades no aprendizado dos conteúdos da disciplina de Introdução à Programação, primeiro componente curricular de programação nos cursos de Computação e Informática. Muitos alunos terminam evadindo ou reprovando vários semestres nesta disciplina e, assim, comprometem a conclusão de seus cursos. Sabe-se, com base em estudo da literatura, que isso se deve principalmente a aspectos como falta de motivação dos alunos, deficiências do ensino médio e dificuldades com raciocínio lógico e conceitos abstratos. Entretanto, outros fatores podem interferir nos resultados dos discentes. Diante disso, o presente artigo tem como proposta utilizar algoritmos de classificação, disponíveis na ferramenta Weka, para investigar se existe relação entre o perfil (social, acadêmico e econômico) dos alunos e o seu desempenho acadêmico nessa disciplina, com o objetivo de guiar as ações da coordenação do curso e do corpo docente no combate à evasão e à reprovação. Para isso, foram testados dados coletados de um curso de Licenciatura em Ciência da Computação da Universidade Federal da Paraíba. Foram encontradas regras que classificam os alunos em aprovado ou reprovado. Assim, foi constatado que alunos com gasto elevado com transporte, sem conhecimento prévio de computação e idade maior ou igual a 19 anos são propensos a reprovação, já os que não trabalham e têm idade menor ou igual a 18 anos e têm conhecimento prévio de computação são mais propensos a aprovação na disciplina.

Palavras-chave: Programação. Evasão. Reprovação. Mineração de dados.

Analysis of the relationship between profile and academic performance of students enrolled in the Programming Introduction course using classification algorithms

Abstract: Upon entering the University, most of the students show difficulties to learn contents of the Introduction to Programming course, first programming course in the Computer Science Degree. Many students dropped off or failed several semesters in this course and, thus delayed their degrees. In the literature, several studies show that the main factors are: lack of motivation of the students, deficiencies of high school and difficulties with logical reasoning and abstract concepts. However, other factors may interfere with student outcomes. The present paper shows the use of classification algorithms, available in the Weka tool, to investigate if there is a relationship between the students (social, academic and economic) profile and their academic performance in this course, in order to guide actions of the course coordination and faculty to minimize evasion and retention. So, data were collected of a Computer

a Universidade Federal da Paraíba (UFPB). E-mail: roberto.silva@dce.ufpb.br. Currículo: http://lattes.cnpq.br/5095958238014357
b Universidade Federal da Paraíba (UFPB). E-mail: douglas.valentim@dce.ufpb.br. Currículo: http://lattes.cnpq.br/0509156062041263
c Universidade Federal da Paraíba (UFPB). E-mail: wenddell.juler@dce.ufpb.br. Currículo: http://lattes.cnpq.br/2195755521034980
d Universidade Federal da Paraíba (UFPB). E-mail: thereza@dce.ufpb.br. Currículo: http://lattes.cnpq.br/2084409307725504
e Universidade Federal da Paraíba (UFPB). E-mail: vanessa@dce.ufpb.br. Currículo: http://lattes.cnpq.br/5196069557142312

Science course from Federal University of Paraiba. Rules were found that classify students as sucess or fail. So, students with high transportation costs, no prior knowledge of computing and age greater than or equal to 19 years possibly will be to fail, and students that do not work and are less than or equal to 18 years old and have previous knowledge of computation are predisposed for sucess in the course.

Keyword: Programming. Evasion. Retention. Data mining.

1 Introdução

Uma preocupação nas Instituições de Ensino Superior (IES) no Brasil e no mundo é a evasão universitária, definida como a saída do aluno de seu curso, sem concluí-lo. Sabe-se, ainda, que os índices de evasão são maiores nos primeiros períodos dos cursos (Bardagi e Hutz, 2009). No caso dos cursos da área de Computação e Engenharia, outra preocupação é o alto índice de retenção em disciplinas de programação. Nos últimos anos, pesquisadores têm concentrado estudos na busca de encontrar respostas para estes problemas analisando dados acadêmicos, sociais e econômicos (Silva, 2013; Araújo et al., 2011; Campello e Lins, 2008).

Segundo Fagundes et al. (2014), o desempenho acadêmico constitui também um potente indicador de qualidade dos cursos de uma instituição, ou seja, sinaliza se os objetivos estão sendo alcançados. Portanto, entende-se que há uma grande pertinência na realização de estudos sobre desempenho acadêmico no curso de Licenciatura em Ciência da Computação (LCC) da Universidade Federal da Paraíba, a fim de estabelecer ações para aumentar/manter a sua qualidade que, atualmente, possui conceito máximo (5) atribuído pelo Ministério da Educação.

O aumento da disponibilidade dos dados dos alunos e o interesse de pesquisadores das áreas de Mineração de Dados e Informática na Educação, principalmente, fizeram surgir uma nova área de pesquisa conhecida como Mineração de Dados Educacionais (MDE). MDE visa explorar dados do ambiente educacional para descobrir padrões (isto é, conhecimento oculto/escondido nos dados) para contribuir no entendimento do processo de aprendizagem e, assim, auxiliar as tomadas de decisão sobre novas práticas pedagógicas (Baker, 2010). Embora MDE ainda seja pouco explorada no Brasil, esta é vista como promissora na compreensão de problemas na área da Educação (Gottardo et al., 2013).

2 Objetivos

Este artigo tem como objetivo geral investigar uma relação entre o perfil (social, cultural, acadêmico e econômico) dos alunos e o seu desempenho acadêmico na disciplina de Introdução à Programação, do curso de Licenciatura em Ciência da Computação, a fim de minimizar os altos índices de evasão e de reprovação.

Em termos de objetivos específicos, tem-se:

- Categorizar, em um nível maior de detalhes, o perfil dos alunos ingressantes no curso de Licenciatura em Ciência da Computação da Universidade Federal da Paraíba;
- Realizar experimentos com o conjunto de dados construído (perfil, econômico e acadêmico) utilizando três algoritmos de classificação;
- Identificar variáveis que influenciam os alunos no sucesso e insucesso da disciplina de Introdução à Programação (retenção e evasão);
- Apresentar aos gestores acadêmicos e ao professor da disciplina os resultados da pesquisa.

3 Procedimentos metodológicos

No meio do semestre letivo 2017.1, foi aplicado um formulário web para 42 alunos matriculados na disciplina de IP com 19 perguntas objetivas envolvendo aspectos pessoais (Q1 a

Q6), econômicos (Q10 a Q12) e acadêmicos (Q13 a Q19). Uma identificação sobre o conteúdo de cada pergunta é apresentada a seguir:

- Q1 – gênero;
- Q2 – idade;
- Q3 – estado civil;
- Q4 – possui filhos;
- Q5 – possui computador;
- Q6 – possui internet em casa;
- Q7 – cidade de origem;
- Q8 – moram na cidade em que estudam;
- Q9 – gastos mensais com transportes;
- Q10 – trabalha;
- Q11 – recebe ajuda de custos;
- Q12 – horas semanais de trabalho;
- Q13 – tipo de escola frequentada no ensino médio;
- Q14 – cursou a disciplina de IP antes de entrar no curso;
- Q15 – motivo pelo qual desistiu ou reprovou anteriormente na disciplina;
- Q16 – conhecimento da língua inglesa;
- Q17 – conhecimento de computação antes de entrar no curso;
- Q18 – conhecimento do perfil do curso de LCC;
- Q19 – LCC foi a primeira opção no Enem.

Todas as perguntas do formulário fizeram parte do conjunto de dados obtido como atributos. Ao fim do semestre, foi disponibilizada a situação final dos alunos (aprovado ou reprovado), que foi adicionado ao conjunto de dados como atributo-classe (rótulo). Dos 42 registros, 34 eram da classe aprovado e 8 reprovado. Em seguida, os dados foram transformados e disponibilizados no formatado .arff, formato padrão de entrada para a ferramenta Weka.

Por fim, os dados foram aplicados aos algoritmos de classificação OneR, PART e JRip, disponíveis na ferramenta Weka, e que têm como saída um conjunto de regras.

4 Resultados

Nesta seção serão apresentados os resultados obtidos utilizando os algoritmos OneR, PART e JRip.

4.1 OneR

A Figura 1 apresenta as quatro regras geradas pelo algoritmo OneR. Neste caso, somente o atributo gastoComTransporte foi usado para separar as classes "aprovado" e "reprovado". Onde classificou trinta e cinco instâncias corretamente (83.3%) e sete incorretamente (16.6%).

Observa-se que alunos com gasto elevado com transporte têm sido classificado como reprovado. Analisando o conjunto de dados, verifica-se que esses alunos moram em outras cidades e, até mesmo, em outros estados, e, assim, precisam se deslocar para as suas cidades diariamente. Sabe-se que este deslocamento no cotidiano acarreta em cansaço e falta de tempo para estudos e, consequentemente, influencia no desempenho das disciplinas cursadas.

Figura 1: Resultado Obtido pelo Algoritmo OneR.

```
=== Classifier model (full training set) ===

gastoComTransporte:
        Alto    -> Reprovado
        Baixo   -> Aprovado
        Medio   -> Aprovado
        Zero    -> Aprovado
(35/42 instances correct)
```

Fonte: Autores.

4.2 PART

A Figura 2 apresenta as quatro regras geradas pelo algoritmo PART. Neste caso, o algoritmo classificou 36 instâncias corretamente (85.7%) e 6 incorretamente (14.3%).

Figura 2: Resultado Obtido pelo Algoritmo PART.

```
PART decision list
------------------

trabalha = Nao AND
idade <= 18: Aprovado (20.0)

conhecimentoPrevioDeComputacao = Sim: Aprovado (13.0/2.0)

trabalha = Nao AND
conhecimentoPrevioDoCurso = Sim: Aprovado (5.0/2.0)

: Reprovado (4.0)

Number of Rules  :      4
```

Fonte: Autores.

Foram determinadas três regras para classificar os alunos como aprovados. De modo geral, o perfil dos alunos aprovados são: 1) não trabalham e possuem idade menor ou igual a 18; 2) tem conhecimento prévio sobre computação; e 3) não trabalham e tem conhecimento prévio do curso que ingressaram. Caso não esteja dentro de um desses perfis, o algoritmo determina a classe como reprovado.

4.3 JRip

Na Figura 3 podem ser observadas as duas regras extraídas pelo algoritmo JRip. Este algoritmo classificou 35 instâncias corretamente (83.3%) e 7 incorretamente (16.7%).

Figura 3: Resultado Obtido pelo Algoritmo Jrip.

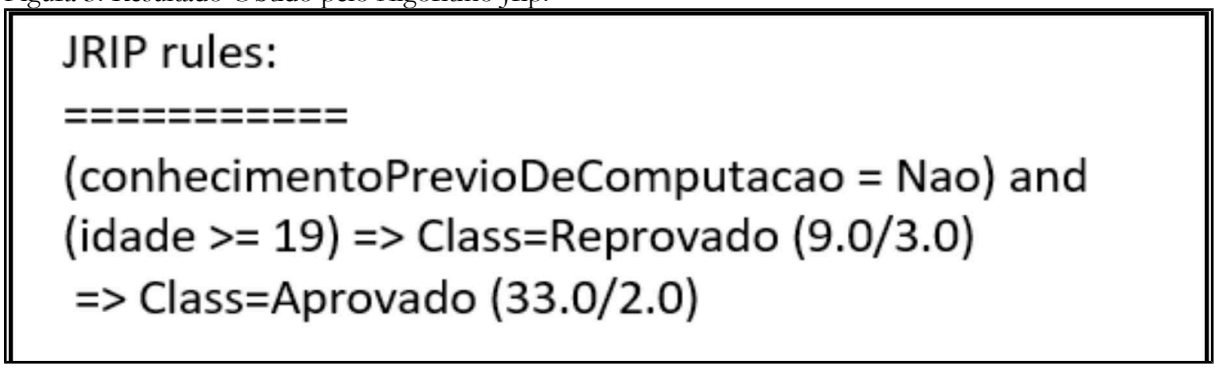

Fonte: Autores.

Neste caso, basicamente, alunos são classificados como reprovados, aqueles que não possuem conhecimento prévio de computação e com idade maior ou igual a 19. A partir dos resultados obtidos com a ferramenta de mineração de dados Weka, pôde-se encontrar fatores que influenciam a reprovação e a aprovação de alunos matriculados em IP. De modo geral, gasto elevado com transporte, não conhecimento prévio de computação e idade maior ou igual a 19 anos podem levar a uma reprovação. Por outro lado, não trabalhar e ter idade menor ou igual a 18 anos, ter conhecimento prévio de computação são fatores que contribuem para uma aprovação na disciplina.

5 Considerações Finais

O crescente número de reprovações e evasões na disciplina de Introdução à Programação é alarmante e cabível de medidas que visem cessar tal crescimento. Dessa forma, foi primordial a captação de dados, a averiguação e o estudo deles para se obter respostas sobre os casos. Assim, a aplicação de Mineração de Dados apresentou-se como alternativa para obtenção de informações pertinentes.

Embora o conjunto de dados aplicado tenha sido restrito, principalmente, no que diz respeito à quantidade de registros de alunos reprovados, foi possível ter um modelo de perfil de alunos que perdem a disciplina de IP. Neste experimento não houve a presença de nenhum registro de aluno como evadido. Apesar de ter tido casos de alunos nesta situação durante o período avaliado, não foi possível obter seus dados pessoais, econômicos e acadêmicos destes alunos porque a coleta aconteceu no meio do semestre e os alunos já tinham desistido da disciplina. Portanto, para evitar estas perdas de dados, recomenda-se coletar os dados dos alunos até a segunda semana após o início das aulas.

Referências

ARAÚJO, E. A. T; CAMARGOS, M. A.; CAMARGOS, M. C. S. Desempenho Acadêmico de Discentes do Curso de Ciências Contábeis: uma Análise dos seus Fatores Determinantes em Uma IES Privada. **XXXV Encontro da Associação Nacional de Pós-graduação e Pesquisa em Administração**. Rio de Janeiro – RJ, Brasil, 2011.

BAKER, R. S. J. Data mining for education. **International Encyclopedia of Education**, v. 7, n. 3, p. 112 – 118, 2010.

BARDAGI, M. P.; HUTZ, C. S. **Não havia outra saída": percepções de alunos evadidos sobre o abandono do curso superior**. Psico-USF (Impr.) vol.14 no.1 Itatiba Jan./ Apr. 2009.

BARROSO, M. F; FALCÃO, E. B. M. **Evasão Universitária: O Caso do Instituto de Física da UFRJ**, IX Encontro Nacional de Pesquisa em Ensino de Física. Rio de Janeiro, 2004.

BRANCO NETO, W. C.; SCHUVARTZ, A. A. Ferramenta Computacional de Apoio ao Processo de Ensino-Aprendizagem dos Fundamentos de Programação de Computadores. **18º Simpósio Brasileiro de Informática na Educação**. São Paulo, Brasil. 2007.

CAMPELLO, A. V. C.; LINS, L. N. Metodologia de Análise e Tratamento da Evasão e Retenção em Cursos de Graduação de Instituições Federais de Ensino Superior. **XXVIII Encontro Nacional de Engenharia de Produção**. Rio de Janeiro, RJ, Brasil, 2008.

DIAS, A. F. M.; CERQUEIRA, G. S.; LINS, L. N. Fatores Determinantes da Retenção Estudantil em um Curso de Graduação em Engenharia de Produção. **COBENGE 2009 – XXXVII Congresso Brasileiro de Ensino de Engenharia**. Recife – PE, 2009.

FAGUNDES, C. V.; LUCE, M. B.; ESPINAR, S. R. O desempenho acadêmico como indicador de qualidade da transição Ensino Médio-Educação Superior. **Ensaio: aval. pol. públ. Educ.**, Rio de Janeiro, v.22, n. 84, p. 635-670, jul./set. 2014.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From Data Mining to Knowledge Discovery: an overview. **Advances in Knowledge Discovery and Data Mining**, AAAI Press / The MIT Press, MIT, Cambridge, Massachusetts, and London, England, p.1-34, 1996.

GOTTARDO, E.; KAESTNER, C.; NORONHA, R. V. **Aplicação de Técnicas de Mineração de Dados para Estimativa de Desempenho Acadêmico de Estudantes em um AVA Utilizando Dados com Classes Desbalanceadas**. ICBL2013 – International Conference on Interactive Computer aided Blended Learning, p. 24-28, Florianópolis-SC, Brasil, 2013.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. **The weka data mining software: an update**. SIGKDD Explor. Newsl., ACM, New York, NY, USA, v. 11, n. 1, p. 10–18, nov 2009. ISSN 1931-0145.

LODER, L. L., NAKAO, O. S. **Evasão e Retenção em Cursos de Engenharia**. Sessão Dirigida. XXXIX Congresso Brasileiro de Educação em Engenharia (COBENGE 2011). Blumenau – SC, 2011.

MARQUES, A. F. **Aplicação de clusterização de dados na base de dados do saneamento ecológico e econômico de Minas Gerais. 88p. Monografia (Bacharelado em Sistemas da Informação) – Universidade Federal de Lavras, Lavras/MG, 2014.**

SCHULTZ, M. R. O., **Metodologias para Ensino de Lógica de Programação de Computadores**. Monografia de Especialização (Ciência da Computação). Universidade Federal de Santa Catarina (UFSC). 69p. Florianópolis, SC, Brasil. 2003.

SILVA, R. F. **Fatores que Influenciam o Desempenho Acadêmico.** Dissertação de Mestrado (Economia). Instituto de Ensino e Pesquisa (Insper). 42p. São Paulo, SP, Brasil, 2013.

SILVA FILHO, R. L. L; MONTEJUNAS, P. R., HIPÓLITO, O.; LOBO, M. B. C. M. **A evasão no ensino superior brasileiro**. Caderno de Pesquisa, v. 37, n.132, p. 641-659. São Paulo/SP. 2007.

SOARES, I. S. **UFRJ – Escola Politécnica – Vestibular 1993-2009 – Revisão Histórica – Vagas, Evasão e Retenção**. In: COBENGE 2009 – XXXVII Congresso Brasileiro de Educação em Engenharia. Recife, PE, 2009.

Vídeo da apresentação

Título: Análise da relação entre perfil e desempenho acadêmico dos alunos matriculados na disciplina de Introdução à Programação utilizando algoritmos de classificação.

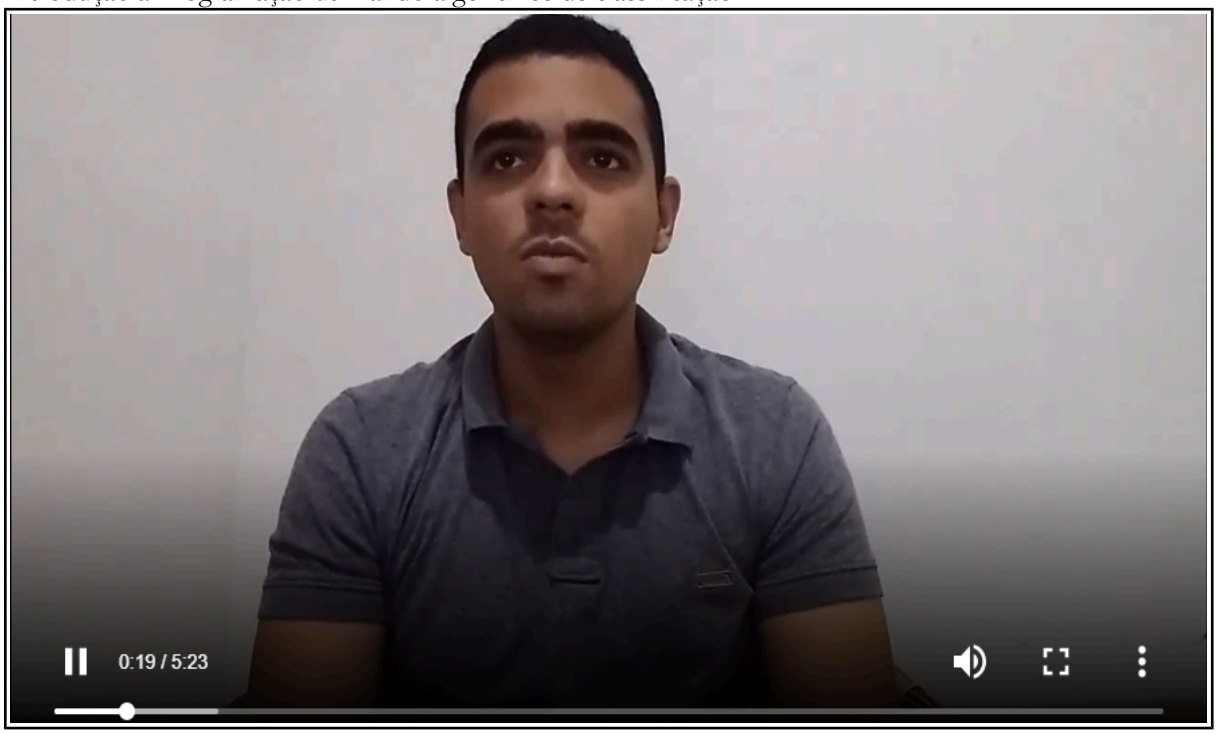

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=20

Transcrição da apresentação

Este ano será realizado entre os dias 27 e 29 de novembro na cidade de João Pessoa na Paraíba no auditório de superintendência de tecnologia da informação da Universidade Federal da Paraíba.

O título do trabalho submetido é "Análise da relação entre perfil e desempenho acadêmico dos alunos matriculados na Disciplina de Introdução à Programação utilizando algoritmos de classificação desempenho acadêmico dos alunos matriculados".

Os atores envolvidos são eu Roberto Silva Oliveira, Douglas Valentim de Almeida Cardins, Wenddell Juler Pereira de Lima, Thereza Patrícia Pereira Padilha, Vanessa Farias Dantase.

Uma preocupação do ensino superior do mundo é o índice de evasão são maiores nos primeiros períodos dos cursos. Nos casos dos cursos de computação e engenharia uma preocupação é a falta de atenção nas disciplinas de programação.

Nos últimos anos pesquisadores têm concentrado os estudos na bolsa de encontrar respostas para esses problemas analisando dados acadêmicos sociais e econômicos. O aumento da disponibilidade dos dados dos alunos no interesse dos pesquisadores na área de mineração de dados informática na educação faz surgir uma nova área de pesquisa conhecida como mineração de dados educacionais, visa explorar dados do ambiente educacional para descobrir padrões, isto é conhecimento oculto escolhido nos dá para contribuir no entendimento do processo de aprendizagem e assim acelerar a tomada de decisão sobre novas práticas pedagógicas.

Este artigo tem como objetivo geral investigar uma relação que o perfil social cultural acadêmico e econômico dos alunos em seu desempenho acadêmico na disciplina de introdução a programação a fim de minimizar os altos índices de evasão de reprovação na disciplina.

No meio do semestre letivo de 2017.1 foi aplicado formulário web para 42 alunos matriculados na disciplina de IP com 19 perguntas objetivas envolvendo aspectos pessoais econômicos e acadêmicos todas as perguntas do formulário fizeram parte do conjunto de dados obtidos como atributo ao fim do semestre foi disponibilizado a situação final dos alunos aprovados e reprovado que foi adicionado ao conjunto de dados como atributo clássico hotton.

Dos 42 registros, 34 eram da classe aprovado, 08 reprovado, em seguida os dados foram transformados e disponibilizados em formato .ARFF formato padrão da entrada para ferramenta WEKA.

Por fim os dados foram aplicados aos algoritmos de classificação OneR, PART e JRip, disponíveis na ferramenta WEKA e tem como sair do conjunto de regras resultados no OneR neste caso somente um atributo gasto no transporte foi usado para separar a classe aprovados e reprovados, onde classificou 33 instâncias aproximadamente, 78 pontos 6% e 9 incorretamente 21.4%. O alto gasto com transporte é uma possibilidade de reprovar na disciplina.

Resultados com algoritmos PART classificou 36 instâncias corretamente aproximadamente 85.7% e seis incorretamente 14,3%.

As regras geradas pelo algoritmo PART falavam que os alunos que não trabalha que tem idade menor de 18 anos tem grande possibilidade de ser aprovado, os que já tinha conhecimento prévio do curso tem maior possibilidade de sre aprovado, os que não trabalham e têm conhecimento prévio do curso tem possibilidade de ser aprovado.

Resultado dos algoritmos JRip classificou 35 instâncias corretamente aproximadamente 83,3% e 7 incorretamente 16,7%.

A regra gerada pelo algoritmo JRip falava que os alunos que não têm conhecimento prévio de computação e tem idade maior que 19 tem maior possibilidade de ser reprovado na disciplina de introdução à programação.

Considerações finais o crescente índice de reprovações na educação na disciplina de introdução a programação é alarmante e cabíveis de medidas que visem o seu crescimento.

Logo foi primordial a captação de dados e averiguação e o estudo com a aplicação de mineração de dados apresentou-se como alternativa para a obtenção de informações pertinentes embora conjunto de dados aplicado tenha sido restrito principalmente no que diz respeito à quantidade registro dos alunos reprovados, foi possível ter um modelo do perfil de alunos que perdem a disciplina de IP mesmo com esses empecilhos na descrição do vídeo vocês podem entrar em contato conosco pois deixaremos nossos e-mails.

Slides da apresentação

Título: Análise da relação entre perfil e desempenho acadêmico dos alunos matriculados na disciplina de Introdução à Programação utilizando algoritmos de classificação.

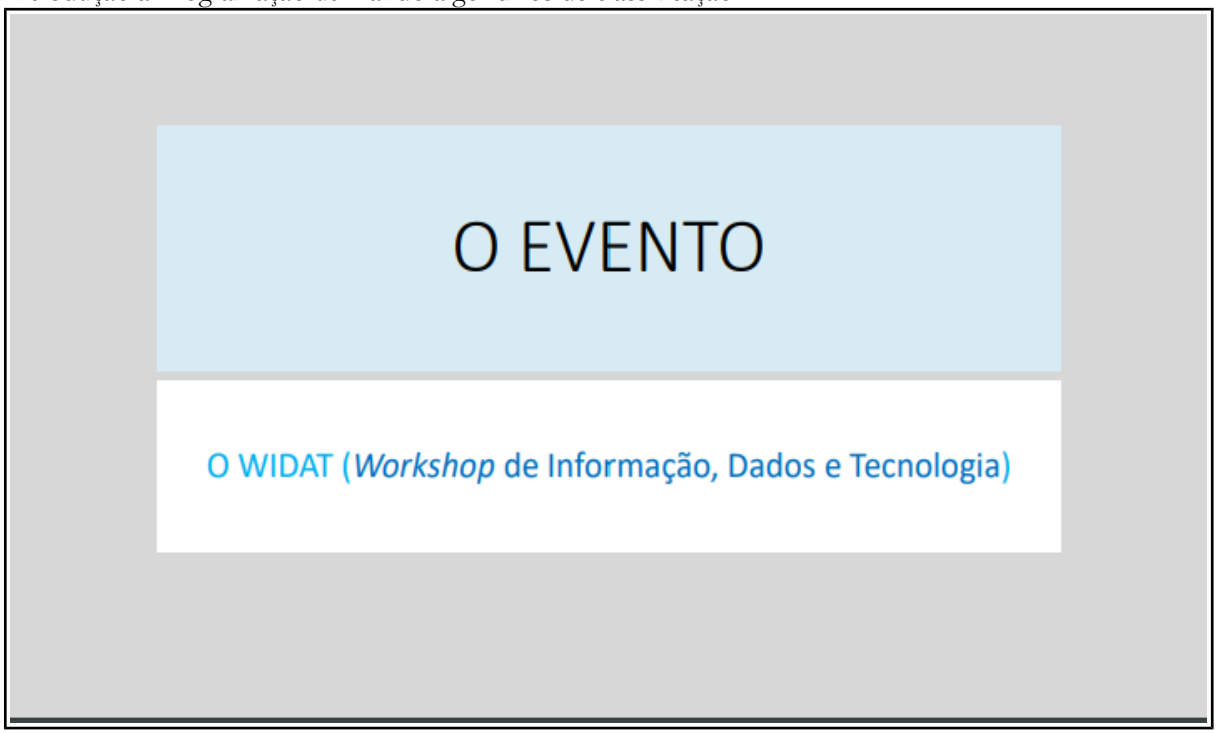

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=20

A Ciência de Dados à luz da ciência do senso comum Aristotélico: uma análise comparativa com a tecnologia sensorial

Marcello Mundim Rodrigues[a] *e Tereza Cristina Fernees*[b]

Resumo: Compara a percepção da compreensão aristotélica aplicáveis à Ciência de Dados, com objetivo de buscar uma fundamentação teórica filosófica a esta disciplina emergente. Apoia-se em duas metodologias: (a) a revisão bibliográfica – nas contribuições dos estudos críticos pertinentes à filosofia aristotélica da experimentação do senso comum e; (b) na análise de conteúdo – pela capacidade de inferência e dedução da compreensão. Argumenta-se a partir da análise dos três níveis de pensamento observado por Aristóteles, sob os seguintes aspectos: (1) os sentidos e as sensações são os dados que a mente recebe; (2) as ideias são os dados que a mente produz e; (3) o pensamento produz conhecimento relacionando as ideias, juntando-as, separando-as e confrontando-as, formado pela capacidade de cognição em busca da razão. Como resultado comparativo, encontra similaridades com as tecnologias atuais, que captam dados do ambiente, utilizando instrumentos que imitam capacidades sensoriais do raciocínio humano, bem como a compreensão desses dados. Finalmente, considera a necessidade de identificar as raízes dos pressupostos teóricos filosóficos, a fim de consolidar a Ciência de Dados e despertar para a produção de novos conhecimentos.

Palavras-chave: Ciência de dados. Filosofia. Tecnologia sensorial.

Data Science based on Aristotelian Common Sense Science: a comparative analysis with the robotics technology

Abstract: The study compares the perception of the aristotelian comprehension applicable to Data Science, with objective of seeking theoretical and philosophical grounds to this emergent subject. The research bases itself on two methods: (a) literature review – on the contributions of the critical studies relevant to the aristotelian philosophy of the common sense experimentation and; (b) content analysis – for its inference capability and comprehension deduction. It argues from the three levels of thinking observed by Aristotle, under the following aspects: (1) senses and feelings are data that the mind receives; (2) ideas are data that the mind produces and; (3) thinking produces knowledge that relate ideas, combining, splitting and confronting them, in which is created by the cognition capability in search of reason. As a comparative result, it finds similarities with the current technologies, which captures data from the environment, using instruments that imitate human reasoning sensory abilities, as well as data comprehension. At last, it considers the need for identifying the roots of the theoretical and philosophical assumptions, in order to consolidate Data Science and awaken for the production of new knowledge.

Keyword: Data science. Philosophy. Sensory technology.

a Universidade Federal de Minas Gerais (UFMG). E-mail: marcellomundim@ufu.br. ORCID: https://orcid.org/0000-0001-7945-6673. Currículo: http://lattes.cnpq.br/7319023790210705

b Universidade Federal de Minas Gerais (UFMG). E-mail: terezacristinafernandes@gmail.com. Currículo: http://lattes.cnpq.br/7232491498080272

1 Introdução

A Ciência de Dados é uma área de estudo que cresceu exponencialmente nos últimos 10 anos. De maneira global, escolas de Ciência da Informação e as I-Schools tentam absorver essa disciplina, oferecendo formação à nível de graduação e pós-graduação com o intuito de profissionalizar o "cientista de dados", indicando que este conhecimento se tornou relevante ao cenário atual e uma oportunidade de crescimento profissional.

Sendo interdisciplinar, apresenta várias visões diferentes. Porém, segundo Wang (2018), há um certo consenso entre os pesquisadores no que diz respeito a identificar e extrair padrões valiosos de grandes volumes de dados, convertendo dados em informação e conhecimento através da mineração e análise de dados. O mesmo pesquisador avalia que a missão e a natureza da Ciência de Dados são consistentes com as da Ciência da Informação e que estão intimamente inter-relacionadas e, juntas, formam os componentes da pesquisa da "cadeia de informações".

Portanto, a Ciência de Dados é uma área emergente e necessária, que absorve conhecimento de outras áreas e se torna o mais novo interesse da Ciência da Informação. Todavia, é possível considerá-la uma ciência?

Do ponto de vista epistemológico, por ser uma nova disciplina e por conter peculiaridades interdisciplinares, é uma área que requer abordagens críticas que lhe dê sustentação sólida, enquanto campo científico. Embora não seja intenção deste artigo estender-se na base conceitual, os termos "dado", "datum" ou "data", os dois últimos, singular e plural em latim, possuem atributos multifacetados, caracterizando-os como um conceito ambíguo. Portanto, sendo os dados um fenômeno atual, que surge com desafios e paradoxos, torna sua ciência um estudo ainda mais reflexivo, com necessidade de sustentações filosóficas.

O pensamento aristotélico, embora muitas vezes criticado por apresentar uma rigidez ordenada e hierarquizada da natureza, começou onde todos deveriam começar – naquilo que já sabia, na sua experiência mental simples de suas observações. O saber prático necessário se baseava no conhecimento do senso comum da natureza, com o intuito de entender suas leis ocultas. Considerando o senso comum, este artigo busca doutrinas aplicáveis à Ciência de Dados, que interessam mais à história da ciência que à história da filosofia.

O quarto paradigma da ciência difundido por James Nicholas Gray (Jim Gray), há mais de uma década constrói a ciência atual a partir da junção das tradicionais que se usam da observação e experimentação (empirismo), teste de teorias, computação e suas simulações com o acréscimo de conceitos, técnicas e ferramentas analíticas dirigidas a dados.

Esse paradigma se baseia no pragmatismo científico, mas anseia por bases filosóficas sólidas para melhor entendimento desse fenômeno. A velocidade do fazer de hoje não facilita a construção de uma fundamentação desse novo paradigma, pois esse processo necessita de cognição, lógica e indagações que consomem tempo, um aspecto extremamente frágil nessa nova era pragmática dos dados.

Neste sentido, este artigo busca se sustentar na ideia de que a filosofia pode tanto argumentar como responder lacunas da Ciência de Dados. Do ponto de vista do pensamento simples, argumentações filosóficas de meras especulações podem tomar grandes proporções epistemológicas, conduzindo a experimentos práticos por cientistas.

Neste caso considera-se que a ciência precisa da filosofia tanto quanto a filosofia precisa da ciência. Em seu livro Um discurso sobre ciências, Boaventura de Souza Santos (2002, p. 10) propõe um novo senso comum, em que a "[…] distinção hierárquica entre conhecimento científico e conhecimento vulgar tenderá a desaparecer e a prática será o fazer e o dizer será a filosofia prática", o que caracteriza uma certa tolerância científica em relação às experiências humanas.

A história da ciência está repleta de confirmações de como especulações filosóficas aguçaram experimentos científicos. Cita-se o exemplo da física do movimento: a falta de precisão e lógica dos argumentos da física aristotélica sobre sua observação do movimento, conduziram sucessores pesquisadores como Galileu, Descartes, Newton e Einstein ao intenso processo da evolução desse conhecimento.

Dessa forma, este artigo parte da premissa que uma ciência se fundamenta não apenas pela metodologia, mas também pela história e filosofia dos fenômenos.

2 Objetivos

O presente artigo possui característica introdutória, resumindo-se a algumas observações gerais e simples, com o objetivo de motivar estudos e reflexões ulteriores.

Sem assumir posição se a ciência deve se orientar em relação ao senso comum, é objetivo deste artigo apresentar similaridades do pensamento aristotélico no que confere suas experiências do senso comum ao produzir conhecimento. Em outro plano, indicar contribuições do pensamento aristotélico sobre a ciência dos dados, contribuindo para a percepção da tecnologia sensorial. Já sob o ponto de vista da percepção do senso comum, indicar semelhanças envolvidas nos processos perceptíveis, nos processos de encadeamento lógico e na cognição através de posições teóricas sólidas fundamentadas na ciência aristotélica.

3 Metodologia

Este artigo apoia-se em duas metodologias: (a) a revisão bibliográfica – nas contribuições dos estudos críticos pertinentes à filosofia aristotélica da experimentação do senso comum e; (b) na análise de conteúdo – pela capacidade de inferência e dedução da compreensão.

Metodologicamente, para a escolha dos documentos, utilizou-se a regra dos textos representativos. Após a leitura flutuante, algumas hipóteses foram levantadas. Em seguida, analisou-se o conteúdo dos livros e artigos com base nos relacionamentos entre três categorias semânticas principais: ciência, filosofia aristotélica e ciência dos dados. Para alcançar os resultados, utilizou-se a técnica de inferência que levaram às interpretações. Em seguida, foi feita uma análise comparativa para apresentar similaridades entre o pensamento aristotélico no que confere suas experiências do senso comum que buscam produzir conhecimento e suas inter-relações.

4 Ressonâncias da ciência no senso comum aristotélico

De maneira resumida, sob o argumento da necessidade da filosofia na ciência, esta seção visa dar atenção à evolução da Ciência da Computação e mostrar como o conhecimento aristotélico,

em parte, auxiliou o desenvolvimento de novas teorias, e por conseguinte, técnicas e tecnologias sofisticadas.

Francis Bacon e John Locke, filósofos do iluminismo, repudiaram completamente o pensamento aristotélico e medieval, como muitos empiristas desde então, muitas vezes negligenciaram a importância crítica da lógica aristotélica para o pensamento científico. Na época moderna, o saber prático necessário tem se baseado no conhecimento das ciências naturais, proporcionando tecnologia através do conhecimento científico (ADLER, 2010).

Porém, chama atenção a história da Ciência da Computação e suas derivações advindas da lógica formal de Aristóteles, com o raciocínio silogístico, mas interpretado e adaptado para a álgebra, no trabalho de George Boole (1815–1864). "As interpretações respectivas dos símbolos 0 e 1 no sistema de lógica são Nada e Universo", disse o matemático (GLEICK, 2013).

Dessa forma, substitui-se termos do silogismo por variáveis, e as palavras lógicas "tudo", "é" e "portanto" com operadores aritméticos. Assim, na famosa premissa maior de Aristóteles "Todos os homens são mortais", pode-se interpretar "Tudo no conjunto x também está no conjunto y", exemplificado por Boole, originando as portas lógicas mais básicas, na linguagem original de Boole, E (AND), OU (OR) e NÃO (NOT) (FERNEDA, 2012).

Incentivado por Vannevar Bush (1890– 1974), a visão de Claude Shannon (1916– 2001) era que o sistema de Boole poderia ser mapeado diretamente em circuitos elétricos, ao perceber que a teoria correta seria "exatamente análoga ao cálculo das proposições usadas no estudo simbólico da lógica". Ele mostrou a correspondência entre circuitos elétricos e operações booleanas e como mapear a lógica no mundo físico ao distinguir suas camadas. Por volta de 1940, Alan Turing (1912–1954) assimilou esse conhecimento e o utilizou ao projetar computadores na linguagem da lógica matemática (TASINAFO, 2008).

Portanto, pode-se inferir que a gênesis da Ciência da Computação é uma ressonância do aguçamento iniciado por Aristóteles, motivado por conceitos que nascem no cotidiano (senso comum). Seguindo seus passos, Boole propôs que as Leis do Pensamento começam com uma descrição de seus objetivos, para investigar as leis fundamentais da operação da mente humana, assim como proposto por Aristóteles.

A lógica concebida por Aristóteles há 25 séculos e que perdura nos dias atuais é ensinada nas aulas de filosofia e Ciência da Computação – lógica de primeira ordem ou de predicados – com algumas modificações do sistema de Gottlob Frege (1848–1925) é inspirada pela tentativa de Boole de melhorar a lógica de Aristóteles.

5 Por que Ciência dos Dados?

Trata-se de um tema basal para a Ciência da Informação (CI). Zins (2011) define: "dados são frequentemente concebidos como matéria-prima para a informação, que é frequentemente concebida como matéria-prima para o conhecimento". Este mesmo autor afirma: "dados, informação e conhecimento são inter-relacionados" (ZINS, 2007, p. 452).

O estudo científico dos dados não é exclusivo da Ciência da Informação, pois incorpora elementos variados e se baseia em técnicas e teorias oriundas de muitos campos, como Ciência da Computação, Inteligência Artificial, engenharias, estatísticas, entre outras, sendo assim ligada em muitos campos, uma área altamente interdisciplinar. Porém, devido a essa característica, os dados,

ou o que constitui dados, são falíveis, portanto, são conjecturas. Consequentemente o Big Data é falível e contaminado por teorias (FRICKÉ, 2015).

Os dados são um novo fenômeno da contemporaneidade que proporcionam grandes desafios e oportunidades: os atuais volumes de dados a analisar, bem como seu dinamismo e capilaridade, surgem como oportunidades de progresso científico e inovação tecnológica em diferentes áreas do eixo ciência-indústria-governo.

Os dados tornam reais as possibilidades de inferência da informação. A partir do tratamento e análise dos dados ou conjuntos de dados, pode-se manipulá-los para inferir (deduzir de maneira lógica) conhecimentos que podem variar desde atividades do emissor de dados, como também conter informações sobre o próprio emissor dos dados.

No domínio universal, "dados" são um conjunto de códigos, representando percepções empíricas ou "matéria-prima empírica". No domínio abstrato ou subjetivo, "dados" são estímulo sensorial ou seu significado (ou seja, a percepção empírica) (ZINS, 2011).

Portanto, a motivação inicial da Ciência de Dados é seu próprio fenômeno na contemporaneidade, sua aplicabilidade e sua transversalidade com outras áreas, sendo assim, tudo que possa contribuir para seu estudo deve ser investigado.

Inspirado por novas teorias acerca dos dados e sua interdisciplinaridade, o artigo busca refletir – a partir de análises, inferidas por pressupostos aristotélicos – os dados sensíveis que consistem na matéria-prima do pensamento e conduzem à possibilidade de inferência, uma potência na construção do pensamento cognitivo em ato, como será visto a seguir.

6 O pensamento, o conhecimento e os dados

Ao dedicar estudos sobre os homens, no célebre Sobre a alma, Aristóteles introduz entre outras compreensões, a descrição dos sentidos externos e de sua distinção dos sentidos internos, donde advém parte deste estudo comparativo. Outros tratados, entre eles, Categorias, Da interpretação, Sobre a sensação, também contêm doutrinas que interessam a este estudo, ao relacionar propriedades que são inerentes ao ser humano; a capacidade do pensamento e acúmulo de conhecimento.

As seções a seguir (6.1 e 6.2) são inferências e interpretações dos referidos tratados sobre a mente. Nessa abordagem, na visão aristotélica, três níveis correlacionados do pensamento são necessários para produzir conhecimento. O primeiro nível refere-se aos sentidos, o segundo, às ideias e o terceiro, ao pensamento.

A seção 7 corresponde aos resultados da analogia dos três níveis de pensamento com os dados e a relação com a tecnologia sensorial.

6.1 Os dados sensíveis, matéria-prima das ideias

Os sentidos estão presentes nos órgãos receptores, respondendo a estímulos sensoriais do mundo externo. Essa é uma capacidade passiva do corpo humano, em que cada um dos sentidos produz sensações quando o órgão sensível sofre ação física de algo do mundo exterior. As sensações podem ser vividas tanto separadamente quanto em conjunto a outros sentidos. Assim, é possível em um único objeto obter a sensação de paladar, tato e olfato ao mesmo tempo, ou produzir sensações simultâneas – sinestesia.

Entretanto, os sentidos sozinhos não são capazes de produzir ideias, eles representam as matérias-primas de como a experiência sensível é formada. Segundo Aristóteles, a experiência sensível torna-se ativa quando a percepção envolve os processos da ação da memória e da imaginação, aliadas à capacidade de compreensão das sensações do mundo exterior. Para o filósofo, o esforço da mente de compreender as informações dos sentidos e da percepção, ou seja, da experiência sensível, forma as ideias.

A partir da atividade racional, não dos sentidos, o cérebro, órgão que recebeu as instruções dos órgãos dos sentidos, consegue distinguir as capacidades motoras, do paladar, da visão, audição e tato, tais como: andar, pular, repouso, cores, sons, entre outros. A capacidade de compreender instantaneamente a natureza das diferenças entre cães e gatos, por exemplo, se dá pela ação da natureza particular de cada um deles. É na mente que a forma das coisas se tornam ideias claras, separando-as da matéria individualizante.

Aristóteles diferencia a capacidade da mente de produzir coisas da capacidade de produzir ideias. Uma é o exato oposto da outra, pois ao produzir coisas, a mente transforma a matéria de acordo com as ideias, enquanto que ao produzir ideias a mente toma as formas das coisas e as transformam em ideias.

Quando a mente forma ideias de cães e gatos, por exemplo, a compreensão desses animais está presente na experiência sensível. Pela ação da sensação, é possível perceber, lembrar, recordar, imaginar ou até sonhar com esses tipos de "objetos".

6.2 Produzir conhecimento – o pensamento por cognição

Este nível de pensamento é chamado por Aristóteles de raciocínio ou de inferência, atribuído a nossa capacidade de cognição. Segundo Da Silva (2011), todo modelo de categorização é cognitivo, dado que este é um processo intrínseco ao pensar e ao agir humano. Somente quando uma asserção se torna a base para afirmar ou negar outra asserção é que a mente ascende ao terceiro nível de pensamento. Nesse nível, o pensamento envolve dar razões para aquilo que pensamos. Entretanto, também nesse nível, aquilo que pensamos pode ser lógico ou ilógico (ADLER, 2010).

O terceiro nível de pensamento está associado à teoria do silogismo, objeto de referência científica à lógica booleana, conforme visto na seção 4. Porém, para compreender o silogismo, deve-se de antemão conhecer a divisão das coisas em categorias através do método lógico dedutivo.

O discurso – técnica altamente desenvolvida, fundamentada na teoria do silogismo – deve compreender o encadeamento hierárquico por gradação, sendo a substância, o centro unificador na ontologia aristotélica. Por conseguinte, examinar quais são os pressupostos embutidos nas ideias, testar o grau de confiabilidade de cada uma e hierarquizar os conceitos na sua ordem de dependência.

7 Resultados – Inter-relação entre o pensamento do senso comum aristotélico, a Ciência dos Dados e a Tecnologia Sensorial

Em analogia, conforme visto na seção 6.1, os sentidos e as sensações são os dados que a mente recebe, enquanto que as ideias são os dados que a mente produz.

Foram considerados dados, matérias primas com instruções captadas pelos órgãos dos sentidos que se conectam à mente. Chegando ao seu destino, as matérias primas (ou instruções) são liberadas formando ideias. Portanto, o primeiro e segundo nível de pensamento formam as ideias, as quais são os dados que a mente produz como resultado daquilo que recebe a partir dos órgãos dos sentidos.

Por vezes chamadas de "instruções", os dados também são considerados, apoiando- se em Zins (seção 5), a "matéria-prima" para a construção de ideias.

O terceiro nível se dá quando a mente começa a produzir ideias a partir da experiência sensível. Este nível depende da capacidade cognitiva de organizar as ideias através do encadeamento de objetos e palavras para poder expressá-las.

Nesta abordagem do senso comum aristotélico, surge uma questão: uma máquina com IA poderia ser programada pela percepção sensorial, utilizando scanners de alta resolução – tal qual os órgãos receptores – para entender e interpretar o implícito "cognitivamente", os dados que os sensores captam e transformá- los em uma informação concreta?

Esta percepção tecnológica já é uma realidade contemporânea. Robôs conseguem aprender baseado no que acontece no ambiente, como ocorre nos carros autômatos, por exemplo.

O plano categórico hierárquico, apresentado na seção 6.2, envolve a organização e a definição da estrutura hierárquica do universal e suas relações com os atributos. Os enormes volumes de dados podem ser lidos sequencialmente pelo computador, o qual pode efetuar operações lógicas ou algébricas em grande velocidade, unindo não só a inteligência artificial, mas também as ciências cognitivas e a Ciência da Informação. Portanto, os processadores podem relacionar as classificações (análise preditiva), análise de agrupamentos de dados tal como o encadeamento sistemático do conhecimento de Aristóteles.

Sendo assim, processadores auxiliam a organizar dados por classificação, a partir de uma análise preditiva, ou por análise de agrupamento hierárquico, por partição ou por densidade, práticas da mineração de dados. O mesmo acontece no silogismo e na lógica, que propõem o encadeamento, ou agrupar nas práticas de sistematização, a partir da observação de um discurso, em busca do aumento do grau de certeza.

8 Considerações finais

Como foi visto na seção 6, Aristóteles sempre fundamentou sua ciência a partir de estudos históricos articulados com sua filosofia. Na seção 4 foi visto o exemplo de cientistas que fundamentaram seus estudos a partir de conhecimentos aristotélicos. Na introdução, mostramos como erros da física aristotélica motivaram estudos subjacentes em busca da realidade. Isso demonstra a preocupação da ciência não só em identificar possíveis raízes históricas, como também buscar uma solidez tanto para refutar estudos anteriores como para confirmar suas hipóteses.

Todavia, um dos objetivos deste artigo foi apresentar argumentos que identifiquem raízes filosóficas históricas da Ciência de Dados para que essa se sustente, aproximando-a de ferramentas tecnológicas que utilizam os dados como sua principal matéria-prima.

A Ciência de Dados, enquanto campo científico e do conhecimento, também necessita de uma solidez na sua fundamentação. Outro objetivo deste artigo foi trazer uma sustentação

filosófica à nova área de conhecimento que vem emergindo, tal qual orienta o quarto paradigma difundido por Jim Gray.

Outro objetivo deste artigo foi comparar os estímulos externos que os órgãos receptores recebem a dados, indicando semelhanças aos dados codificados de computadores com tecnologia sensorial. De maneira similar, os dados sensoriais são instruções da percepção enviada ao cérebro, enquanto que os dados da tecnologia sensorial são dados enviados a processadores tecnológicos (seção 6.1).

No contexto tecnológico foram observadas semelhanças no que concerne os procedimentos utilizados pela análise de dados utilizados na (IA) com os princípios da realidade categórica, cognitiva e lógica metafísica de Aristóteles (seção 6.2).

A abordagem filosófica se sustentou nos tratados de Aristóteles, por este ter sido o pioneiro "cientista" a descrever, usando experiências mentais simples, o comportamento sensorial orgânico humano.

Muitas vezes, a capacidade sensitiva é tão natural aos seres humanos que não prestamos atenção em como esse fenômeno ocorre. Hoje, encontramos similaridades com a ciência moderna pelo complexo sistema nervoso central. Células nervosas levam as "instruções", ou as "matérias primas", ou "códigos", ou "células", em última instância, os "dados", que irão se encaixar por sinapses nas terminações nervosas mentais. Consequentemente o sistema nervoso decodifica esses dados que recebe do meio externo, que podem ser arquivados ou respondidos se solicitados. Podem ser simples reações como movimentos e sensações agradáveis, como também formulação de conhecimento complexo.

Nesta perspectiva, há um corolário de comparações que podem ser feitas sob o ponto de vista do papel dos dados nos processos de diversos paradigmas da ciência. Neste artigo, foi abordado o da tecnologia sensitiva, que cópia, de maneira efetiva, quase biológica, os processos atribuídos aos órgãos sensíveis humanos.

Dessa forma, como foi verificado, existem certas correspondências da percepção sensitiva da observação do senso comum, que, quando comparadas criticamente, podem ser transformadas em tecnologias empíricas. Assim, também, através de percepções da Organização do Conhecimento, da representação das categorias cognitivas como forma de encadear e identificar os dados.

Contudo, ainda estamos longe de um robô que entenda completamente o mundo. Sonhos, esperanças, sentimentos, em escala menor, é o que nos distingue.

Embora fazer comparações de dados – a partir do ponto de vista da tecnologia sensorial – possa parecer coerente, este não é um ponto de partida que auxilie no avanço científico para a Ciência de Dados. Inicialmente, deve-se verificar o fenômeno em proporções tanto históricas quanto futuristas.

Por fim, deve-se mencionar que a ciência moderna tenta descrever as condições materiais subjacentes a certos efeitos empíricos, enquanto a ciência aristotélica procura explicar as coisas em termos de propósitos e os tipos de coisas que existem. De fato, visam coisas diferentes, porém, isso não significa que um refuta o outro, eles se sustentam na busca do conhecimento.

Referências

ADLER, M. J. **Aristóteles para todos:** uma introdução simples a um pensamento complexo. São Paulo: É Realizações, 2010.

ARISTÓTELES. **Poética**: Organon; Política; Constituição de Atenas. São Paulo: Nova Cultural, 1999. 315 p. (Os pensadores).

_____. **Categories**. Da alma (De anima), int., trad. e notas por Carlos Humberto Gomes. **Lisboa: Edições**, v. 70, 2001.

_____. **Metafísica**: Livro I. Trad. e nota de Lucas Angioni. Campinas: IFCH/UNICAMP, 2002.

COTRIM. G. **Fundamentos da filosofia**: história e grandes temas. 15. ed. São Paulo: Saraiva, 2002.

DA SILVA, L. A.; PERES, S. M.; BOSCARIOLI, C. **Introdução à mineração de dados: com aplicações em R**. Brasil: Elsevier, 2017.

DA SILVA, A. R.; D. O. LIMA, G. A. B. As categorias e a categorização cognitiva contemporânea: enfoque sobre os olhares da biblioteconomia e ciência da informação e das ciências cognitivas. **Revista Interamericana de Bibliotecología**, v. 34, n. 3, 2012.

FERNEDA, E. **Introdução aos modelos computacionais de recuperação de informação**. Ciência moderna, 2012.

FRICKÉ, M. Big data and its epistemology. **Journal of the Association for Information Science and Technology**, v. 66, n. 4, p. 651-661, 2015.

GLEICK, J. **A informação: uma história, uma teoria, uma enxurrada**. Editora Companhia das Letras, 2013.

HEY, T.; TANSLEY, S.; TOLLE, K. (Editors). **The fourth paradigm**: data-intensive scientific discovery. Redmond, Washington: Microsoft Research, 2009.

ZINS, C. Conceptions of information science. **Journal of the American Society for Information Science and Technology**, v. 58, n. 3, p. 335-350, 2007.

_____. Redefinindo a Ciência da Informação: da "ciência da informação" para a "ciência do conhecimento". **Informação & Sociedade: Estudos**, v. 21, n. 3, 2011.

REALE, G. **Introdução a Aristóteles**. Rio de Janeiro: Contraponto, 2012.

SANTOS, B. de S. **A crítica da razão indolente**: contra o desperdício da experiência. 3. ed. São Paulo: Cortez, 2001.

TASINAFO, P. M. Um breve histórico do desenvolvimento da lógica matemática e o surgimento da teoria da computação. **Anais do 14° Encontro de Iniciação Científica e Pós-Graduação do ITA – XIV ENCITA / 2008**. São Paulo, 2008.

WANG, L. Twinning data science with information science in schools of library and information science. **Journal of Documentation**, v. 74, n. 6, p. 1243-1257, 2018.

Vídeo da apresentação

Título: A Ciência de Dados à luz da ciência do senso comum Aristotélico: uma análise comparativa com a tecnologia sensorial.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=21

Transcrição da apresentação

Oi, boa tarde meu nome é Teresa, eu sou Marcelo, e nós somos estudantes de mestrado do PPGGOC, da UFMG. Nós estamos aqui pra falar do nosso artigo intitulado "A Ciência de Dados à luz da Ciência do Senso Comum Aristotélico: uma análise comparativa com a tecnologia sensorial.

A ideia de nós dois escrevemos juntos surgiu porque nossos temas de pesquisa para a dissertação envolve a lógica nos processos empíricos das atividades da organização do conhecimento.

Na introdução do nosso trabalho, nós fizemos considerações a respeito da ciência dos dados, pois ela já nasce interdisciplinar, e essa característica a torna uma ciência facetada. Então os dados, que são um fenômeno atual, emergem com desafios e paradoxos que tornam essa ciência um estudo ainda mais reflexivo com a necessidades da sua sensação filosófica.

Para sustentar a ideia de que a ciência dos dados requer uma base filosófica, nós apontamos para o quarto paradigma de Jim Gray, que indica a necessidade de junção das ciências tradicionais, que usam observação, experimentação e computação, mas que também anseiam por bases filosóficas sólidas para o melhor entendimento do fenômeno dos dados.

Mesmo quando as experimentações baseadas no senso comum, como é o caso de Aristóteles, que são refutadas por cientistas modernos e contemporâneos, de certa maneira contribuíram para o agravamento desses pesquisadores encontrarem respostas lógicas e transformar o abstrato em realidade, mostramos isso ao relembrar a física do movimento, que foi inicialmente apontada por Aristóteles, e mais tarde contestada e aprimorada por Galileu, em sequência por Descartes, Newton e finalmente resolvido por Einstein.

Pelo menos nenhum cientista da nossa época conseguiu refutar a teoria da relatividade de Einstein, isso mostra que embora contenha erros, a Física de Aristóteles e articulada com sua filosofia motivou estudos anteriores indicando a evolução do conhecimento, na seção quatro [do artigo] nós tratamos também, só que do ponto de vista da Ciência da Informação.

Quanto aos nossos objetivos nós pretendemos foi apresentar as similaridades do pensamento aristotélico sobre a ciência de dados, também indicar semelhanças na capacidade humana perceptiva sustentada nos tratados de Aristóteles por ele ter sido pioneiro em descrever a ação humana passiva dos órgãos sensível de receber os dados externos, decodificá-los e transformá-los em um aprendizado do conhecimento. Nosso objetivo maior é trazer desde a comparação uma sustentação filosófica na área de conhecimento "Ciência de Dados" que vêm emergindo

Quanto à metodologia nós apoiamos em duas: uma é revisão bibliográfica, que nós utilizamos estudos críticos pertinentes na filosofia aristotélica e evolução da ciência; também utilizamos a metodologia "Análise de Conteúdo" e nós organizamos em três categorias principais, que foi "ciência", "filosofia aristotélica" e "ciência de dados".

Chamamos atenção para a contribuição de fundamentos sólidos da filosofia Aristotélica na evolução da Ciência da Computação. George Boole é muito citado nas pesquisas da Ciência da Computação devido a álgebra, porém o que muitos não sabem, pelo menos quem não é da área da Ciência da Computação é que a álgebra é inspirada no aristotélico.

Em sequência nós vamos fazer uma pergunta: Por que a ciência de dados? A resposta para nós é muito óbvia né, o tema ciência dos dados é basal para a Ciência da Informação. O autor Zins afirma que os dados, a informação e o conhecimento, são inter-relacionados, e os dados são um novo fenômeno da contemporaneidade que proporcionam grandes desafios e oportunidades.

Os enormes volumes de dados a analisar, tantos os estruturados quanto os não estruturados, onde hoje fala muito do Big Data, Internet das Coisas, e o seu dinamismo e capilaridade é para a Ciência da Informação uma grande oportunidade, principalmente porque muito do que fazemos em tratamento de organização do conhecimento pode ser aplicado também aos dados, assim como nós fazemos com a informação.

O pensamento, o conhecimento e os dados: é nessa seção que fazemos a comparação de dados fundamentados nos tratados filosóficos e, por que não dizer científicos de Aristóteles, onde ele chama a atenção para os dados sensíveis que considera a matéria prima das ideias. Mas o que seria se seriam esses dados sensíveis? É como se fossem instruções que nossos órgãos e nossos sentidos recebem, por exemplo quando nós estamos num ambiente quente o sentido do tato é recebe aquela instrução, que são dados que vão diretamente para a nossa mente, então esses dados são uma matéria prima que formou no conhecimento do nosso cérebro

Esse seria um primeiro e segundo nível de pensamento tratado por Aristóteles, portanto os sentidos e as sensações são os dados que a mente recebe enquanto que as ideias são os dados que a mente produz.

Portanto na próxima subseção nós tratamos o produzir conhecimento e o pensamento por cognição. Este processo é o terceiro nível de conhecimento, chamado por Aristóteles de raciocínio ou de inferência, e é atribuída à nossa capacidade de cognição.

Porém, para compreender esse nível de compreensão conforme Aristóteles, é necessário entender de antemão as divisões das coisas em categorias que Aristóteles escreveu em seu livro metafísica, que é a lógica dedutiva e que também está presente nos silogismos que o Marcelo comentou e que está no na seção quatro, que é uma comparação com a Álgebra de Boole, além de outros tratados que também contém doutrinas da psique humanas observadas por Aristóteles. Dessas doutrinas se assemelham a Ciência Cognitiva, que é muito utilizado na Ciência da Informação também na Psicologia, na Filosofia, entre outros campos de conhecimento.

No nosso texto está bem mas é explicado, aqui é só uma abordagem para trazer na apresentação, e também a gente quer chamar atenção que nosso estudo é meramente introdutório, a nossa abordagem ela é superficial apenas para trazer à tona essa semelhança da ciência dos dados com a doutrina da filosofia aristotélica. Não introduzimos de maneira ampla para não acarretar em uma gama de habilidades difíceis de demonstrar, porque a filosofia de Aristóteles é muito complexa, então a gente deu uma abordagem superficial mas o aprendizado nosso foi bastante profundo, portanto é uma pesquisa de abordagem seletiva e introdutória.

Nos resultados, o que nós chamamos de inter-relação entre o pensamento do senso comum aristotélico, a Ciência dos Dados, e tecnologia sensorial, o sentido e as sensações são os dados que a mente recebe, como o entendimento nosso de resultado do nosso trabalho, e as ideias são os dados que a mente produz.

Foram considerados dados matérias primas com instruções captadas pelos órgãos e os sentidos que se conectam à mente chegando ao seu destino, as matérias primas ou instruções são liberadas formandos e de ideias.

As tecnologias sensoriais recebem sensores e estes têm os mesmos objetivos dos nossos órgãos de sentidos. Quando pensamos em carros autônomos, por exemplo, e sabemos que essa tecnologia empregada sensores para captar os dados de espaço e de distância, é semelhante à percepção de profundidade humana que a mente processa.

No caso das máquinas é um processador, primeiro e segundo nível de pensamento. Já o terceiro nível de pensamento está relacionada à capacidade cognitiva categórico hierárquico, e envolve a organização e a definição da estrutura hierárquica do universal e suas relações com os atributos.

Este nível de pensamento se assemelha com a inteligência artificial. Processadores são programados para relacionar classificações, fazer as análises preditivas, análise agrupamento de dados, tal qual encadeamento do sistema do conhecimento de Aristóteles que ocorre no cérebro humano.

Em analogia, processadores de inteligência artificial assumem o papel do sistema nervoso central. Os dados, ao chegarem ao seu destino final, são decodificados, e as respostas aos estímulos externos podem ser simples reações, como, por exemplo, o movimento, como também formulações de conhecimento complexas que podem ser aprendidas e armazenadas.

Nas considerações finais [do artigo], reafirmamos a necessidade de vincular a Ciência dos Dados à Filosofia, e constatamos com provas basais algumas comparações do processo de captação dos dados do mundo externo ao mundo sensível dos seres humanos.

Comparamos os órgãos sensíveis e toda a interpretação dos dados pelos órgãos sentidos na visão aristotélica com a tecnologia sensorial, então a diferença das atividades da mente que é o terceiro nível de pensamento que nós abordamos e que relaciona a cognição, são diferentes das atividades dos sentidos do 1º 2º nível de pensamento, que são os estímulos externos que os nossos órgãos e os sentidos captam, assim também como são os sensores e processadores de máquina.

Por fim nós queremos reafirmar né Marcelo, que a filosofia precisa da ciência tanto quanto a ciência precisa de Filosofia como base de sustentação.

Esse é o nosso trabalho, eu quero agradecer a oportunidade que o professor Guilherme nos deu do nosso artigo ter sido escolhido, nós ficamos muito felizes com isso. Espero que quem está com a paciência de assistir a gente e que gostou ou achou interessante que leia, porque é uma abordagem um pouco diferente do que nós estamos acostumado no curso de pós-graduação da Ciência da Informação.

Aspectos do ciclo de vida de dados em processos de construção de ontologias biomédicas

Jeanne Louize Emygdio[a] *e Eduardo Ribeiro Felipe*[b]

Resumo: Tendo por foco o estudo das coisas existentes no mundo e das relações que estas estabelecem entre si, as Ontologias vêm ganhando campo especial de investigação científica por serem consideradas alternativas viáveis à organização das informações massivas e ininterruptamente alimentadas pelos seres humanos nos espaços digitais, por meio das tecnologias da informação e comunicação (TICs). As perspectivas centrais da utilização das ontologias repousam sobre as possibilidades de prover interoperabilidade semântica entre os sistemas de informação, pouco alcançada por meio dos modelos, técnicas e ferramentais usualmente aplicados. O objetivo deste artigo é descrever de que forma a gestão do ciclo de vida dos dados pode contribuir para prover maior qualidade à construção de ontologias biomédicas. A metodologia adotada foi a pesquisa qualitativa, de caráter descritivo sobre os processos de construção da Ontologia realista Obstétrica e Neonatal – OntoNEO. Os resultados encontrados comprovaram a eficiência do plano de gestão de dados como requisito de atribuição de qualidade à referida ontologia, o que a habilitou a integrar o projeto Basic Formal Ontology – BFO, padrão de referência na construção de ontologias realistas de alto nível.

Palavras-chave: Ontologias biomédicas. Ciclo de vida de dados. Plano de gestão de dados. Representação do conhecimento.

Aspects of the data life cycle in processes of construction of biomedical ontologies

Abstract: With the focus of the study of the existent things in the world and of the relations that these establish with each other, the Ontologies have been gaining special field of scientific investigation for being considered viable alternatives to the organization of the massive information and uninterruptedly fed by the human beings in the digital spaces, through of information and communication technologies (ICTs). The central perspectives of the use of ontologies rest on the possibilities of providing semantic interoperability among information systems, little achieved through the models, techniques and tools usually applied. The purpose of this article is to describe how the data life cycle management can contribute to provide higher quality to the construction of biomedical ontologies. The methodology adopted was the qualitative research, of a descriptive character on the construction processes of the realistic Ontology Obstetric and Neonatal – OntoNEO. The results obtained proved the efficiency of the data management plan as a requirement of quality attribution to this ontology, which enabled it to integrate the Basic Formal Ontology – BFO project, a reference standard in the construction of high level realist ontologies.

Keyword: Biomedical ontologies. Data life cycle. Data management plan. Knowledge representation.

a Universidade Federal de Minas Gerais (UFMG). E-mail: jeanne.emygdio@gmail.com. ORCID: https://orcid.org/0000-0002-7329-4447. Currículo: http://lattes.cnpq.br/6849175974671037

b Universidade Federal de Minas Gerais (UFMG). E-mail: erfelipe@hotmail.com. ORCID: https://orcid.org/0000-0003-1690-2044. Currículo: http://lattes.cnpq.br/1010588591399870

1 Introdução

1.1 Ontologias

De origem filosófica, o estudo das ontologias busca compreender a realidade dos seres, sua essência, princípios e causas (SEARLE, 1998), baseando-se em exaustivas classificações dos elementos do mundo real visando identificar seu tipo (categoria), estrutura, propriedades, eventos, processos e as inter-relações estabelecidas entre estes elementos (SMITH, 2003).

Atualmente, estes estudos têm sido caracterizados pela interdisciplinaridade, envolvendo campos como a Ciência da Informação (VICKERY, 1997; SOERGEL, 1999; ALMEIDA e BAX, 2003; ALMEIDA, 2013) e a Ciência da Computação (WAND e WEBER, 1990; GUARINO, 1998; WAND, STOREY e WEBER,1999; CANTELE et al, 2004; FONSECA, 2007), com implicações em domínios da medicina (FARINELLI et al, 2016; MENDONÇA e ALMEIDA, 2016, ALMEIDA e FARINELLI, 2017), gestão e organização do conhecimento (TORRES, SIMÕES e ALMEIDA, 2017), biologia (HARRIS e PARKINSON, 2003), engenharia, gestão pública (FARINELLI, SILVA e ALMEIDA, 2013), direito (BREUKERS e HOEKSTRA, 2004; GRIFFO, ALMEIDA e GUIZZARDI, 2015) e geografia (RODRIGUES, CHAVES e SILVA, 2006; MACHADO et al, 2011).

Em função do desenvolvimento da Web Semântica (BERNERS-LEE; HENDLER e LASSILA, 2001) e da necessidade de lidar com a recuperação adequada de massivas informações digitais (ALMEIDA; SOUZA e BARACHO, 2015), as ontologias têm sido utilizadas como recurso alternativo para a representação da realidade em função da formalidade com que seus modelos são concebidos, baseados em lógica descritiva e axiomas formais. Quando convertidos em artefatos de informação proveem vocabulários semânticos consensuais que viabilizam a interoperabilidade semântica entre sistemas computacionais.

Na área da saúde, conforme pesquisas realizadas nas últimas décadas, grande esforço tem sido destinado a integrar e recuperar dados para uso profícuo destes sistemas, especialmente visando a criação do prontuário eletrônico de pacientes – EHR (RECTOR, 2000; SMITH et al, 2007; ANDRADE, ALMEIDA e SCHULZ, 2012; FARINELLI et al, 2016; MARTÍNEZ-COSTA, C., SCHULZ, 2017; BODENREIDER, 2018; HAENDEL et al, 2018).

Em função da complexidade dos dados e informações biomédicas (insumos para a construção de ontologias), compreende-se a relevância das pesquisas no entorno de seu ciclo de vida. Embora a incipiência de tais pesquisas, iniciativas de aspectos complementares podem ser observadas.

Em Ibraim e Ataelfadiel (2017), e Noy et al (2010), o ciclo de vida é visto sob o enfoque principal da Engenharia de Ontologias, subárea da Engenharia do Conhecimento e que aborda processos, métodos e metodologias de desenvolvimento e disseminação de ontologias, bem como plataformas tecnológicas relacionadas (NOY et al, 2010). Embora em Noy et al (2010) as análises ocorram sobre a construção de ontologias biomédicas, apenas em Ibraim e Ataelfadiel (2017) encontram-se aportes teóricos para classificação dos dados em um ciclo de vida de ontologias.

Em VUMC (2005) encontra-se o modelo "Translational Research" que visa a descrição do processo de incorporação de resultados de uma pesquisa científica às práticas reais e, a partir

delas, a retroalimentação de novas pesquisas. O modelo compreende aspectos relacionados aos processos de acesso a dados, sendo composto por quatro ciclos sequenciais que abrangem a coleta, o consumo e a geração de insumos para um novo processo ou pesquisa.

Em Hunkler et al (2011), encontra-se a apresentação de um processo de governança de grandes volumes de dados provenientes da área da saúde, coletados via surveys (Survey of Health, Ageing and Retirement in Europe – SHARE). O processo envolve as tarefas e atores relacionados à governança, além de cuidados especiais para a disseminação pública de dados sensíveis.

Na seção seguinte são apresentados aspectos teóricos acerca dos dados e ciclos de vida que serviram de subsídio para análise de aderência das etapas de construção de uma ontologia biomédica e de identificação dos aspectos de qualidade resultantes.

1.2 Dados e Ciclos de Vida

O conceito de dado tem sua referência histórica na teologia, sua utilização tanto no singular, quanto no plural é encontrada em registros que datam do século XVII (BORGMAN, 2015). É importante ressaltar que em sua percepção, o significado do dado não reside nele mesmo, sendo reflexo de um contexto, um símbolo, um referencial que depende da interpretação do observador.

Embora pareça uma abstração óbvia em nosso dia a dia, o dado não possui uma definição simples, devido sua ampla abrangência semântica. Ele é o insumo base tanto para os sistemas de informação, quanto para os instrumentos informacionais como Listas Controladas, Taxonomias, Tesauros e Ontologias. Constitui-se de uma unidade celular que acrescida de metainformação e semântica, contribui para que a informação seja produzida. Esta visão estruturada em camadas (dado – informação – conhecimento) possui ampla aceitação nos estudos e práticas referentes ao estudo da informação e do conhecimento.

No entanto, sua definição tem sido simplificada e associada a exemplos como números, símbolos, letras e fatos (National Research Council 1999, apud Borgman). O delineamento de suas fronteiras conceituais muitas vezes não são claras e se mesclam com conceituações sobre informação. Neste trabalho um conceito norteador para dado, é o utilizado pela Organisation for Economic co-operation and Development (OECD1) em sua definição sobre "dado de pesquisa"; a organização integrada por 36 nações membro, expressa que: dados de pesquisa são definidos como registros factuais (pontuações numéricas, registros textuais, imagens e sons) usados como fontes primárias para pesquisa científica, e que são comumente aceitos na comunidade científica como necessários para validar os resultados de uma pesquisa. Um conjunto de dados de pesquisa constitui uma representação parcial e sistemática do assunto investigado.

O dado, em comparação com outras estruturas que lidam com informação, como sistemas computacionais por exemplo, também possui "Ciclo de Vida": Um modelo sequencial de ações que resultam em decisões na utilização/manutenção do dado. Briney (2015) elenca uma comparação entre ciclo de vida antigo e novo na perspectiva do dado. Na Figura 1, do Apêndice A, são representadas as quatro etapas consideradas como ciclo de vida antigo, sendo que na primeira etapa, "Planejamento do Projeto", é necessário pensar em quais dados devem ser adquiridos. O próximo passo é trabalhar a "Aquisição dos Dados" propriamente dita. Em

seguida é vista a "Análise dos Dados" para que a última etapa, "Publicação" possa ser realizada. A autora destaca que neste modelo composto por quatro estágios, a aquisição e análise são críticos para o sucesso do processo, e sua crítica reside no sentido de que este ciclo não recompensa o uso do dado além da análise, considerando-os como um subproduto da pesquisa em vez de serem produtos com importância em si mesmos, como um artigo por exemplo. Este modelo foi usado por centenas de anos, mas com o advento digital, o ciclo demanda outras etapas, abordadas no Novo Ciclo de Vida.

Este novo conjunto de processos considera "O Compartilhamento de Dados", a "Preservação" e o "Reuso" como passos no processo de pesquisa, além de incluir "Planejamento de Gerenciamento de Dados e Projeto", "Aquisição de Dados", "Análise de Dados", "Publicação de Artigos" e "Divulgação de Dados", "Preservação" e "Reuso". Na Figura 2, do Apêndice A, são apresentados estes processos e seu fluxo. Este ciclo assemelha-se a outras propostas, como a da DataONE(2018), demonstrada na Figura 3 no mesmo apêndice.

Para Mearian (2003), o ciclo de vida informacional também deve abordar sua persistência, o suporte para sua gravação e recuperação. Observou-se nos artigos pesquisados que a preocupação com a questão processual das etapas de tratamento do dado em seu ciclo de vida foi uma etapa posterior, anteriormente havia uma atenção em relação à arquitetura de armazenamento. Período aquele em que muitas informações foram perdidas por falta de hardware compatível com mídias substituídas por outras. Políticas de migração de dados entre sistemas e sua possível interoperabilidade entre aplicações diversas eram importantes para minimizar o impacto da evolução tecnológica.

Diversos autores e instituições propuseram ciclos de vida de dados abordando processos que, em várias etapas se assemelham. Santana (2013) destaca que não é possível abordar um processo de ciclo de vida sem considerar o contexto em que os dados devam ser tratados, bem como sua especificidade, seja administrativa, descritiva, técnica, estrutural ou de preservação. O autor ainda propõe um Ciclo de Vida dos Dados para Ciência da Informação, CVD-CI, representado na Figura 4, do Apêndice A.

Em Lenhardt et al (2014) encontram-se passos comuns em várias propostas de ciclo de vidas observadas e já descritas anteriormente, tais como: Planejar, Coletar, Controlar Qualidade, Documentar, Preservar, Usar.

Justifica-se o investimento na adoção de um ciclo de vida de dados por benefícios como: facilidade na recuperação, uso e análise dos dados, tanto pelo pesquisador como por colaboradores; fornecimento de dados de qualidade para pesquisas translacionais; melhoria na tomada de decisão; incremento do valor investido na pesquisa; expansão da compreensão sobre um determinado problema e/ou domínio, etc. Um gerenciamento eficiente pode permitir que cientistas externos ao projeto possam encontrar, entender e utilizar os dados no futuro. Adicionando a este cenário a documentação por metadados, a possibilidade de citações e créditos futuros é garantida, além de permitir a rastreabilidade autoral.

2 Objetivos

Embora robustas as pesquisas voltadas à aplicação de ontologias na área da saúde, as respectivas práticas de governança sobre os dados tratados nestas pesquisas precisam ser

aprimoradas. Conforme apresentado anteriormente, não foram identificadas práticas de governança do ciclo de vida do dado dentro do ciclo de vida ontológico, sendo este o fator motivador da presente pesquisa.

Desta forma, o objetivo deste estudo será o de compreender o ciclo de vida de dados biomédicos a fim de representá-los em uma ontologia e, por extensão, compreender ainda, de que forma a gestão deste ciclo de vida poderá agregar maior qualidade à representação de tais dados.

Para o estudo foi selecionada a Ontologia Obstétrica e Neonatal – OntoNEO2 (FARINELLI, ALMEIDA, ELKIN e SMITH, 2016), uma ontologia realista que abrange os domínios de cuidados no pré-natal, intraparto e pós-natal. Tal escopo foi estabelecido baseando-se na análise de um conjunto de padrões de EHR (nacionais e internacionais), sistemas de EHR adotados por diferentes hospitais e entrevistas com obstetras americanos e brasileiros visando identificar os fluxos de trabalho das clínicas de saúde e as demandas informacionais dos médicos envolvidos. A ontologia foi construída por membros do grupo de Pesquisa RECOL3 da Universidade Federal de Minas Gerais (UFMG), do qual os autores do presente artigo participam.

3 Procedimentos Metodológicos

A pesquisa de natureza qualitativa e caráter descritivo baseou-se em uma análise dos procedimentos que conduziram a construção da OntoNEO, em comparação com as etapas dos ciclos de vida previamente apresentados neste estudo. Estes procedimentos foram organizados em etapas selecionadas dos estudos de Briney (2015), DataONE (2018) e Dias (2018). Por fim foram analisados aspectos de qualidade agregados à OntoNEO em função das práticas adotadas em sua construção. Os resultados serão apresentados na próxima seção.

4 Resultados

Os resultados das análises realizadas serão apresentados em cinco etapas, a saber: 1) Informações sobre dados e formatos de dados, 2) Conteúdo dos metadados e formatos, 3) Políticas para acesso, compartilhamento e reúso, 4) armazenamento de longo prazo e, 5) questões orçamentárias.

4.1 Informações sobre dados e formatos de dados

A pesquisa foi realizada a partir do consumo e da produção de dados experimentais variados, como:

(i) Dados brutos ou derivados:

a) consumo de dados provenientes dos padrões adotados para a definição de seu escopo e para prover insumos de dados para a construção da ontologia: Registro de Saúde da Mulher, Registro Anteparto e Formulário Pós-Parto fornecidos pelo Colégio Americano de Obstetras e Ginecologistas (ACOG); o Formato de Registro Eletrônico de Saúde das Crianças fornecido pela Agência de Pesquisa e Qualidade em Assistência à Saúde (AHRQ); Padrões para a Estrutura Clínica e Conteúdo dos Registros de Pacientes fornecidos pelo Centro de Informação de Saúde e Assistência Social do Reino Unido e pela Academia de Faculdades Reais de Medicina; Padrão Nacional para Informações de

Resumo de Alta do Paciente da Autoridade Australiana de Informações e Qualidade em Saúde. Observou-se a preocupação com as especificidades terminológicas, técnicas e administrativas do contexto, o que, em termos de qualidade, contribuiu para a expansão da compreensão sobre o domínio do problema e para a padronização dos insumos de dados para a construção da ontologia. Tais práticas se assemelham aos processos de Planejamento e Coleta encontrados em DataONE (2018);

b) consumo de dados provenientes de pesquisa translacional: um conjunto de 11 ontologias abertas, previamente construídas e publicadas no Bioportal4 serviram de base para a construção da OntoNEO. Tais artefatos proveram classes, entidades e relacionamentos para reúso, em aderência aos princípios da OBO Foundry5 para a construção de ontologias interoperáveis voltadas à representação de realidades biológicas e biomédicas. Entre elas encontram-se a Ontologia de Artefatos e Informação (IAO), a Ontologia dos Genes (GO) e a Ontologia de Doenças Humanas (DOID). Neste sentido observou-se a preocupação com a qualidade dos dados brutos a serem reutilizados, com a perspectiva de prover, ao término da construção, uma ontologia de qualidade para alimentar novas pesquisas translacionais, conforme visto em VUMC (2005).

(ii) Modelos e saídas

a) Produção de modelo de representação do conhecimento abrangendo coleções físicas de classes, atributos e relacionamentos, distribuídas em três conjuntos de dados: informações básicas sobre os cuidados de saúde pertencentes ao escopo da ontologia; dados de formulários e documentos relacionados e entidades sociais envolvidas no contexto. A OntoNEO encontra-se disponível publicamente no repositório de ontologias biomédicas Bioportal. Neste aspecto observou-se a preocupação com as especificidades técnicas e administrativas para que a ontologia pudesse ser publicada respeitando- se as normas de qualidade da OBO Foundry. Tal cuidado constituiu em um incremento do valor investido na pesquisa uma vez que possibilita à comunidade externa o acesso e reúso de sua produção. As práticas adotadas assemelham-se ao processo de Publicação/Divulgação de Dados descrito no novo modelo de Briney (2015);

b) Realização de Prova de Conceito (PoC) sobre a capacidade da ontologia em prover interoperabilidade semântica no domínio estabelecido. Estes resultados podem ser encontrados em Farinelli, Almeida e Emygdio (2018), tendo por saída a proposição de uma arquitetura de interoperabilidade semântica. Observou-se a preocupação com a validação do dado produzido (OntoNEO) quanto à proposta de se constituir em um artefato de informação realmente capaz de integrar semanticamente sistemas computacionais. A PoC garante a eficácia da ontologia produzida e a qualidade do processo de construção.

(iii) Materiais científicos

a) Publicação de artigos científicos relacionados à pesquisa: no período de 2013 a 2017, relativo à produção da pesquisa de doutorado que culminou na construção da OntoNEO, foram produzidos 11 artigos, direcionados a periódicos científicos e congressos e simpósios de grande reconhecimento na área. Dentre eles destaca-se a publicação no

JASIST (ALMEIDA e FARINELLI, 2017). Neste aspecto observou-se a preocupação quanto a divulgação dos conhecimentos teóricos e empíricos que poderão nortear a condução de novas pesquisas, na comunidade nacional e internacional. Tais atividades relacionam-se às previstas em Briney (2005), e compreendem uma contrapartida relevante às agências financiadoras, além de agregarem valor ao reconhecimento da pesquisadora.

(iv) Sobre processamento de dados

A construção da OntoNEO baseou-se em um modelo de ciclo de vida iterativo e incremental, provendo desenvolvimento gradativo da ontologia, com a definição de novas entidades e relações a cada iteração. Três níveis conceituais foram desenvolvidos antes de sua formalização: a) definição do escopo da iteração; b) avaliação de aderência às ontologias preexistentes no domínio para a definição de vocabulário consensual Os seguintes critérios foram estabelecidos para a seleção de classes para reúso: i) a ontologia em questão é aderente aos princípios da OBO Foundry?; ii) as classes possuem definição?; iii) quantas vezes o termo foi previamente reutilizado? iv) qual o status da ontologia no repositório da OBO Foundry?; c) construção de novos termos e relações para atender aos requisitos da OntoNEO não cobertos na fase anterior. As ferramentas OntoFox e Protegé foram utilizadas para importação dos termos e axiomas necessários para a geração do arquivo em formato OWL da OntoNEO. O controle de versões da ontologia foi realizado a partir do ambiente colaborativo para construção de ontologias CMAP Tools.6 Cada versão foi submetida para validação por representantes de diferentes comunidades de especialistas, incluindo médicos. Há compromisso do autor principal em manter atualizações desta ontologia, em função dos avanços científicos na área. O controle de qualidade realizado nestes procedimentos repousam sobre os dados de reúso para construção da OntoNEO, integração de versões, e preservação da ontologia, consonância com Briney (2005), DataONE (2018) e Dias (2018).

4.2 Conteúdo dos metadados e formatos

Conforme citado anteriormente, foram utilizados diversos padrões para formalização de conteúdos de metadados e formatos, além dos princípios da OBO Foundry, essenciais para a construção de ontologias realistas de alto nível agregáveis ao repositório em questão. Houve preocupação em relação à qualidade de representação dos dados, aumentando a possibilidade de reúso futuro e realimentação de pesquisas translacionais e independentes de domínio em função do nível da ontologia.

4.3 Políticas para acesso, compartilhamento e reúso

A OntoNEO segue ainda as diretrizes da OBO Foundry para acesso, compartilhamento e reúso. Os direitos autorais são garantidos aos autores e devem ser mantidos pela licença Creative Commons (License: CC-BY). Tais práticas, associadas às mencionadas no item 4.2 contribuem para facilitar a rastreabilidade autoral, garantir maior número de citações e créditos futuros. E ainda, aproximam-se dos processos de controle encontrados em Dias (2018).

4.4 Armazenamento a longo prazo

A ontoNEO é um projeto que se encontra na fase inicial de desenvolvimento, podendo ser acessada pelos sites: <https://ontoneo.com/> e <https://bioportal.bioontology.org/ontologies/>. O NTONEO, onde será mantida em caráter permanente. Os aspectos de qualidade envolvidos neste item relacionam-se aos processos de preservação do dado, políticas de arquivamento, padrões da comunidade e atribuição de responsabilidades, encontrados em Briney (2005) e Dias (2018).

4.5 Questões orçamentárias

O projeto foi mantido em parte por meio de financiamento das agências de fomento CAPES e CNPQ ao autor principal. Outra parte do projeto foi financiada pelo NIH NCATS sob o prêmio CTSA Número UL1TR001412. As questões orçamentárias são previstas no plano de gestão de dados proposto por Dias (2018).

5 Considerações finais

O presente artigo apresentou uma revisão teórica acerca dos estudos sobre ontologias e sobre os ciclos de dados de pesquisa buscando traçar um caminho de compreensão da relevância da adoção das práticas de governança de dados como premissa para a atribuição de maior qualidade aos processos de construção de ontologias biomédicas.

Uma análise descritiva foi realizada sobre todas as fases de construção da ontologia OntoNEO, abrangendo desde a aquisição de variados dados brutos, puros ou provenientes de pesquisas translacionais, até a publicação das diversas saídas do projeto. Estas fases, apresentadas na seção de resultados caracterizam um tipo de ciclo de vida dos dados para a construção de ontologias biomédicas de maior qualidade, conforme discutido em cada análise.

Em função do volume e dos valores resultados oriundos da pesquisa, especialmente, por sua aceitação como uma ontologia de alto nível, integrante do projeto OBO Foundry, é possível concluir que a adoção das práticas de governança, incluindo as de versionamento e atualização das ontologias constituem uma iniciativa relevante para agregar maior qualidade a estes artefatos, tornando mais eficaz sua capacidade de prover interoperabilidade semântica entre sistemas computacionais.

Referências

ALMEIDA, M. B. (2013). Revisiting Ontologies: a necessary clarification. **Journal of the American Society of Information Science and Technology**. v. 64, n. 8. p. 1682–1693. DOI: 10.1002/asi.22861

ALMEIDA, M. B.; BAX, M. P. Uma visão geral sobre ontologias: pesquisa sobre definições, tipos, aplicações, métodos de avaliação e de construção. **Ci. Inf.**,Brasília, v. 32, n. 3, p. 7-20, set./dez. 2003.

ALMEIDA, M. B.; FARINELLI, F. (2017). Ontologies for Representation of Electronic Medical Records: the Obstetric and Neonatal Ontology. **Journal of the Association for Information Science and Technology**. doi:10.1002/asi.23900.

ALMEIDA, M. B.; SOUZA, R.; BARACHO, R. M. A. Looking for the identity of Information Science in the age of big data, computing clouds and social networks. In: **Proceedings of the 4th International Symposium of Information Science (ISI 2015)**, Croatia.

ANDRADE, A.Q.; ALMEIDA, M.B.; SCHULZ, S. Revisiting ontological foundations of the OpenEHR Entry Model. **Proceedings of the International Conference of Biomedical Ontologies (ICBO)**, 2012, Austria.

BERNERS-LEE, T.; HENDLER, J.; LASSILA, O. The Semantic Web: A new form of Web content that is meaningful to computers will unleash a revolution of new possibilities. **Scientific American**., v.1, p. 34 – 43, 2001.

Best Practices | DataONE. Disponível em:<https://www.dataone.org/best-practices>. Acesso em: 26 set. 2018.

BORGMAN, C. L. **Big data, little data, no data: scholarship in the networked world**. The MIT Press: England, 2015.

BREUKERS, J. A. P. J.; HOEKSTRA, R. J. Epistemology and ontology in core ontologies: FOLaw and LRI-Core, two core ontologies for law. **CEUR Workshop Proceedings**, 2004.

BRINEY, K. **Data management for researchers: organize, maintain and share your data for research success**. Exeter, UK: Pelagic Publishing, 2015.

CANTELE, R. C.; ADAMATTI, D. F.; FERREIRA, M. A. G. V.; SICHMAN, J. S. Reengenharia e ontologias: análise e aplicação. **I Workshop de Rede Semântica (WWS2004)**, 1, 2004.

DIAS, G. A. **Guia de Dados de Pesquisa**, 2018. Acesso em: 22 ago. 2018

FARINELLI, F.; ALMEIDA, M. B.; ELKIN, P.; SMITH, B. OntONeo: The Obstetric and Neonatal Ontology. Proceedings of the **International Conference of Biomedical Ontologies**, Corvallis, U.S, 2016.

FARINELLI, F.; ALMEIDA, M.B.; ELKIN, P.; SMITH, B. (2016). Dealing with Social and Legal Entities in the Obstetric and Neonatal Domain. In Proceedings of the International Conference of Biomedical Ontologies, Corvallis, U.S.

FARINELLI, F.; ALMEIDA, M.B. EMYDGIO, J.L. Arquitetura de dados orientada por ontologias: interoperando sistemas de saúde. In: XVI Congresso Brasileiro de Informática em Saúde (CBIS 2018).

FARINELLI, F.; SILVA, S. de M.; ALMEIDA, M. B. Iniciativas governamentais para interoperabilidade semântica. **Revista Fonte**, ano 10, v. 13, p.66-74, dez. 2013.

FONSECA, F. The double role of ontologies in information science research. **Journal of the American Society for Information Science and Technology**, v. 58, p. 786-793, 2007.

GRIFFO, C.; ALMEIDA J. P. A.; GUIZZARDI, G. Towards a legal core ontology based on alexy's theory of fundamental rights. In: **15th International Conference on Artificial Intelligence and Law (ICAIL)**, 2015.

GUARINO, N. Formal ontology and information systems. In N. Guarino (Ed.). **Formal ontology in Information Systems** (1998, pp. 3–15). Amsterdam: IOS Press.

HAENDEL, M. A.; MCMURRY, J. A.; RELEVO, R.; MUNGALL, C. J.; ROBINSON, P. N.; CHUTE, C. G.. A Census of Disease Ontologies. **Annual Review of Biomedical Data Science**, v.1, p. 305-331, 2018.

HARRIS, M.; PARKINSON, H.. Standards and Ontologies for Functional Genomics:Towards Unified Ontologies for Biology and Biomedicine. **Comp. Funct. Genom.** 2003; 4:116–120.

IBRAHIM, E. A. A.; ATAELFADIEL, M. A. M. Ontology Life Cycle: A Survey on the Ontology and its Development Steps. International Journal of Science and Research (IJSR), v. 6, n. 8, 2017, p. 1352-1357.

LENHARDT, W. C.; AHALT, S.; BLANTON, B.; CHRISTOPHERSON, L.; IDASZAK, R. Data Management Lifecycle and Software Lifecycle Management in the Context of Conducting Science. **Journal of Open Research Software**, v. 2, n. 1, p. e15, 9 jul. 2014.

MACHADO, I. M. R.; ALENCAR, R. O. de; J.; CAMPOS, R. de O.; JUNIOR, C.l A. D.. An ontological gazetteer and its application for place name disambiguation in text. **Journal of the Brazilian Computer Society**, 17(4):267-279, 2011.

MARTÍNEZ-COSTA, C.; SCHULZ, S. Validating EHR clinical models using ontology patterns. **Journal of Biomedical Informatics**, 76 (2017) 124–137.

MEARIAN, L. The Data Life Cycle. **Computerworld**, Knowledge Center Storage. v. November 17, 2003, p. 39, 40, 2003.

NOY, N.; TUDORACHE, T.; NYULAS, C.; MUSEN, M. The ontology life cycle: Integrated tools for editing, publishing, peer review, and evolution of ontologies. **AMIA Annual Symposium Proceedings**, v. 2010, p. 552–556, 2010.

RECTOR, A. L. **Clinical terminology: why is it so hard?** Methods Inf Med. 1999 Dec;38(4-5):239-52.

RODRIGUES, C.; CHAVES, M. S.; SILVA, M. J.. Uma Representação Ontológica da Geografia Física de Portugal. **IX Encontro de Utilizadores de Informação Geográfica**, ESIG-Oeiras, Portugal, 2006.

SANTANA, R. C. G.. Ciclo de Vida dos Dados e o Papel da Ciência da Informação. **XIV Encontro Nacional de Pesquisa em Ciência da Informação (Enancib 2013)**, p. 21, [s.d.], 2013.

SMITH, B.; ASHBURNER M.; ROSSE, C.; BARD, J.; BUG, W.; CEUSTERS, W.; GOLDBERG, L. J.; EILBECK, K.; IRELAND, A.; MUNGALL, C. J.;The OBI Consortium; LEONTIS, N.; ROCCA-SERRA, P.; RUTTENBERG, A.; SANSONE, S.; SCHEUERMANN, R. H.; SHAH, N.; WHETZEL, P.; LEWIS, S.. The OBO Foundry: coordinated evolution of ontologies to support biomedical data integration. **Nat Biotechnol**. 2007 November; 25(11): 1251. doi:10.1038/nbt1346.

SOERGUEL , D.. **The rise of ontologies or the reinvention of classification**.1999. Disponível em: http://www.dsoergel.com/cv/B70.pdf. Acesso em: out. 2018.

STRASSER, C.; COOK, R.; MICHENER, W.; BUDDEN, A. Primer on Data Management: What you always wanted to know. **DataONE**, p. 11, [s.d.].

TORRES, S.; SIMÕES, M.G.; ALMEIDA, M.B. (2017). Princípios para modelagem de domínios em sistemas de organização do conhecimento In: **Anais do III Congresso ISKO Espanha-Portugal**.

VICKERY, B. C. Ontologies. **Journal of Information Science**, London, v. 23, n. 4, p. 227-286, 1997.

VUMC – Vanderbilt University Medical Center **Strategic Plan for VUMC Informatics.** 2005. Disponível em: <https://ncs.mc.vanderbilt.edu/Data/NonSecure/IC_Strategic_Plan_9-12-05.pdf>.

WAND, Y.; WEBER, R. An Ontological Model of an Information System. **IEEE Transactions on Software Engineering**, Vol. 16, No. 11, November 1990.

_____. An Ontological Analysis of the Relationship Construct in Conceptual Modeling. **ACM Transactions on Database Systems**, Vol. 24, No. 4, December 1999, Pages 494–528.

WAND, Y.; STOREY, V. C.; WEBER, R.. An Ontological Analysis of the Relationship Construct in Conceptual Modeling. **ACM Transactions on Database Systems**, Vol. 24, No. 4, December 1999.

Apêndice A

Figura 1 – Ciclo de vida antigo.

Fonte: Adaptado de Briney (2015).

Figura 2 – Ciclo de vida novo.

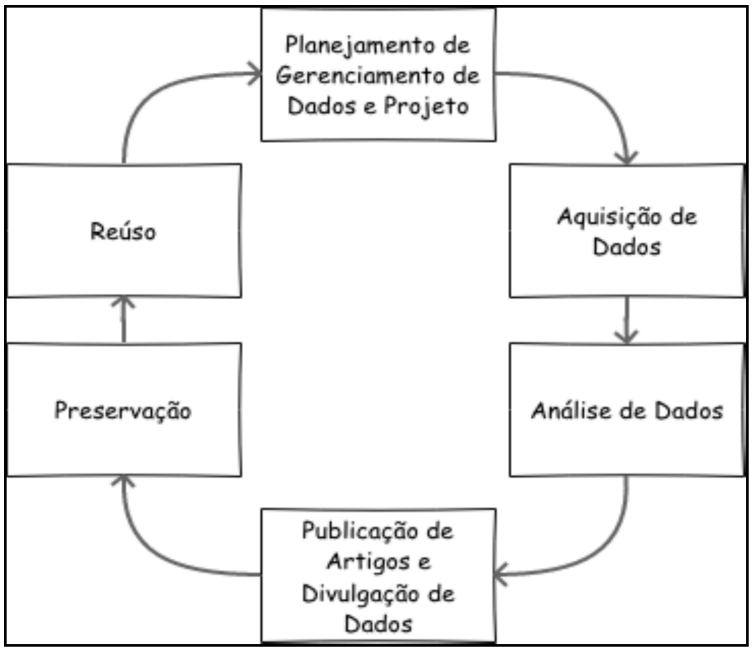

Fonte: Adaptado de Briney (2015).

Figura 3 – Ciclo de vida dos dados.

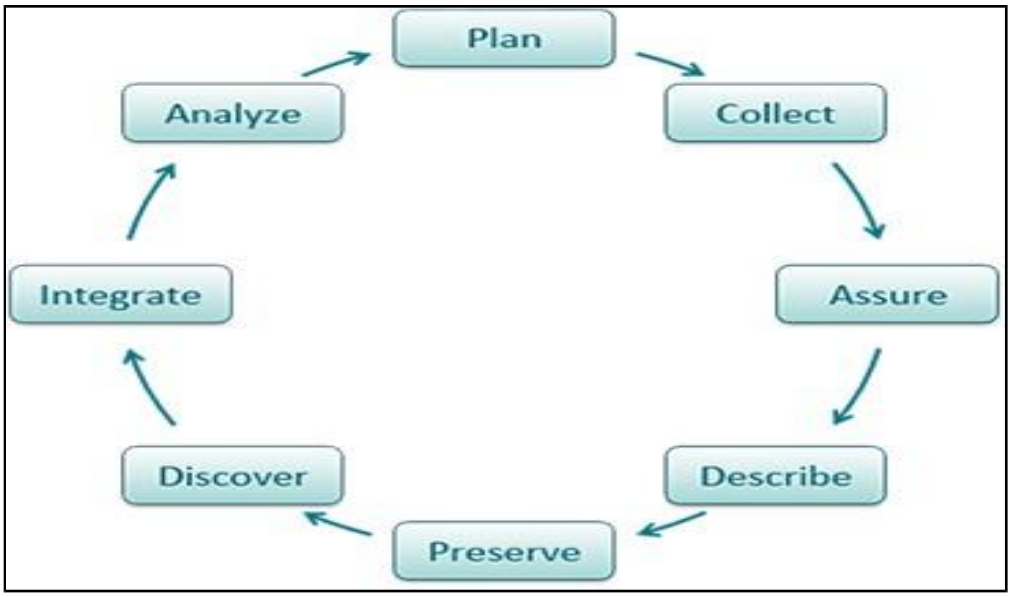

Fonte: DataONE (2018).

Figura 4 – Ciclo de Vida dos Dados para Ciência da Informação, CVD-CI.

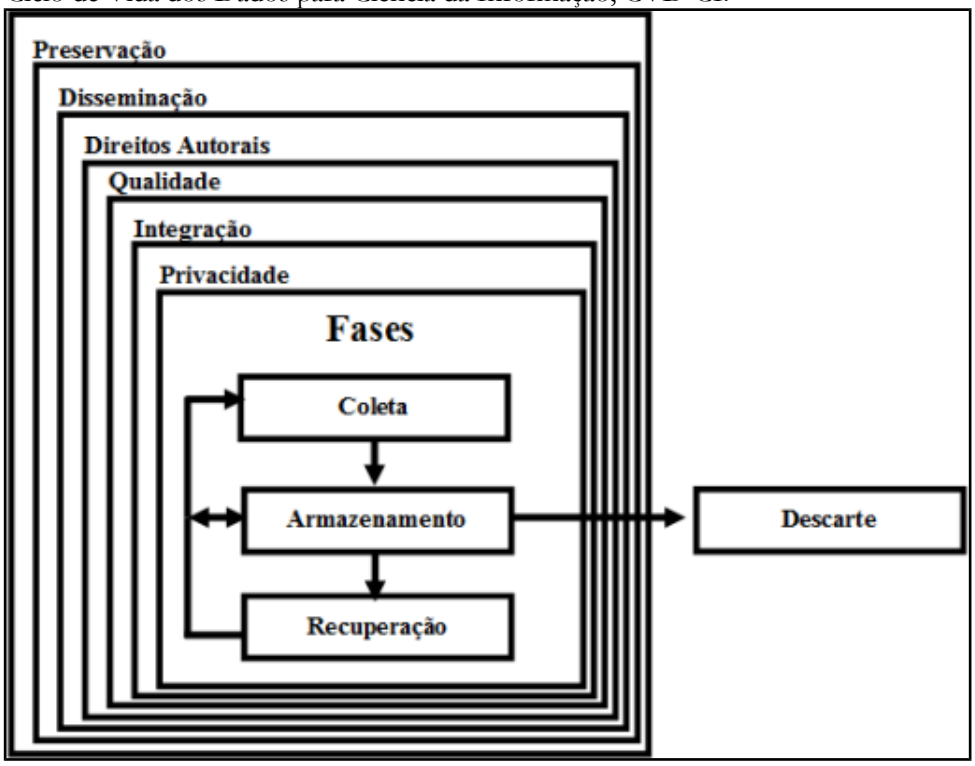

Fonte: Santana (2013).

Vídeo da apresentação

Título: Aspectos do ciclo de vida de dados em processos de construção de ontologias biomédicas.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=22

Transcrição da apresentação

Olá a todos meu nome é Eduardo sou aluno de doutorado na Universidade Federal de Minas Gerais sob a orientação do professor doutor Maurício Barcelo de Almeida eu e minha colega Jeane gostaríamos de apresentar o nosso artigo intitulado Aspectos do ciclo de vida de dados em processo de construção de ontologias biomédicas no segundo o Workshop de Informação, Dados e Tecnologia dos nossos colegas da Universidade Federal da Paraíba.

Estaria apresentando a primeira parte com a introdução, referencial teórico, objetivos e logo em seguida minha colega dará sequência a essa apresentação. Nessa primeira etapa eu dividi em quatro grandes grupos, onde o artigo na introdução apresenta conceitos ontologias em suas origens na filosofia, a sua vocação na representação na realidade dos seres, os seus aspectos intimamente ligados às classificações e principalmente a sua capacidade de estabelecer relações entre os elementos.

Também o artigo retrata interdisciplinaridade como um ponto forte das ontologias e contribuições na área médica na questão da web semântica não podemos deixar de citar a capacidade da ontologia de retratar a realidade em um ambiente virtual na questão dos dados, também colocamos a origem das primeiras representações de conceitos de dados na teologia, o dado enquanto reflexo do contexto, o dado dependente da interpretação do observador e também a sua questão como insumo dos sistemas de informação. Insumo é uma unidade básica dos instrumentos informacionais utilizamos a definição da OECD com uma definição norteadora dos conceitos estabelecidos no artigo e com relação ao ciclo de vida citamos nesses slides aqui quatro boas referências que nos ajudaram na construção do trabalho falando mais especificamente sobre ciclo de vida a identificação inicial foi que ciclo de vida muitas vezes é citado em desenvolvimento de software em construção de ontologias mas foi um pouco mais difícil encontrar essa definição relacionada aos dados é importante ressaltar que encontramos definições de ciclo de vida em dados, porém é direcionado unicamente à persistência dos dados em um período onde a preocupação era o armazenamento e recuperação das informações visto que muitas informações foram perdidas quando os suportes informacionais tecnológicos, as fitas magnéticas nos disquetes eram substituídos com uma velocidade muito rápida impossibilitavam muitas vezes a recuperação dos dados, a autora Briney ela apresenta dois ciclos de vida interessantes, um ciclo de vida que ela denomina de antigo com quatro processos básicos como é visto no slide e um ciclo de vida que ela denomina novo onde ela acrescenta os processos de preservação e reúso.

Também é importante notar nos dois outros ciclos de vidas importantes no artigo o da DataONE e de Santana especificamente direcionam ciclo de vida para a ciência da informação e nos remete muitas vezes e nos lembra muitas vezes no modelo interativo de desenvolvimento de software, pois bem em relação aos objetivos nós procuramos combinar os interesses de nossas teses do grupo de pesquisa Recol e da disciplina do professor Guilherme Dias, encontramos no trabalho da professora Fernanda Farinelli a ontologia OntoNEO e procuramos então compreender o ciclo de vida dos dados biomédicos em processo de construção ontológica.

Pelo tempo já procurando concluir a primeira parte eu quero destacar então que o ciclo de vida de dados ele traz diversos benefícios, ele pode tratar facilidade na recuperação dos dados da

informação, ele pode permitir o uso em análise dos dados na pesquisa pelo próprio pesquisador como colaboradores ele é o ciclo de vida de dados, ele pode melhorar a tomada de decisão e principalmente fornecer dados de qualidade para pesquisas translacionais, onde um instrumento é utilizado como origem como fonte para outros instrumentos, pode permitir que cientistas externos ao projeto encontrem, entendam e utilizem esses dados no futuro e dentro desse cenário acrescentando a documentação por metadados é possível então estabelecer situações e créditos futuros de uma maneira mais ampliada além de permitir a rastreabilidade autoral.

Eu passo então para a segunda parte da apresentação do artigo agradeço a atenção de todos muito obrigado.

Saudações a todos meu nome Jeanne eu sou aluna de doutorado do programa de pós-graduação em Gestão e Organização do Conhecimento da Universidade Federal de Minas Gerais e orientanda do Professor Doutor Luis Barcelos já aumenta nessa segunda parte vou apresentar a vocês os procedimentos metodológicos os resultados e as considerações finais do nosso estudo.

O estudo se caracterizou por uma natureza qualitativa caráter descritivo tendo sido realizado em três fases: a primeira delas compreendeu uma análise dos procedimentos de construção do OntoNEO em comparação com os processos de governança de dados previamente estudados representados pelo colega Eduardo utilizei aqui os termos processo de governança para compreender as fases do ciclo de vida de dados e processos dos planos de gestão de dados com vistas ao simplificar a minha apresentação.

A fase 2 nós organizamos os procedimentos de construção da OntoNEO em processos de governança de dados selecionados de Briney (2005), DataONE (2018) e Dias (2018). Esse último trabalho se baseia em padrões da Universidade Virginia para governança de dados.

Na fase 3 fizemos uma análise dos aspectos de qualidade e agregados ao OntoNEO em função das práticas de governança que foram adotadas em sua construção, encontramos dois resultados principais ao término do nosso estudo. O primeiro deles repousa sobre uma percepção clara dos aspectos de qualidade que a governança de dados pode proporcionar aos processos de construção de ontologias biomédicas e o segundo reforço de identificação de cinco macros processos relacionados à governança de dados e que podem ser aplicáveis a construção de ontologias biomédicas.

Então detalhando um pouquinho desses dois resultados nós temos entre os aspectos de qualidade identificados o primeiro deles repousando sobre uma premissa de que a ontologia na ser construída ela seria integrante de uma iniciativa denominada OBO Foundy é uma iniciativa internacional de construção de ontologias de alto valor de qualidade para integração de dados biométicos.

Então pra que uma ontologia se agregue a esta iniciativa ela precisa também ser construída com altos padrões de qualidade seguindo as premissas definidas por esse projeto.

Então para o alcance desse nível de qualidade nós percebemos que a professora Fernanda ela adotou padrões tecnológicos internacionais especificidades técnicas e administrativas do contexto real médico que eles vão depressivo reúso de dados de outras antologias já integrantes a iniciativa OBO Foundy. Portanto com qualidade já previamente certificada pela iniciativa ou redução de modelos de ciclo de vida para a construção de sistemas de informação da área de engenharia de

software da ciência da computação para a condução das práticas de engenharia de antologias no campo da ciência da informação o que também contribuiu para o aumento da qualidade dos artefatos final gerando.

Foi realizada uma prova de conceito que garantiu a eficiência do artefato informacional gerado no atendimento aos propósitos que motivaram sua construção. Esse modelo portanto ele é um modelo de representação do conhecimento de alta qualidade para a representação de dados biomédicos e foi disponibilizado em formato aberto em caráter permanente tendo um site próprio e ainda sendo possível o seu acesso no repositório de acesso público bio portal que também integra a iniciativa OBO Foundy paralelamente percebemo uma ampla divulgação e compartilhamento do conhecimento científico produzido pela pesquisadora.

A pesquisa também recebeu financiamentos de agências de fomento nacionais e internacionais porque ela foi realizada com uma pesquisa do tipo sanduíche, ela se realizou em parte do departamento de filosofia informática biomédica da Universidade de Buffalo e em parte aqui na escola sem essa informação da Universidade Federal de Minas Gerais.

Na sequência nós passamos ao detalhamento dos cinco macros processos que foram percebidos e que compreendem a gestão de informações sobre dados e formatos a gestão de conteúdo dos metadados e formatos a gestão de políticas para acesso, compartilhamento erros de dados a gestão de armazenamento de longo prazo e gestão de questões orçamentárias, então esse 5 macros processos eles nos permitiram é uma visão de aderência ao ciclo de vida estudado em cada um daqueles autores que já foram citados nos dando uma percepção de que ainda não tenha sido esse o propósito inicial da pesquisa realizada pela nossa colega o cuidado a meculosidade dela durante todas as fases de construção da ontologia ela permitiu uma aderência clara a ciclos de vida relevantes para a governança de dados e uma visualização de macroprocesso candidatos a estruturação de planos de gestão de dados específicos para esse tipo de pesquisa sendo assim nas nossas considerações finais temos retornar aos objetivos do nosso estudo afirmarmos que em função do volume e do valor dos resultados oriundos da pesquisa realizada pela professora doutora Fernanda Farinelli e que foi analisado em nosso estudo concluímos que a adoção de práticas de governança de dados em processos de construção de ontologias elas agregam maior qualidade aos artefatos informacionais gerados possibilita a formalização de melhores práticas para os processos de engenharia de ontologias e podem ainda fomentar pesquisas para formalização de ciclo de vida de dados ou planos de gestão de dados aplicáveis aos processos de engenharia de ontologias promovendo também avanços nas pesquisas voltadas à governança de dados.

Deixamos aqui os nossos contatos pra elucidação de possíveis dúvidas e agradecemos a atenção de todos e pela grata oportunidade participarmos do 2º WIDAT um forte abraço.

Slides da apresentação

Título: Aspectos do ciclo de vida de dados em processos de construção de ontologias biomédicas.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=22

Direito fundamental à privacidade no Brasil: tendências

Rossana Gleucy de Ávila Chagas e Carvalho[a]

Resumo: A proposta deste artigo é constatar as tendências que uma decisão do Supremo Tribunal Federal pode promover e a nova Lei Geral de Proteção de Dados Pessoais, em relação à privacidade de dados pessoais na doutrina e jurisprudência brasileiras. Para tanto foi feita uma pesquisa qualitativa nos argumentos doutrinários e jurisprudenciais utilizados pela Ministra Cármem Lúcia, relatora, na análise do mérito da Ação Direta de Inconstitucionalidade no 4.815/DF, ajuizada em 5 de julho de 2012, pela Associação Nacional dos Editores de Livros – ANEL, e considerações sobre a efetividade da Lei Geral de Proteção de Dados Pessoais. Os resultados encontrados na pesquisa apontam para a desvalorização do direito à privacidade, intimidade e identidade em relação a outros princípios e direitos tais como: a liberdade de expressão, pensamento e opinião; direito de informação; princípio da transparência na gestão pública dentre outros. A conclusão a que se chegou é a de que o panoptismo idealizado por Bentham e destacado por Foucault não está, nos dias atuais, ligado apenas a atividades estatais. Há ainda interesses corporativos ou comerciais e pessoais que vêm enfraquecendo o direito constitucional à privacidade.

Palavras-chave: Privacidade. Liberdade de expressão. Panoptismo.

Personal data privacy in Brazil: tendencies

Abstract: The objective of this article is to identify trends that a decision of the Federal Supreme Court and the General Law for Personal Data Protection could cause to the privacy into Brazilian legal doctrine and jurisprudence. For this purpose, this qualitative research took place about doctrine and jurisprudence used by the Minister Reporter Cármem Lúcia at the examination of the merits by the Direct Action of Unconstitutionality no 4.815/DF, filed on July 5th, 2012, by the Associação Nacional dos Editores de Livros – ANEL and about the effectiveness of the General Law for Personal Data Protection. The results found in this research indicate devaluation of the right privacy against other fundamental rights in Brazil, such as freedom of expression, thought, opinion, right to information, transparency in the public management, among others. The conclusion reached in this research is that the panopticon idealized by Bentham and emphasized by Foucault is not, nowadays, connected to state-activities. There are private corporate, commercial and personal interests that are weakening the constitutional right to privacy.

Keyword: Privacy. Freedom of expression. Panopticism.

a Universidade Federal de Santa Catarina (UFSC). E-mail: professoraebd@gmail.com. Currículo: http://lattes.cnpq.br/7268555128235175

1 Introdução

O direito à privacidade sofreu transformações ao longo do tempo (CANCELIER, 2017, p. 214). Do "right to be alone" (direito a ser deixado só) conceito de Brandeis (1890) até o sentido mais pragmático da concepção atual "caracterizada pela liberdade de autodeterminação informativa, isto é, a capacidade de controlar as informações pessoais pelo seu titular" (MACHADO, 2014, p. 338).

No entanto, nos dias atuais, o controle do indivíduo sobre suas informações pessoais não se apresenta como uma tarefa fácil. Os avanços das ferramentas da tecnologia da informação e da comunicação ocorridos nas últimas décadas alteraram o comportamento as relações sociais de convivência humana.

Há dois fatores jurídicos que devem especialmente ser analisados quando se pretende analisar as tendências em relação ao direito à privacidade no Brasil: o primeiro, é a promulgação da Lei Geral de Proteção de Dados Pessoais (Lei nº 13.709 de 13 de agosto de 2018), novidade no ordenamento jurídico brasileiro por tratar especificamente sobre o tema "privacidade" e que alterou o Marco Civil da Internet (Lei nº 12.965); Celso Lafer (2006, p. 241) afirma que a positivação de um direito humano por vezes exacerba os problemas práticos de sua tutela, em vez de eliminá-los, como normalmente se espera.

O segundo fator que precisa ser levado em consideração é a decisão da Suprema Corte brasileira, proferida na Ação Direta de Inconstitucionalidade – ADI nº 4815/DF, ajuizada em 5 de julho de 2012, pela Associação Nacional dos Editores de Livros – ANEL. Essa ação, levou o Supremo Tribunal Federal – STF a discutir o direito fundamental à privacidade e o processo foi relatado pela Ministra Cármem Lúcia.

Especificamente, esta ADI questionou a constitucionalidade da proibição contida nos artigos 20 e 21 do Código Civil, que exigem autorização para a publicação de biografias não autorizadas de notórias personalidades brasileiras, como se fosse uma espécie de censura privada.

A relevância jurídica desta decisão reflete-se no impacto social que dela se espera, pois o voto da relatora foi aceito por unanimidade pelos outros ministros, além disso, como é sabido, após a decisão da máxima corte brasileira, "os tribunais devem uniformizar sua jurisprudência e mantê-la estável, íntegra e coerente", conforme o art. 926 do Código de Processo Civil de 2015.

2 Objetivos

Assim, o objetivo do presente artigo é constatar as tendências em relação à privacidade, intimidade e identidade na doutrina jurídica e jurisprudência brasileiras diante da novidade na legislação (Lei de Proteção de dados pessoais) e do julgado do STF, respectivamente.

3 Procedimentos Metodológicos

Para que o objetivo supracitado fosse alcançado foi feita uma pesquisa qualitativa organizada a partir dos argumentos doutrinários e jurisprudenciais utilizados pela Ministra Cármem Lúcia, relatora da ADI nº 4815/DF e do texto da Lei Geral de Proteção de Dados no que tange aos direitos de privacidade, intimidade e identidade, em contraste com a ideia do panoptismo desenvolvido por Jeremy Bentham e destacado por Foucault.

Vale ressaltar que dezesseis entidades também se manifestaram no processo, tratando-se assim, de um colegiado de opiniões que foram consideradas pelo órgão, ouvidas as associações de escritores, órgãos públicos, universidade, etc.

No mesmo sentido, levou-se 8 anos para discutir e redigir alterações no projeto de lei que, posteriormente, gerou a Lei de Proteção de Dados Pessoais.

4. Resultados

No que tange à análise da decisão na ADI 4815/DF, os resultados encontrados na pesquisa apontam para a desvalorização do direito à privacidade, intimidade e identidade em relação a outros princípios, direitos e deveres jurídicos tais como a liberdade de expressão e liberdade de conhecimento.

Castels (1999) chama a atenção para o fato de que "a geração, processamento e transmissão de informação torna-se a principal fonte de produtividade e poder" (Castells, 1999, p.21). Não obstante, percebe-se que, ao tratar do direito de liberdade de expressão, a Ministra Cármem Lúcia compreende essas relações de poder e suas consequências para a sociedade.

Assim, a tendência no STF, e consequentemente, na jurirsprudência brasileira, é a de reforçar o caráter comunitarista dos direitos da personalidade, no bojo dos quais encontram-se o direito à privacidade e à intimidade. Segundo essa linha de pensamento, dá-se mais importância ao interesse coletivo que ao interesse "egoísta" individual.

Em relação à Lei Geral de Proteção de Dados Pessoais, a opção do legislador pátrio é seguir as diretrizes da legislação correlata na Europa, destacando princípios importantes como o princípio da finalidade, adequação, necessidade e transparência, dos quais falaremos adiante, dentre outros. Faltando porém a criação da autoridade fiscalizadora da proteção de dados.

4.1 Direito de Liberdade de Expressão (art. 5º, IV e V)

O STF entende que o direito de liberdade de expressão deve ser entendido em seu sentido amplo, como sendo a fonte do direito de liberdade de todos os outros tipos de expressão do pensamento, abarcando a liberdade de opinião atividade intelectual, artística, científica, liberdade de conhecimento e de comunicação, mas também é uma liberdade de conteúdo espiritual, como a expressão musical e da comunicação pelas artes plásticas (STF, 2015).

Ou seja, o direito à privacidade tem intrínseca relação com a liberdade. Este também é o pensamento de Jabur (2000).

Em contrapartida, citando Canotilho, a Ministra ressalta que o direito de liberdade de expressão também envolve a liberdade de profissão, de livre iniciativa econômica, de prestação de serviços e de propriedade (STF, 2015). Defendeu ainda a expressão como sendo "responsável pela construção e reconstrução de relações sociais, políticas e econômicas". É "o fio condutor de lutas e direitos fundamentais" (STF, 2015, p. 51).

O princípio da livre manifestação do pensamento, diz respeito à autonomia e ao livre desenvolvimento da personalidade do indivíduo (STF, 2015).

Numa dimensão social e política, princípio magno do Estado Democrático de Direito (STF, 2015). É condição e garantia da democracia, do pluralismo político e da tolerância. É, portanto, também, um direito político.

Cármem Lúcia, citando Wolfgang Sarlet, afirma que o direito de liberdade de expressão "assume uma espécie de posição preferencial", sem, contudo, lhe atribuir "a condição de direito absolutamente imune a qualquer limite e restrição sem se estabelecer uma hierarquia prévia entre as normas constitucionais" (STF, 2015, p.36). No entanto, a liberdade de expressão é reconhecida como que numa posição de vantagem no caso de conflito com outros bens fundamentais individuais e coletivos (STF, 2015).

Por entender as relações de poder envolvidas no exercício do direito de liberdade de expressão, a ministra entende que nem o Estado, nem particulares podem lhe impor limites, exceto quando o exercício desse direito atentar contra outros bens juridicamente protegidos ou para garantir a liberdade do outro (STF, 2015).

Assim, "conflitos entre particulares podem atingir direitos fundamentais pela desproporcionalidade, ou seja, por abuso ou exorbitância do poder exercido por um com relação a outro ou em contrariedade ao interesse público" (STF, 2015, p.58). Citando julgado da Corte Europeia de Direitos Humanos, a Ministra adverte que "toda formalidade, condição, restrição ou punição imposta na matéria deve ser proporcional ao fim legítimo buscado" (STF, 2015, p.62).

A Corte Interamericana, porém, continua a Ministra, "considerou conteúdo ao direito à liberdade de expressão e de pensamento, por ser formado tanto pelo direito de expressar o próprio pensamento (dimensão individual), quanto pelo direito de buscar, receber e difundir informações sobre qualquer matéria (dimensão social)".

4.2 Direito à informação (art. 5º, XIV)

O direito à informação é também é considerado constitucionalmente fundamental e se refere à proteção a se obter e divulgar informação sobre dados, qualidades, fatos de interesse da coletividade, ainda que sejam assuntos particulares, porém com expressão ou de efeitos coletivos.

Da liberdade de informação depende a opinião pública que se baseiam, exatamente, em dados que precisam ser públicos sobre pessoas que exercem funções públicas, por exemplo, no entanto, citando Agostini, a Ministra entende que na sociedade atual, apresenta-se diluída a "fronteira entre privado e político, ao ponto de se tornarem quase irreconhecíveis" (STF 2015, p. 74).

Citando Canotilho, a Ministra Cármem Lúcia, defende que em respeito à intimidade existem instrumentos jurídicos privilegiados de garantia tais como o direito à inviolabilidade do domicílio e da correspondência, da proibição de tratamento informático de dados referentes à vida privada, bem como o sigilo profissional, reserva confidencial para rostos e papéis pessoais e que é recente a constitucionalização expressa da inviolabilidade da intimidade, privacidade, honra e imagem (STF, 2015).

A proteção aos direitos à intimidade e privacidade foram deixados a cargo do legislador infraconstitucional: Código Penal Brasileiro, nos artigos 138 a 145, que versam sobre os crimes contra a honra; Lei nº 12.527/2011, Lei de Acesso à Informação (STF, 2015) e a Lei Geral de Proteção de Dados Pessoais, Lei nº 13.709/18, a qual foi aprovada recentemente, em 14 de agosto, 2018, dentre outras.

Em seu voto, a Ministra faz duas observações importantes sobre a constitucionalidade das normas questionadas nesta ação: (1) Definição de seu conteúdo na forma protegida no sistema

jurídico fundamental brasileiro e de sua eficácia social; (2) A definição desse direito não é a mesma para todos, mas altera-se segundo a escolha feita pelo sujeito de direito a submeter-se a atividade que: a) seja regida pela transparência referente às instituições estatais, visando o controle que os cidadãos exercem sobre o governo; b) aqueles cuja condição profissional dependa do público para o seu desempenho com êxito; c) extraia ou retire dos cidadãos, pelo exercício de sua função ou atividade, os ganhos materiais, profissionais ou de reconhecimento, pelo que há de ser por eles conhecido.

Resumindo suas proposições, a Ministra afirma que em certos casos a pessoa se sujeita a ser conhecida e reconhecida pelo público. Assim, não se pode, portanto, considerar da mesma forma alguém que nada quer ou se extrai do público em sua condução de vida.

Especificamente em relação à questão da publicação das biografias, após tecer vários comentários sobre a importância histórica e social das mesmas, a Ministra afirma que a notoriedade exige o pagamento de um preço que "é fixado pela extensão da fama", que normalmente é buscada. Mesmo quando não é buscada a fama cobra seu preço que é o "reconhecimento público que se traduz em exposição do espaço particular", no qual todos querem adentrar (STF, 2015, p.87). No entendimento da ministra deve ser defendida a vida do outro, mas a curiosidade das pessoas também precisa ser satisfeita e para isso existe o trabalho do biógrafo (STF, 2015, p.99).

De qualquer forma, garante Cármem Lúcia, há sempre um espaço de indevassabilidade e segredo que compõe o íntimo de uma pessoa que não é pra ser levado ao conhecimento do público.

O passado compõe o que a pessoa se torna, a interpretação plural, advinda de variadas biografias é que podem levar gerações futuras a chegar à conclusão sobre o que ocorreu, porque e como se repetir (se positivo) ou evitar (episódios negativos).

No âmbito da proteção de dados, a exploração de dados pessoais ficará limitada por três princípios norteadores: princípio da finalidade (aquela que foi informada ao titular das informações); o princípio da minimização da coleta (só poderão ser coletados os dados realmente necessários para que seja atingida a finalidade); e, por fim, o princípio da retenção mínima (os dados deverão ser excluídos após atingirem sua finalidade).

Tendo em vista porém, que foi vetado o artigo que criava uma agência específica para fiscalização da aplicação da lei (Autoridade Fiscalizadora), Schreiber (2018), entende serem equivocadas as propostas no sentido de atribuir esse poder de fiscalização para órgãos de segurança. O autor destaca ainda que a criação de uma Autoridade de Proteção de Dados seria fundamental para que a lei cumprisse seu papel efetivamente, a fim de criar uma cultura de privacidade.

5 Considerações Finais

Por ser uma decisão unânime na Suprema Corte brasileira, sobre uma ação direta de inconstitucionalidade dos artigos 20 e 21 do Código Civil pátrio, a relevância jurídica traz importante impacto na jurisprudência e doutrina que versam sobre o tema no Brasil, as quais precisam se ajustar coerentemente, pela necessária estabilidade jurídica, conforme dispõe o Código de Processo Civil de 2015, em seu artigo 926.

Nos dias atuais, as facilidades das tecnologias da informação e da comunicação fazem com que determinados grupos de pessoas encontrem vantagens no relacionamento com o público em geral.

Mesmo que "a notoriedade torne a pessoa alvo de interesse público", as informações que extrapolem as linhas da quadra de jogo ou desempenho, a busca, produção e divulgação de informações não é ilegítima, "nem pode ser cerceada sob o argumento de blindar-se a pessoa com a inviolabilidade constitucionalmente assegurada" (STF, 2015, p.94).

Por um lado, as pessoas se beneficiam de câmeras para sua própria segurança; por outro, essa câmera também pode ser responsável pela captação de outras imagens que não deveriam, mas são divulgadas para o público em geral em questão de segundos.

Por todo o exposto, a Ministra destacou que é preciso saber se preservar, e que pessoas podem vir a serem sujeitos de estudos, pesquisas, obras, nas quais suas vidas são relatadas e os escritos produzidos e divulgados, independente de autorização da narrativa e das versões do autor da produção.

Assim, o estudo traz como conclusão, a partir da apresentação dos argumentos utilizados pela Ministra Cármem Lúcia, que o panoptismo idealizado por Bentham e destacado por Foucault, em seus estudos sobre a disciplina e o controle social, não é, nos dias atuais, um mecanismo de poder que beneficia apenas atividades de vigilância do aparelho estatal; Há interesses corporativos ou comerciais (lucro) e pessoais que mitigam o direito constitucional à privacidade, dessa forma, com a promulgação da Lei Geral de Proteção de Dados Pessoais, que entrará em vigor somente em fevereiro de 2020, os usuários poderão ter um controle maior sobre esse tipo de processamento de seus dados pessoais, com finalidade de lucro.

Assim, atinge-se o objetivo deste trabalho constatando-se que a tendência jurídica e jurisprudencial pelo que se depreende dos argumentos expressos no julgamento da Ação Direta de Inconstitucionalidade, ora estudada, é a de que o direito de privacidade e de intimidade seja considerado menos importante que os direitos de liberdade de expressão e liberdade de conhecimento.

Por último, cabe ressaltar que muito se discutirá ainda sobre as disposições da Lei Geral de Proteção de Dados Pessoais, até que está entre em vigor (fevereiro/2018). Assim, além do estabelecimento de uma agência fiscalizadora para a proteção dos dados pessoais, também seria útil que outras pesquisas acompanhassem os desdobramentos do Regulamento Geral de Proteção de Dados da Europa, que já entrou em vigor em maio de 2018, e que exerceu forte influência na elaboração da lei brasileira que versa sobre o mesmo tema.

Referências

BAUMAN, Zygmunt. **Vigilância Líquida**. Rio de Janeiro: Zahar, 2014.

BENTHAM, Jeremy. **O Panóptico**. 2ª ed. Belo Horizonte: Autêntica, 2008.

BRASIL. **Código de Processo Civil**. Senado Federal: Centro Gráfico, 2015.

_____. **Código Civil**. Senado Federal: Centro Gráfico, 2015.

_____. Constituição (1988). **Constituição da República Federativa do Brasil.** Senado Federal: Centro Gráfico, 1988.

_____. Supremo Tribunal Federal, **Ação Direta de Inconstitucionalidade** nº 4.815. Relatora Ministra Cármem Lúcia Antunes Rocha, j. 10-6-2015, P, DJE de 1º-2-2016.

CANCELIER. Mikhail Vieira de Lorenzi. O Direito à Privacidade hoje: perspectiva histórica e o cenário brasileiro. **Revista Sequência (Florianópolis)**, n. 76, p. 213-240, ago. 2017.

CASTELLS, Manuel. **A sociedade em rede.** São Paulo: Paz e Terra, 2003.

FOUCAULT, Michel. **Vigiar e Punir: nascimento da prisão.** Petrópolis: Vozes, 1987.

JABUR, Gilberto Haddad. **Liberdade de pensamento e direito à vida privada: conflito entre direitos da personalidade**. São Paulo: RT, 2000.

LAFER, Celso. **A reconstrução dos direitos humanos**. São Paulo: Companhia das Letras, 2006.

SCHEIBER, Anderson. **Proteção de Dados Pessoais no Brasil e na Europa**. Jornal Carta Forense, Colunas, Ensaio, 2018. Disponível em < http://www.cartaforense.com.br/conteudo/colunas/protecao-de-dados-pessoais-no-brasil-e-na-europa/18269> Acesso em 19 nov. 2018.

VIEIRA, Tatiana Malta. **O direito à privacidade na sociedade da informação: efetividade desse direito fundamental diante dos avanços da tecnologia da informação**. Dissertação de Mestrado no curso de pós-graduação stricto sensu em Direito, Estado e Sociedade: Políticas Públicas e Democracia. Universidade de Brasília, 2007.

WEIMANN, Gabriel. **Terror on the Internet: The New Arena**, the New Challenges, Special Report, United States Institute of Peace, Washington-DC, 2004.

Vídeo da apresentação

Título: Direito fundamental à privacidade no Brasil: Tendências.

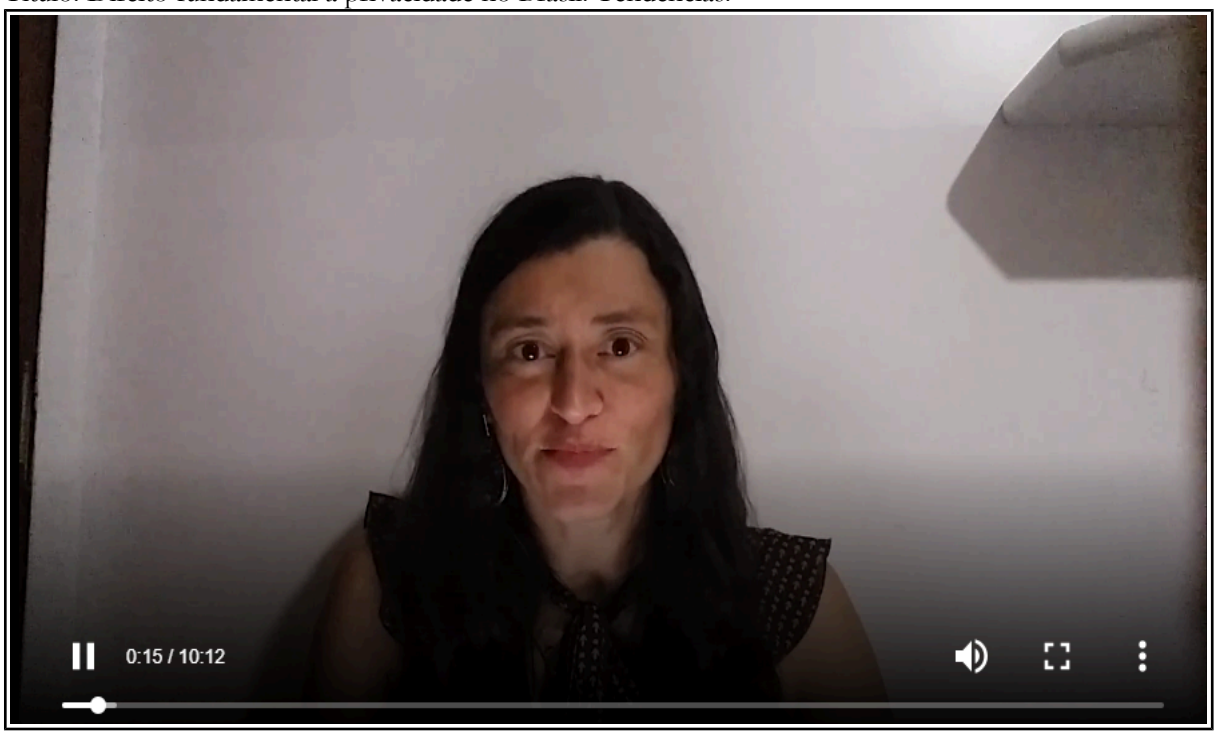

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=23

Transcrição da apresentação

Olá pessoal meu nome é Rosana eu sou aluna do mestrado em ciência da informação da Universidade Federal de Santa Catarina eu e o meu orientador Márcio Matias escrevemos um artigo pra compartilhar com a turma do WIDAT (2018) o Workshop de Informação, Dados e Tecnologia.

O artigo que descrevemos ele fala sobre o direito de privacidade no Brasil tendências, nesse artigo a gente conversa especificamente sobre a ação direta de inconstitucionalidade número 4815 que é aquela ação direta de constitucionalidade que falava sobre a proibição contida nos artigos 20 e 21 do código civil é no sentido de exigir uma autorização para a publicação de biografias não autorizadas e notórias personalidades prazeres anel ela então argumentou o seguinte: se eu escrevo uma obra um artigo e alguém precisou autorizar isso é censura privada e também vamos comentar rapidamente sobre a lei geral de proteção de dados pessoais é uma lei que alterou o marco civil da internet uma lei cuja lei correlata na Europa que versa sobre o mesmo assunto lá já está em vigor mas a nossa que ela foi promulgada foi publicado agora em agosto de 2018 mais só vai entrar em vigor em 2020.

Então esse assunto tem feito alterações no direito o mundo jurídico porque o Direito precisa proteger a pessoa o indivíduo que quer ter o controle sobre suas informações o que não tem sido uma tarefa fácil nas últimas décadas em virtude mesmo dos avanços das ferramentas da tecnologia da informação e da comunicação que alteraram o comportamento das relações sociais e a convivência humana.

Então a lei 4815 ela foi ajuizada pela ANEL, a ministra Cármen Lúcia foi relatora e eu seja lá ela dá sua opinião e todos os rapazes relatório em e juízes julgam se vão acompanhar ou não o voto do relator e nesse caso é por unanimidade e se for aceito aí nós temos uma orientação do próprio código de processo civil de 2015 que diz que os tribunais devem formalizar a jurisprudência manteve estável e íntegra, com ele, ou seja, essa decisão após essa decisão os outros julgados deverão pelo menos considerar esse julgado nesse sentido aqui de manter a jurisprudência uniformizada estável.

A ministra destacou que é preciso saber se preservar, ou seja, ainda não um demonstrou o protecionismo para consulta na internet pelo contrário ela diz que as pessoas têm que tomar cuidado porque podem ser sujeitos de estudos de pesquisas de obras nas quais as suas vidas são relatadas nos escritos produzidos e divulgados independente da organização da narrativa e das versões voltou na produção.

Então existe aqui uma comparação com as câmeras porque as pessoas se beneficiam das câmeras para sua própria segurança e por outro lado essa câmera e pode ser responsável pela captação de outras imagens que não deveriam mas são divulgadas para o público em geral em questões de segundos, então o Supremo Tribunal Federal disse que a ação da ANEL é procedente, ou seja, é preciso dar uma interpretação conforme os artigos 20 e 21 do código civil, ou seja, não foram revogados parcial nem totalmente esses artigos só precisam ser interpretados conforme a constituição, ou seja, eles têm que estar em consonância com o direito com os outros direitos fundamentais é defendida também pela constituição a liberdade de pensamento de liberdade de expressão de criação artística de produção científica.

Então declara a decisão declara inexigível o consentimento da pessoa biografado relativamente a obras biográficas literárias e audiovisuais, sendo por igual diz necessária autorização de pessoas retratadas como coadjuvantes dos familiares do cônjuge que está sendo retratado aquela biografia.

Há outro aspecto importante da decisão é que se reafirma o direito à inviolabilidade da intimidade nos seguintes termos intimidade privacidade honra e imagem das pessoas nos termos do inciso 5º e 10º do artigo 5º da constituição da república, ou seja, se nessa publicação houver transgressão aos princípios a esses outros e direitos, violabilidade, intimidade privacidade honra à imagem da pessoa é cabível indenização reparação por meio da organização.

Então a tendência que se percebe é que quando houver uma tensão entre a liberdade de expressão e o direito à informação, esses dois é direitos em contraste com gesso da personalidade dos quais fazem parte do direito a privacidade e intimidade e identidade imagem e etc vai prevalecer a liberdade de expressão o direito à informação vão prevalecer.

O direito de privacidade intimidade, por exemplo, ficam mitigados são considerados menos importantes na tendência tem de forma quando houver esse tipo de conflito a tendência é que os princípios da privacidade e intimidade sejam considerados menos importantes.

A notoriedade torna a pessoa alvo de interesse público isso é normal o ministro disse que é normal que as pessoas precisam proteger. Mesmo assim as informações que se a polar em as regras são passíveis de indenização determinados grupos de pessoas então que encontram vantagens no relacionamento com o público geral precisam sempre haver precisam tomar cuidado com que elas estão publicando.

Nós vemos então aqui que uma reflexão explorado destacado provocou aqui não está sendo explorado pelo estado como é esperado nem naquela época mas é pelas corporações por interesses comerciais pelas empresas interesses privados, esses interesses também estão mitigando direito constitucional à privacidade e aí entra a lei geral de proteção de dados pessoais que traz toda uma política de proteção abre uma cidade e que dá inclusive diretrizes para as pessoas se protegerem porém os usuários precisam ficar atentos porque essa lei ainda não está em vigor as empresas estão se adaptando a isso aí a lei entrará em vigor em 2020 então é recomendável que haja outros estudos no sentido de acompanhar a implementação da legislação correlata na Europa legislação que versa sobre o mesmo tema na Europa pra quê pra que aqui a gente possa garantir é a preservação desses direitos. Por exemplo no Brasil não está prevista não tem ainda uma agência que regule a fiscalização que fiscalize a implementação da lei e isso é muito importante.

Bom agradeço a atenção de todos esperam tenho todos um grande evento e até a próxima se Deus quiser.

Informação e privacidade na Lei Geral de Proteção de Dados

Rosilene Paiva Marinho de Sousa[a], Fernando Antônio de Vasconcelos[b] e Marckson Roberto Ferreira de Sousa[c]

Resumo: As Tecnologias da Informação e Comunicação têm possibilitado a criação de uma grande quantidade de dados que necessitam ser devidamente controlados para a garantia da proteção dos direitos fundamentais da pessoa humana. O presente trabalho tem como escopo analisar a relação entre informação e privacidade no âmbito da Lei Geral de Proteção de Dados. Reflete sobre os instrumentos legais de amparo a proteção de dados no âmbito do ordenamento pátrio. Busca discorrer sobre os contornos que envolvem a referida lei na proteção da privacidade e o acesso à informação considerando o papel do consentimento como requisito para tratamento dos dados pessoais. Como metodologia adotar-se-á pesquisa bibliográfica e exploratória. Como resultados, examina como a referida lei coloca o acesso à informação como instrumento que permite a privacidade se manter como ponto central para a proteção dos direitos fundamentais dos indivíduos, concluindo que o controle torna-se instrumento de garantia dos direitos de liberdade, intimidade e privacidade.

Palavras-chave: Informação. Privacidade. Lei Geral de Proteção de Dados Pessoais.

Information and privacy in the General Law of Data Protection

Abstract: Information and communication technologies have made it possible to create a large amount of data that needs to be properly monitored to guarantee the protection of the fundamental rights of the human Person. The present work is scoped to analyse a relationship between information and privacy under the general law of data Protection. It reflects on the legal instruments of protection of parental ordination. It seeks to discuss the contours that involve the law in the protection of privacy and access to information considering the role of consent as a requirement for the treatment of personal data. As a methodology, bibliographical and exploratory research will be adopted. As a result, it examines how an law places access to information as an instrument that allows a privacy to remain as a central point for the protection of the fundamental rights of individuals, concluding that control becomes a guarantee instrument the rights of freedom, intimacy and privacy.

Keyword: Information. Privacy. General Data Protection Law.

a Centro Universitário de João Pessoa (UNIPE). E-mail; adv.rpmarinho@gmail.com. Currículo: http://lattes.cnpq.br/4465533418771961

b Centro Universitário de João Pessoa (UNIPE). E-mail: fer.mengo@uol.com.br. ORCID: https://orcid.org/0000-0001-8634-9921. Currículo: http://lattes.cnpq.br/8223857460283833

c Universidade Federal da Paraíba (UFPB). E-mail: mrck.sousa@gmail.com. ORCID: https://orcid.org/0000-0003-2001-1631. Currículo: http://lattes.cnpq.br/0221265788966967

1 Introdução

As transformações advindas com as Tecnologias da Informação e Comunicação impactaram a forma de armazenar, processar e transmitir informações mudando rapidamente a vida de bilhões de pessoas. A proteção da privacidade tem sido uma preocupação constante em face do volume de dados produzidos com a massificação da utilização dos computadores.

O aumento do volume de dados tem proporcionado uma assimetria informacional em que ocorre a redução do conhecimento do cidadão sobre o uso de seus dados e dos efeitos advindos desse uso.

A dicotomia entre acesso à informação e a privacidade tem sido tema de discussões quanto aos contornos e limites de sua proteção. Surge dessa forma, a necessidade de disciplinar como e quando disponibilizar informações pessoais a terceiros. Nesse sentido, o sigilo posto como uma barreira ao acesso à informação passa a ser substituído pelo controle de seu acesso, permitindo assim que a privacidade possa se manter como ponto central para a proteção dos direitos fundamentais dos indivíduos, chegando-se ao arremate de que o controle torna-se instrumento de garantia dos direitos de liberdade, intimidade e privacidade.

Dessa forma, a relevância deste trabalho surge ao levar em consideração que a proteção sobre dados pessoais possa contribuir no controle do armazenamento, processamento e transmissão de informações, resguardando assim direitos fundamentais.

2 Objetivos

Este trabalho tem como objetivo analisar a relação entre informação e privacidade no âmbito da Lei Geral de Proteção de Dados. Para isso, busca ainda refletir sobre os instrumentos legais de amparo a proteção de dados no âmbito do ordenamento pátrio, examinando contornos que envolvem a referida lei na proteção da privacidade e o acesso à informação, considerando o papel do consentimento como requisito para tratamento dos dados pessoais.

3 Procedimentos Metodológicos

Do ponto de vista metodológico, trata-se de uma pesquisa bibliográfica e exploratória. A pesquisa bibliográfica consiste na seleção de informações bibliográficas (livros, artigos científicos, documentos, dentre outros), que possam contribuir para explicar o objeto de investigação (HENRIQUES; MEDEIROS, 2017, p.107). Já a pesquisa exploratória, segundo Severino (2007), visa levantar informações sobre um determinado objeto, delineando o campo de trabalho, bem como as condições de manifestação desse objeto.

4 Resultados

Nos resultados são expostos discussões sobre como se apresentam a proteção de dados no ordenamento pátrio, seguido da análise da proteção da privacidade e do acesso à informação, destacando a importância do consentimento para o tratamento dos dados pessoais.

4.1 A Proteção aos Dados Pessoais no Ordenamento Pátrio

No panorama do ordenamento jurídico brasileiro que antecedia a regulação da proteção de dados, constatava-se a sua proteção por meio das garantias constitucionais da liberdade, intimidade e dignidade da pessoa humana, estando a privacidade na esfera dessas garantias.

A Constituição Federal (CF) considera invioláveis a vida privada, e a intimidade em seu artigo 5º, inciso X, bem como a interceptação de comunicações telefônicas, telegráfica ou de dados, no mesmo artigo, inciso XII. Ainda em âmbito constitucional, destacam-se os direitos de acesso, retificação e complementação de informações, com previsão no artigo 5º, incisos XIV e XXXIII (BRASIL,1988).

No âmbito infraconstitucional, destacavam-se a proteção de dados em leis específicas não havendo até então, uma proteção geral exclusiva sobre o tema.

Dentre essa proteção, o Código de Defesa do Consumidor, em seu artigo 43 determina a proteção do consumidor em vários aspectos envolvendo às informações pessoais presentes em banco de dados e cadastros dos consumidores (BRASIL, 1990). Ainda no âmbito da proteção do consumidor, a Lei do Cadastro Positivo de nº 12.414/11, estabeleceu regras a partir de princípios de proteção de dados pessoais para tratamento de dados financeiros para formação de histórico de crédito (BRASIL, 2011a).

O Habeas Data foi regulado pela Lei nº 9.507/97, tendo como objetivo de garantir a retificação de dados pessoais em banco de dados de entidades governamentais ou de caráter público (BRASIL, 1997).

Outro instituto que pode ser citado, diz respeito à Lei de Acesso à Informação que em seu artigo 31, trouxe regras específicas para proteção de dados pessoais (BRASIL, 2011b).

A Lei nº 13.709/18 surge como uma Lei Geral de Proteção de Dados pessoais (LGPD), possibilitando a integração da proteção à personalidade de forma mais adequada (BRASIL, 2018).

Hodiernamente, a proteção de dados pessoais está presente em mais de 120 países, inclusive no Brasil, conforme apresentado na figura 1.

Figura 1 – Lei de Proteção de dados no mundo.

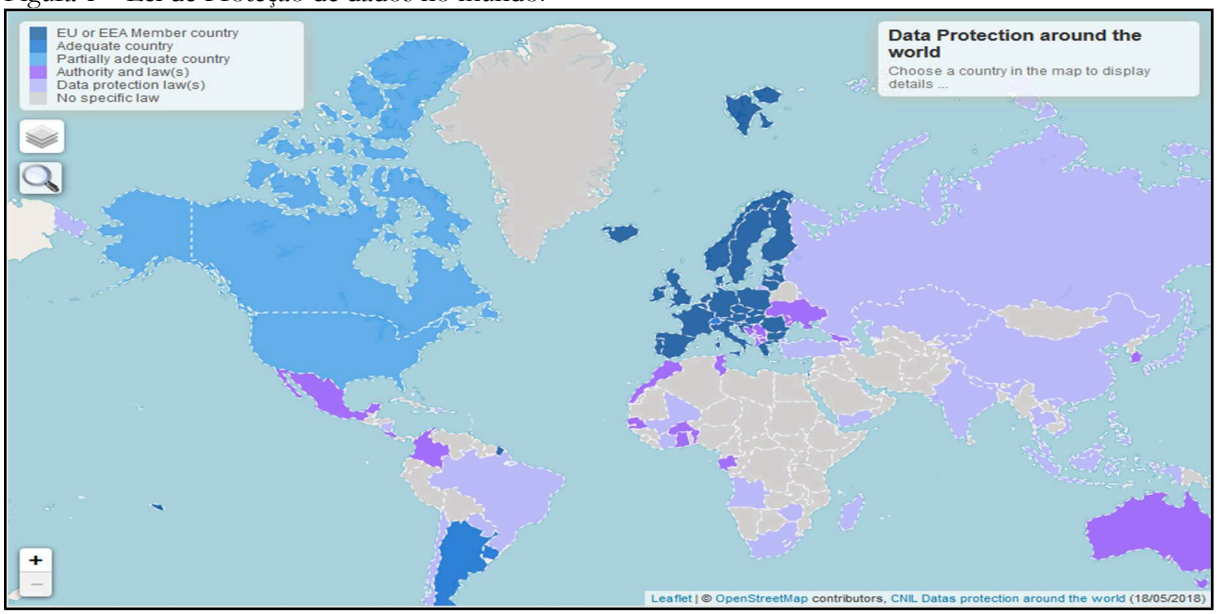

Fonte: CNIL (2018, online).

Editada no contexto do Regulamento Geral de Proteção de dados da União Europeia, a LGPD tem por objetivo proteger os direitos fundamentais de liberdade, privacidade e o livre

desenvolvimento da personalidade da pessoa natural. A referida lei visa regular o tratamento de dados pessoais compreendendo este, como toda operação realizada com dados desde a coleta, perpassando pelo acesso, uso, transmissão, processamento, armazenamento e eliminação, conforme previsão do artigo 5º, inciso X, CF (BRASIL, 1998). Essa lei, busca ainda estabelecer regras sobre o tratamento de dados pessoais pelas empresas e pelo poder público, fixando limites para tal.

O dado pessoal constitui aquelas informações relacionadas à pessoa natural, tendo como fundamentos a previsão do artigo 2º (BRASIL, 2018), que envolvem entre outros, o respeito à privacidade; a autodeterminação informativa; a liberdade de expressão, de informação, de comunicação e de opinião.

Os agentes de tratamento dos dados pessoais são definidos pela lei em seu artigo 5º, ao conceituar as figuras do controlador, operador e do encarregado (BRASIL, 2018). Por controlador, conforme exposto no artigo 5º, inciso VI, compreende-se como "[…] pessoa natural ou jurídica, de direito público ou privado, a quem competem as decisões referentes ao tratamento de dados pessoais". O operador, conforme o inciso VII, do mesmo artigo, compreende a "[…] pessoa natural ou jurídica, de direito público ou privado, que realiza o tratamento de dados pessoais em nome do controlador". E, a figura do encarregado, prevista no inciso VII, constituída pela "[…] pessoa natural, indicada pelo controlador, que atua como canal de comunicação entre o controlador e os titulares e a autoridade nacional" (BRASIL, 2018, online).

A referida lei apresenta como princípios que devem ser aplicados no tratamento dos dados pessoais a previsão do artigo 6º, estabelecendo pelo princípio da finalidade, que o referido tratamento deve obedecer a propósitos legítimos, específicos e informados ao titular dos dados; o princípio da necessidade exige que o tratamento esteja limitado à abrangência de dados pertinentes, proporcionais e não excessivos em relação às finalidades propostas; o princípio da qualidade dos dados está atrelado à garantia de exatidão, clareza, relevância e atualização dos dados ao seu titular; a transparência também se trata de um princípio que garante o acesso a informações claras, precisas e de forma fácil. Pode-se destacar que os contornos objetivos da LGPD, pressupõem o crescimento exponencial da dimensão coletiva da privacidade em que qualquer cidadão está exposto a danos em sua privacidade pelo uso ilícito de dados pessoais.

4.2 Proteção da privacidade e acesso à informação

A utilização de conceitos que envolvem dados e informações exige uma análise sobre a definição dos mesmos devendo ser compreendidos em suas particularidades.

Segundo Le Coadic (1996), os dados consistem numa forma de representação composta da informação codificada, que permite colocá-las sobre o processamento eletrônico. Os dados podem ser considerados como um conjunto de fatos distintos e objetivos, quantificáveis e qualificáveis, em que sozinhos e independentes não conduzem a nenhuma interpretação.

Quanto à informação, a sua criação depende da compreensão dos dados e da atribuição de significado aos mesmos. Segundo Capurro (2003) não há uma definição única sobre o seu significado, sendo assim de caráter polissêmico. Essa polissemia, permite compreendê-la pelo viés de noção básica, que segundo Capurro e Hjørland (2007), a noção de que se deve ter em mente é que a informação corresponde ao que é informativo para uma determinada pessoa, e o que é

informativo depende das necessidades interpretativas e habilidades do indivíduo. Dessa forma, Machlup e Mansfield (1983) já assinalavam que a informação envolve indivíduos transmitindo e recebendo mensagens no contexto de suas ações possíveis.

Estabelecida a diferença entre dado e informação, torna-se necessário evidenciar que as tecnologias da informação e comunicação, têm possibilitado a disponibilidade de dados pessoais em grande volume, o que reforça a vulnerabilidade dos cidadãos frente a violação dos seus direitos fundamentais de liberdade, privacidade e do desenvolvimento da pessoa natural.

Praticamente, em toda atividade realizada pelos indivíduos há produção de dados, mesmo que de forma indireta. Os dados pessoais são considerados atualmente como o principal insumo da economia, pois podem ser tratados e valorados economicamente.

Atualmente, tem se tornado frequente os casos de vazamento de dados por meio de redes sociais, sendo mais evidente o caso do Facebook, em que houve vazamento de dados de 87 milhões de usuários pela empresa Cambridge Analítica (FOLHA DE SÃO PAULO, 2018).

O que ocorre na prática trata-se de uma assimetria informacional em que o aumento da quantidade de dados reduz o conhecimento dos cidadãos principalmente sobre o uso de seus próprios dados.

Nesse caso, a LGPD surge para favorecer o controle do cidadão sobre seus dados. Pode-se dizer que a LGPD abandona a ideia do sigilo ao acesso à informação, pois este constitui paradigma de exclusão. Já a proteção de dados, embora pareça paradoxal, tem como uma de suas principais funções proporcionar segurança para que informações pessoais circulem adequadamente. Para isso, torna o uso do dado pessoal legal, ao buscar estabelecer várias instâncias de controle de forma responsável e tutelada, proporcionando meios claros e seguros para a sua proteção.

Nesse sentido, a proteção da privacidade fica ligada ao controle sobre os dados pessoais, destacando-se o dever de informar, por parte das empresas que lidam com os dados, de forma clara e transparente, sobre o que fazem com os mesmos, como um direito do titular. Por outro lado garante a autodeterminação informativa, como forma do titular decidir o que, quando e como devem ser utilizados os seus dados.

4.3 O consentimento no tratamento de dados pessoais

Como requisito considerado mais importante para o tratamento dos dados pessoais está o consentimento do titular, previsto no inciso I do artigo 7º (BRASIL, 2018). O consentimento implica na permissão do titular dos dados para que alguém possa coletá-los e tratá-los.

De acordo com o artigo 5º, inciso XII, da LGPD, o consentimento constitui manifestação livre, informada e inequívoca, pela qual o titular concorda com o tratamento de seus dados para determinada finalidade. O referido conceito de consentimento no âmbito da LGPD inova ao utilizar o termo inequívoco, ao referir-se a possibilidade de que o mesmo possa ser auditável, uma vez que, segundo Vancim e Neves (2015), no âmbito do Marco Civil da Internet, exige-se que o consentimento seja livre, expresso e informado, conforme exposto em seu inciso VII (BRASIL, 2014).

No artigo 7º da LGPD determina-se que o consentimento deverá ser fornecido por escrito ou por outro meio que demonstre a manifestação inequívoca de vontade do titular. Além disso, a

LGPD exige que caso o fornecimento seja realizado de forma escrita, deverá ser realizada por meio de cláusula destacada das demais cláusulas contratuais.

Caso exista alguma dúvida sobre a realização do consentimento por parte do titular, cabe ao controlador o ônus da prova de que o consentimento foi obtido em conformidade com a Lei.

No caso de vício de consentimento, o tratamento de dados pessoais resta vedado, sendo considerado nulo caso as informações fornecidas ao titular tenham conteúdo enganoso ou abusivo, e não se apresente de forma clara e inequívoca. As autorizações genéricas para o tratamento de dados pessoais também são consideradas nulas.

No caso de mudança na finalidade do consentimento não compatível com o original, o controlador deverá informar previamente ao titular sobre as mudanças de finalidade. Nesse caso, o titular poderá revogar o consentimento a qualquer momento mediante manifestação expressa, de forma gratuita e de modo facilitado caso discorde das alterações.

No caso de compartilhamento dos dados pessoais com outros controladores deverá obter consentimento específico do titular para esse fim.

Pode-se dizer que o controle por meio do consentimento do titular, torna-se instrumento de garantia dos direitos de liberdade, intimidade e privacidade, uma vez que o consentimento possibilita a mudança de eixo da estrutura da privacidade constituída pelo cidadão, informação e segredo, para o eixo da tríade cidadão, informação e controle.

A LGPD além de possibilitar a proteção da privacidade no uso da tecnologia, tem como uma de suas principais funções proporcionar segurança para que informações pessoais possam ser devidamente disseminadas. Nesse sentido, o consentimento, torna-se o aspecto mais proeminente para o tratamento dos dados pessoais, pois a circulação sobre o processamento, transmissão e disseminação dos dados e informações dependem da vontade do titular.

O direito à liberdade, à privacidade e ao livre desenvolvimento da pessoa natural, assume novos contornos. Segundo Rodotá (2008, p. 15), a privacidade deve ser considerada também como o direito do cidadão de manter o controle sobre suas próprias informações e de como deve ser definida sua própria esfera particular. Nesse sentido, a ideia passa a ser fortalecida pela LGPD, pois, possuem como fundamento a autodeterminação informativa, que permite ao cidadão definir como seus dados e informações devem ser tratados e disseminados.

4 Considerações Finais

A discussão sobre proteção de dados pessoais não se considera nova. Vários países já possuem uma lei efetiva de proteção de dados ou estão em processo de implementação.

No Brasil, a LGPD surge num momento em que a atenção está voltada para a efetivação de garantias constitucionais de liberdade, privacidade e desenvolvimento da pessoa humana. Apesar da existência de várias normas que tratam da proteção de dados, surge a necessidade de estabelecer o diálogo das fontes para que os referidos institutos sejam alinhados e a LGPD possa ter efetividade prática.

Restou claro que a proteção da privacidade também tem como uma de suas principais funções proporcionar segurança para que informações pessoais possam ser disseminadas adequadamente.

O papel do consentimento torna-se o aspecto mais relevante para o tratamento dos dados pessoais, pois a circulação sobre o processamento, transmissão e disseminação dos dados e informações do titular dependem de sua vontade.

Dessa forma, o acesso à informação por meio do controle da LGPD permite a privacidade se manter como ponto central para a proteção dos direitos fundamentais dos indivíduos, indicando que o controle torna-se instrumento de garantia dos direitos de liberdade, intimidade e privacidade.

Nesse sentido, os objetivos propostos neste trabalho foram alcançados por ter conseguido apresentar uma visão sobre como a privacidade e o acesso à informação coadunam para a efetivação das garantias constitucionais.

Referências

BRASIL. Constituição (1988). **Constituição da República Federativa do Brasil**. Brasília, DF: Senado Federal: Centro Gráfico, 1988, 292 p.

BRASIL. **Lei nº 8.078**, de 11 de setembro de 1990. Dispõe sobre a proteção do consumidor e dá outras providências. Disponível em: <http://www.planalto.gov.br/ccivil_03/LEIS/L8078.htm>. Acesso em: 6 out. 2018.

BRASIL. **Lei nº 9.507**, de 12 de novembro de 1997. Regula o direito de acesso a informações e disciplina o rito processual do *habeas data*. Disponível em: <http://www.planalto.gov.br/ccivil_03/LEIS/L9 507.htm>. Acesso em: 6 out. 2018.

BRASIL. **Lei nº 12.414**, de 9 de junho de 2011. 2011a. Disciplina a formação e consulta a bancos de dados com informações de adimplemento, de pessoas naturais ou de pessoas jurídicas, para formação de histórico de crédito. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/L12414.htm>. Acesso em: 6 out. 2018.

BRASIL. **Lei nº 12.527**, de 18 de novembro de 2011. 2011b. Regula o acesso a informações previsto no inciso XXXIII do art. 5o, no inciso II do § 3o do art. 37 e no § 2o do art. 216 da Constituição Federal; altera a Lei no 8.112, de 11 de dezembro de 1990; revoga a Lei no 11.111, de 5 de maio de 2005, e dispositivos da Lei no 8.159, de 8 de janeiro de 1991; e dá outras providências. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12527.htm>. Acesso em: 6 out. 2018.

BRASIL. **Lei nº 12.965**, de 23 de abril de 2014. Estabelece princípios, garantias, direitos e deveres para o uso da Internet no Brasil. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2014/lei/l12965.htm>. Acesso em: 6 out. 2018.

BRASIL. **Lei nº 13.709**, de 14 de agosto de 2018. Dispõe sobre a proteção de dados pessoais e altera a Lei nº 12.965, de 23 de abril de 2014 (Marco Civil da Internet). Disponível em:

<http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13709.htm>. Acesso em: 6 out. 2018.

CAPURRO, R. Epistemologia e Ciência da Informação. In: Encontro Nacional de Pesquisa em Ciência da Informação – Enancib, 5., 2003, Belo Horizonte. **Anais…** Belo Horizonte: ECI/UFMG, 2003.

CAPURRO, R; HJØRLAND, B. O conceito de informação. **Perspectivas em Ciência da Informação**. Belo Horizonte, v. 12, n. 1, p. 148-207, jan./abr. 2007.

CNIL. **Protéger les données personnelles, accompagner l'innovation, préserver les libertés individuelles**. Data protection around the world. Disponível em: <https://www.cnil.fr/en/data-protection- around-the-world>. Acesso em: 6 out. 2018.

FOLHA DE SÃO PAULO. **Facebook e Cambridge Analytica são alvos de ação coletiva**. 10 abr. 2018. Disponível em: <https://www1.folha.uol.com.br/mundo/2018/ 04/facebook-e-cambridge-analytica-sao- alvos-de-acao-coletiva-diz-jornal.shtml>. Acesso em: 8 out. 2018.

HENRIQUES, A.; MEDEIROS. J. B. **Metodologia Científica na Pesquisa Jurídicas**. 9. ed. São Paulo: Atlas, 2017.

LE COADIC, Y. **A ciência da informação**. Brasília, DF: Briquet de Lemos/Livros, 1996.

MACHLUP, F.; MANSFIELD, U. (Ed.). **The study of information: Interdisciplinary messages**. New York, NY: Wiley, 1983.

RODOTÁ, S. **A Vida na Sociedade da Vigilância**: A privacidade hoje. Rio de Janeiro: Renovar, 2008.

SEVERINO, A. J. **Metodologia do Trabalho Científico**. 23. ed. São Paulo: Cortez, 2007.

VANCIM, A. R.; NEVES, F. F. **Marco Civil da Internet**: Anotações à Lei Nº 12.965/2014. São Paulo: Mundo Jurídico, 2015.

Vídeo da apresentação

Título: Informação e privacidade na Lei Geral de Proteção de Dados.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=24

Transcrição da apresentação

Olá pessoal, estou aqui no segundo Workshop de Informação, Dados e Tecnologia de 2018 que ocorrerá nos próximos dias 27 a 29 de novembro na Universidade Federal da Paraíba.

Vou apresentar o trabalho intitulado Informação e privacidade na Lei Geral de Proteção de Dados autoria de Rosilene Paiva Marinho de Sousa doutora pelo Programa de pós-graduação em ciência da informação da Universidade Federal da Paraíba e mestrando em direito pelo programa de pós-graduação em direito do Centro Universitário de João Pessoa (UNIPE) juntamente com os professores doutores Fernando Antônio de Vasconcelos professor do programa de pós-graduação em ciências jurídicas da Universidade da Paraíba e do programa de pós-graduação em direito do Centro Universitário de João Pessoa (Unipê) e o professor Marchson Roberto Ferreira de Souza professor do programa de pós-graduação em ciência da informação da Universidade Federal da Paraíba e também do programa de pós-graduação em Gestão nas Organizações Aprendentes também pela Universidade Federal da Paraíba.

O objetivo deste trabalho é analisar a relação entre informações por voz e privacidade no âmbito da lei geral de proteção de dados, pra isso realiza uma reflexão dos instrumentos jurídicos de proteção de dados no âmbito do ordenamento jurídico brasileiro e examina os contornos da informação e da privacidade no âmbito da lei levando em consideração o consentimento como requisito para o tratamento de dados pessoais.

A metodologia utilizada no trabalho foi uma pesquisa bibliográfica exploratória e a partir daí a gente passa a trabalhar um pouco sobre a proteção de dados no ordenamento jurídico então a tratar neste ordenamento jurídico da proteção de dados é feita referência tanto no constitucional como no âmbito infraconstitucional. No âmbito constitucional levou-se em consideração as garantias fundamentais para chamar o artigo quinto da qual a privacidade está inserida juntamente em outros incisos com os direitos de acesso retificação e complementação de informações também prevista em alguns desses do artigo 5º.

E a infraconstitucional já se podia falar em proteção de dados em algumas normas é em caráter específico, por exemplo, quando uma defesa do consumidor em seu artigo 43 já regulava informações pessoais em bancos de dados e cadastros de consumidores já a lei 12.414 de 2011 que além do cadastro positivo já trabalhava a questão da proteção de dados ao estabelecer regras para o tratamento de dados financeiros para formação de histórico de crédito.

Existia também a lei do abc já dá para retificação de dados pessoais principalmente em bancos de dados de entidades governamentais indicaram até público a lei de acesso à informação também no artigo 31 já trouxe também algumas questões que ela relacionados à proteção de dados o marco civil da internet também e agora por último surgiu a lei 13.709 agora 2018 que a lei geral de proteção de dados com o objetivo específico de proteger direitos fundamentais de liberdade privacidade e do livro desenvolvimento da pessoa natural.

Então essa lei veio pra regular proteção de dados utilizando-se para fazer o tratamento de dados utilizando esse tratamento como toda operação realizada com dados desde a coleta perpassando por organização tratamento, acesso, uso e até a eliminação desses dados e tratam dado pessoal como toda a informação relacionada pessoa natural apresenta com os fundamentos principais o respeito à privacidade e à liberdade de expressão a liberdade de informação e um dos

princípios mais relevantes nessa lei que é um dos fundamentos mais importante que é a questão da autodeterminação informativa que é está diretamente relacionado à questão do curso e meter gente vai ver mais na frente.

Quanto à proteção da privacidade e acesso à informação é interessante destacar que toda atividade humana ela realiza produção de dados, então o momento em que a informação até as tecnologias da informação e comunicação com o passar do tempo foram realizando transformações nessas questões e gerando grande volume de produção de dados.

O dado passou a ser considerado o principal insumo da economia que podem ser tratados e valoradas é comum cadente a partir daí foram surgindo vazamento desses dados e o caso mais emblemático que a gente pode citar é o caso do Facebook, onde houve um vazamento de aproximadamente 87 milhões de dados de 887 milhões de usuários por da Cambridge Analytica.

Fica então a lei geral de proteção de dados e chegou nesse momento é para abandonar com buscando abandonar essa ideia desse sigilo ao acesso à informação e propor que a informação possa circular de forma responsável e tutelada proporcionando meios claros em seguros para que haja essa proteção de dados.

Então a lei geral de proteção de dados ela traz como o consentimento do titular como o elemento mais importante para o tratamento de dados, então esse consentimento consiste na permissão para que alguém possa coletá-lo e tratá-lo, esses dados na verdade para que ele possa trazer essa garantia a proteção dos dados pessoais então é o consentimento ele pode ser considerado como uma manifestação livre informada a inequívoca e por ser inequívoca ela permite que esse consentimento possa ser habitável.

Então ele pode ser habitável, ele deve ser de forma escrita deve se dar também de forma destacada dentro do contrato da forma que se apresenta e no caso de haver um vínculo de consentimento pode ser considerado nulo porque é o conteúdo provavelmente deve ter algum caráter enganoso e abusivo.

Quanto há a mudança de finalidade, é o controlador ele tem que informar o titular dos dados e se essa informação ao titular dos dados quando ela ocorrer pode haver em caso o titular dos dados não concorde com essa mudança finalidade pode ser revogada a qualquer tempo de forma expressa gratuita e de modo em facilitar pelo controlador.

Então o controle ele torna-se um instrumento de garantia dos direitos de liberdade privacidade e de livre desenvolvimento da personalidade de modo que segundo Rodotá é do livro Retotar com tradução meda esse eixo que antes fazia é constituir por cidadão informação em segredo ele passa a ser constituído por um cidadão informação e controle isso porque por que esse controle é quem vai proporcionar a segurança jurídica necessária que vai permitir ao titular dos dados a garantia do controle dos seus dados e consequentemente a garantia da privacidade dos seus dados.

Então ao permitir que o consentimento seja primordial para o tratamento dos dados à liberdade, à privacidade, o livre desenvolvimento da pessoa assume novos contornos e por isso a privacidade pode ser vista com um direito do cidadão de manter o controle sobre suas próprias informações.

Esse é o objetivo o contorno mais interessante mais importante que vai ligar a questão da privacidade e a proteção de dados ao consentimento e o acesso à informação.

O papel dos metadados na curadoria digital

Rachel Cristina Vesú Alves[a]

Resumo: Os metadados são importantes para proporcionar a organização, a representação, o acesso, a busca, a recuperação e a preservação dos recursos informacionais nos diferentes domínios do conhecimento e ambientes informacionais digitais. Os metadados podem desempenhar diversas funções, sendo que uma das mais requeridas nos ambientes informacionais na atualidade refere-se a preservação digital e curadoria digital. Assim, o problema norteador deste trabalho está em identificar qual o papel dos metadados na curadoria digital? Por meio de uma metodologia exploratória, o objetivo deste trabalho é abordar a importância e o papel dos metadados na curadoria digital, assim como, identificar quais os principais tipos ou categorias de metadados mais utilizados na curadoria digital. Os resultados parciais deste trabalho, revelam uma variedade de papéis ou funções que os metadados podem exercer no cenário da curadoria digital, assim como, uma variedade de padrões a serem utilizados, dependendo do contexto ou domínio. Deste modo, a próxima fase do estudo encaminha-se para a identificação dos padrões de metadados que podem ser utilizados no cenário de curadoria digital.

Palavras-chave: Metadados. Curadoria Digital. Preservação Digital.

The role of metadata in digital curation

Abstract: Metadata is important to provide the organization, representation, access, search, retrieval and preservation of information resources in different domains of knowledge and digital information environments. Metadata can perform several functions, and one of most required in today's information environments refers to digital preservation and digital curation. Thus, the guiding problem of this work lies in identifying the role of metadata in digital curation. Through an exploratory methodology, the objective of this research is to approach the importance and role of metadata in digital curation, also identify main types or categories of metadata most used in digital curation. The partial results of this research reveal a variety of roles or functions that metadata can exert in digital curatorial scenario, as well, as a variety of standards to be used depending on context or domain. Thus, next phase of the study is directed to identify metadata standards that can be used in digital curation scenario.

Keyword: Metadata. Digital Curation. Digital Preservation.

a Universidade Estadual Paulista (UNESP). E-mail: rachelvesu@gmail.com. ORCID: https://orcid.org/0000-0002-1649-3722. Currículo: http://lattes.cnpq.br/5658134053257855

1 Introdução

É indiscutível a importância que os metadados adquiriram na atualidade para proporcionar a organização, a representação, o acesso, a busca, a recuperação e a preservação nos diferentes domínios do conhecimento e ambientes informacionais digitais.

Os metadados podem desempenhar diversas funções como, por exemplo, identificação e descrição da informação; busca e recuperação; localização, restrição de uso e formas de acesso; autoria e propriedade intelectual; visibilidade e acessibilidade das informações; valoração do conteúdo, entre outras. Dentre as funções desempenhadas pelos metadados, a que vem sendo mais requerida atualmente nos ambientes digitais refere-se a preservação digital (MÉNDEZ RODRÍGUEZ, 2002).

A preservação digital pode ser definida como uma "[…] série de atividades gerenciais necessárias para garantir o acesso contínuo aos materiais digitais ao longo do tempo […] refere-se a todas as ações necessárias para manter o acesso aos materiais digitais, além dos limites de descontinuidade de mídia ou mudança tecnológica e organizacional." (BEAGRIE; KILBRIDE, 2015, tradução nossa).

A preservação digital pode ser considerada como um aspecto importante da curadoria digital, outro termo bastante difundido nos últimos tempos. A curadoria digital está relacionada com o gerenciamento de dados de pesquisa, em outras palavras refere-se a "[…] manter, preservar e agregar valor aos dados de pesquisa digital em todo o seu ciclo de vida." (DIGITAL CURATION CENTER, 2018).

Houve um crescimento nos últimos tempos não só dos recursos informacionais digitais, mas também de uma grande quantidade de dados que precisam ser gerenciados para serem acessados ao longo do tempo em um ambiente digital.

A curadoria digital consiste em um conceito mais amplo, pois "[…] começa antes que os objetos digitais sejam criados, configurando o planejamento da coleta de dados que resulta em objetos digitais "preparados para curadoria", que estão na melhor condição possível para garantir que possam ser mantidos e utilizados no futuro."

De acordo com Harvey (2010) a curadoria digital não engloba apenas a questão da preservação, mas também o reúso dos dados. Em outras palavras, "A curadoria digital enfatiza a adição de valor a conjuntos de dados e objetos digitais, por meio de itens como metadados ou anotações adicionais, para que possam ser reutilizados." (HARVEY, 2010, p. 08).

Nesse sentido, pode-se entender que o uso de metadados passa a ser essencial para a curadoria digital, pois exige um gerenciamento dos recursos em seu ciclo de vida; deve proporcionar o acesso aos dados e recursos informacionais; a preservação digital dos dados e recursos informacionais ao longo do tempo, além do reúso dos dados.

Assim, o problema norteador deste trabalho está em identificar qual o papel dos metadados na curadoria digital?

2 Objetivos

O objetivo deste trabalho é abordar a importância e o papel dos metadados na curadoria digital, assim como, identificar quais os principais tipos ou categorias de metadados mais utilizados na curadoria digital.

3 Procedimentos Metodológicos

A metodologia da pesquisa está embasada em estudo exploratório que, segundo Cervo e Bervian (2003), consiste na busca de informações sobre um determinado assunto, para que solucione os diversos aspectos de um problema. Segundo Köcher (2002, p. 126) estudos exploratórios desencadeiam "[…] um processo de investigação que identifique a natureza do fenômeno e aponte as características essenciais das variáveis que se quer estudar".

Assim, acredita-se ser possível identificar a importância e o papel dos metadados na curadoria digital.

4 Resultados

Os resultados parciais revelam uma variedade de papéis ou funções que os metadados podem exercer no cenário da curadoria digital. Assim como, uma diversidade de padrões de metadados a serem utilizados, dependendo do contexto e domínio no qual está inserido.

A preservação é uma das funções que os metadados desempenham na curadoria digital. Segundo Grácio (2012) a preservação digital pode ser abordada sob três aspectos principais: o aspecto organizacional, o aspecto legal e o aspecto técnico. Os metadados permeiam todos esses aspectos, pois devem ser determinados de modo amplo na política de preservação digital das instituições, que por sua vez, engloba a determinação desses três aspectos.

Porém, são nos aspectos técnicos da preservação onde estão presentes a maior parte dos metadados responsáveis pela descrição e preservação digital do recurso informacional.

A obsolescência tecnológica de software e hardware, dos formatos de arquivo, além da degradação das mídias digitais, são fatores preponderantes que motivam o estabelecimento da preservação digital e do acesso a longo prazo dos recursos informacionais em ambientes digitais.

Assim, torna-se necessário o uso de estratégias de preservação (migração, emulação, encapsulamento etc) para preservar o aspecto físico, de conteúdo e a autenticidade dos recursos informacionais, garantindo seu acesso ao longo do tempo.

Neste contexto, os metadados e padrões de metadados a serem utilizados na preservação digital estão mais relacionados com as funções de: descrição, organização, mudança de formatos de arquivo, informações sobre as estratégias de preservação utilizadas e as ações de preservação sobre o recurso informacional ao longo do tempo.

É importante ressaltar também que algumas informações a serem preservadas ao longo do tempo estão representadas em metadados descritivos. Um exemplo a ser considerado são os metadados título, autor e data, geralmente presentes em padrões de metadados descritivos. Atributos descritivos, essenciais para caracterizar um recursos informacional, são dados a serem preservados ao longo do tempo, além dos atributos próprios da preservação digital como, por exemplo, atributos sobre as estratégias de preservação utilizadas.

De acordo com o Digital Curation Center (2018 tradução nossa) o ciclo de vida da curadoria digital compreende as seguintes etapas:

- **Conceitualizar**: conceber e planejar a criação de objetos digitais, incluindo métodos de captura de dados e opções de armazenamento;
- **Criação**: produção de objetos digitais e atribuição de metadados administrativos, descritivos, estruturais e técnicos para arquivamento;
- **Acesso e uso**: garantir que os usuários designados possam acessar facilmente os objetos digitais […];
- **Avaliar e selecionar**: avaliar objetos digitais e selecionar aqueles que requerem curadoria e preservação a longo prazo. Seguir as orientações documentadas nas políticas e requisitos legais;
- **Descartar**: liberar os sistemas de objetos digitais não selecionados para curadoria e preservação a longo prazo […];
- **Transferir**: objetos digitais para um arquivo, repositório digital confiável, data center ou similar, seguindo novamente as diretrizes documentadas, políticas e requisitos legais;
- **Ação de preservação**: empreender ações para assegurar a preservação e retenção a longo prazo da natureza autêntica dos objetos digitais;
- **Reavaliar**: objetos digitais que falham nos procedimentos de validação para avaliação […];
- **Armazenar**: manter os dados de maneira segura, conforme descrito pelos padrões relevantes;
- **Acesso e reutilização**: garantir que os dados sejam acessíveis aos usuários designados para uso e reutilização […];
- **Converter**: criar novos objetos digitais a partir do original, por exemplo, migrando para uma forma diferente.

Estão contempladas em todas essas etapas vários tipos de metadados. Assim, observa-se que os metadados vão desempenhar papéis importantes no ciclo de vida da curadoria digital.

De acordo com Harvey (2010, p. 67-68, tradução nossa), pode-se encontrar os seguintes tipos de metadados na curadoria digital:

- **Metadados administrativos**: metadados relacionados ao uso, gerenciamento e processo de codificação de objetos digitais durante um período de tempo. Inclui os subconjuntos de metadados técnicos, metadados de gerenciamento de direitos e metadados de preservação.
- **Metadados descritivos**: metadados que descrevem uma obra para fins de descoberta e identificação, como criador, título e assunto.
- **Metadados técnicos**: uma forma de metadados administrativos que lida com o processo de codificação de criação ou armazenamento de formatos do recurso.
- **Metadados estruturais**: metadados que indicam como os objetos compostos são estruturados, provê o suporte para o uso dos objetos.

- **Metadados de preservação**: metadados administrativos que lidam com a proveniência de um recurso e sua gestão de arquivamento. (HARVEY, 2010, p. 67-68, tradução nossa).

Os tipos e categorias de metadados citados estarão presentes nos esquemas dos padrões de metadados. Alguns padrões serão compostos por mais de um tipo de metadados, já outros apresentarão a predominância de um desses tipos. É o caso do padrão de metadados de preservação digital Premis (Data Dictionary for Preservation Metadata).

5 Conclusão ou Considerações Finais

Este trabalho consiste em uma análise preliminar do papel dos metadados na curadoria digital.

Foi possível identificar que os metadados estão presentes em todo ciclo de vida da curadoria digital e que constituem-se em diferentes tipos como, administrativos, descritivos, técnicos, estruturais e de preservação.

A preservação digital constitui-se como um dos aspectos da curadoria e, mesmo voltada para aspectos mais técnicos dos recursos informacionais e requisitos do sistema, também preservam informações descritivas e de contextualização de um recurso, por exemplo.

Deste modo, a próxima fase do estudo encaminha-se para a identificação dos padrões de metadados que podem ser utilizados no cenário de curadoria digital, considerando a variedade de domínio e padrões existentes. Assim, faz-se necessário a identificação desses padrões com base nas características específicas de domínio e as diretrizes estabelecidas pela Digital Curation Center.

Referências

BEAGRIE, N.; KILBRIDE, M. **Digital Preservation Handbook**. Disponível em: <https://dpconline.org/handbook>. Acesso em: 07 out. 2018.

CERVO, A. L.; BERVIAN, P. A. **Metodologia científica**. 5. ed. São Paulo: Prentice Hall, 2003.

DIGITAL CURATION CENTER. **What is digital curation?** 2018. Disponível em: <http://www.dcc.ac.uk/digital-curation/what- digital-curation>. Acesso em: 07 out. 2018.

GRÁCIO, J. C. A. **Preservação digital na gestão da informação: um modelo processual para as instituições de ensino superior**. São Paulo: Cultura Acadêmica, 2012. ISBN 9788579833335. Disponível em: <http://hdl.handle.net/11449/113727>. Acesso em: 22 nov. 2018.

HARVEY, R. **Digital Curation: a how-to-do-it maual**. New York: Neal-Schuman, 2010.

KÖCHE, J. C. **Fundamentos da metodologia Científica**: teoria da ciência e iniciação à pesquisa. 20.ed. Petrópolis: Vozes, 2002.

MÉNDEZ RODRÍGUEZ, E. ***Metadados y recuperación de información:*** estándares, problemas y aplicabilidad en bibliotecas digitales. Gijón: Trea, 2002. 429 p.

Vídeo da apresentação

Título: O papel dos metadados na curadoria digital.

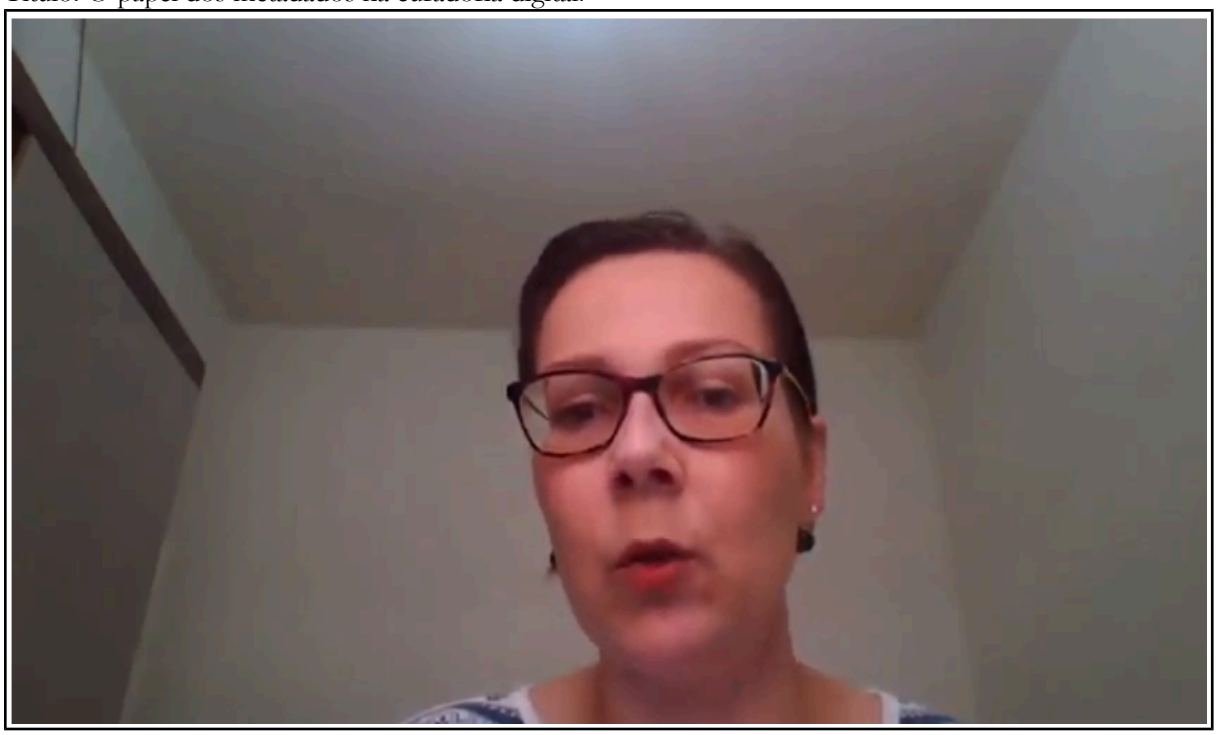

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=25

Transcrição da apresentação

O meu nome é Rachel, eu sou professora do curso de biblioteconomia da Faculdade de Filosofia e Ciências da UNESP de Marília e o meu trabalho é "O papel dos mandados na curadoria digital".

Objetivo deste trabalho era analisar, abordar a importância do papel dos metadados na curadoria digital, em especial identificar quais os principais tipos ou categorias de metadados são mais utilizados na curadoria digital e no ciclo de vida da curadoria digital.

Bom, nós sabemos que a preservação digital é um item muito importante nos dias atuais e uma parte, um requisito dentro da curadoria digital, um requisito que faz parte dessa curadoria. E nesse ciclo de vida em nessa preocupação com a preservação digital os metadados se fazem presentes. Então em relação ao ciclo de vida da curadoria digital nós temos aí algumas algumas etapas, uma contextualização a criação do objeto digital que envolve as partes de captura desse objeto e armazenamento desse objeto, portanto metadados nesse cenário, criação desses objetos digitais e a inclusão, atribuição de metadados descritivos, administrativos, estruturais, garantia de acesso e uso nessa curadoria, obviamente também tem os metadados relacionados a isso, temos uma etapa de avaliação e seleção desses materiais na curadoria, o descarte e transferência, às ações de preservação que têm que ser realizadas nesses objetos nesse ciclo de curadoria, logo depois uma reavaliação, desses objetos digitais, armazenamento desses objetos a longo prazo, o acesso e a reutilização de muitos objetos ou informações desses objetos e converter objetos digitais a partir do original que está bem relacionado com a questão de preservação.

Bom nesse cenário todo a preservação digital ela é um item fundamental mas não existe sozinha, em todas essas etapas do ciclo de vida os metadados estão presentes e vários tipos de metadados, então quais esses tipos de metadados? Quais os papéis dos metadados nesse ciclo?

O que foi possível identificar na literatura que nós temos metadados administrativos que vão atuar neste ciclo, geralmente estão relacionados ao uso de gerenciamento e processamento das informações desses objetos digitais, pra isso futuramente pode ser utilizado na preservação mas nós precisamos ter essa representação, essa descrição por metadados de modo mais administrativos, temos que ter metadados descritivos, sem ele nós não temos um contexto do objeto nem a individualização desse objeto, metadados técnicos, que de alguma forma nesse ciclo de curadoria traz informações técnicas do objeto no sistema mas também atua certa forma na administração desses é objetos digitais no ciclo de vida da curadoria, metadados estruturais que vão indicar como os objetos são compostos, como são estruturados e vão fornecer informações de uso desses objetos na como eles podem ser utilizados e, por fim, associado a todos esses os metadados de preservação, que certa forma preserva mas também funcionam para administrar certas informações e gerir esses objetos, preservar ao longo do tempo e fazer o gerenciamento desses objetos para acesso a longo prazo.

O que foi possível identificar que nós temos vários tipos e categorias de metadados conforme abordados no trabalho e esses tipos de metadados vão compor padrões, alguns padrões vão ter mais que um tipo de metadado e outras vão ser bem específicos, então nós temos padrões descritivos que podem ter as leis a um ou outro metadado administrativo e temos, por exemplo, padrões metadados específico de preservação, lembrando que eles vão atuar esses

padrões que são específicos de preservação, vão atuar com padrões descritivos por exemplo e os dois nem o sistema, nem em um ambiente vão estar gerenciados por padrões metadados administrativos por exemplo.

O que nós podemos concluir dessa análise, desse levantamento sobre os papéis dos metadados na curadoria digital é que embora a preservação digital seja o item bem atual, específico e importante de ser considerado, também faz parte do objeto de estudo desse trabalho, não se faz uma preservação digital nessa preocupação toda do ciclo de vida dos objetos, sem ter outros tipos de padrões de metadados, então o ciclo de vida da curadoria digital vai estar presente nesse ciclo vários outros tipos de metadados e padrões, então alguns mais administrativos, outros mais destrutivos, outros mais técnicos muitos estruturais e por fim de preservação que vai tratar de informações específicas de preservação mas atuar com outros tipos de padrões nesse contexto para poder proporcionar essa preservação digital na curadoria digital.

A preservação digital constitui um papel importante nesse ciclo de curadoria, os metadados se fazem presentes, obviamente são muito importantes e a próxima fase do estudo além desse diagnóstico inicial é abordar quais os padrões de metadados são utilizados nessa preservação digital.

Proteção autoral de dados: uso de Blockchain

Elizabete Cristina de Souza Aguiar Monteiro[a], Jacquelin Teresa Camperos Reyes[b], Elaine Parra Affonso[c] e Ricardo César Gonçalves Sant'Ana[d]

Resumo: A tecnologia blockchain pode apresentar potencial para proteger o direito autoral de dados quando estes estão envolvidos em ambientes digitais. Com o intuito de explicitar como blockchain tem sido abordada para questões de proteção do direito autoral de dados, foi realizada uma revisão sistemática de literatura, junto com análise de conteúdo, em trabalhos publicados na base de dados Scopus. Os resultados demonstram que o uso da tecnologia blockchain para a proteção de direitos autorais é pouco recorrente nos 80 estudos analisados, apenas oito apresentam aplicação dessa tecnologia para proteção autoral de dados. Entre as aplicações que emergem nesse cenário há plataformas como Mycelia, criação de marca d água e contratos inteligentes. Conclui-se que o uso de blockchain no contexto de proteção de dados autorais não é foco das pesquisas recuperadas, situação que torna essa temática uma oportunidade para pesquisas em diversas áreas do conhecimento.

Palavras-chave: Direitos autorais. Blockchain. Propriedade intelectual. Dados.

Authoral protection of data: use of Blockchain

Abstract: Blockchain technology may have the potential to protect copyright when data are involved in digital environments. In order to explain how blockchain has been approached for copyright protection issues, a systematic review of the literature, together with content analysis, was carried out in published works in the Scopus database. The results show that the use of blockchain technology for copyright protection is not very recurrent in the 80 studies analyzed, only eight present application of this technology for data protection. Among the applications that emerge in this scenario are platforms like Mycelia, watermark creation and smart contracts. It was observed that blockchain is involved with studies and applications in several areas of knowledge, marking this topic as a fertile field for research in the scope of protection and verification of data copyright.

Keyword: Copyright. Blockchain. Intellectual property. Data.

a Universidade Estadual Paulista (UNESP). E-mail: ecsamonteiro@gmail.com. ORCID: https://orcid.org/0000-0002-3797-8139. Currículo: http://lattes.cnpq.br/3258820169472861

b Universidade Estadual Paulista (UNESP). E-mail: jcamperosreyes@gmail.com. ORCID: https://orcid.org/0000-0002-0078-5376. Currículo: http://lattes.cnpq.br/5415219564237576

c Faculdade de Tecnologia do Estado de São Paulo (FATEC). E-mail: elainepff@gmail.com. ORCID: https://orcid.org/0000-0002-3953-462X. Currículo: http://lattes.cnpq.br/8697314376216832

d Universidade Estadual Paulista (UNESP). E-mail: ricardo.santana@unesp.br. ORCID: http://orcid.org/0000-0003-1387-4519. Currículo: http://lattes.cnpq.br/1022660730972320

1 Introdução

O avanço na ciência e na produção de dados em diversas atividades da sociedade podem proporcionar oportunidades no âmbito da colaboração internacional, geração de conhecimentos e progresso da ciência porém, apresenta desafios quando relacionados à reutilização e a proteção autoral dos dados.

O compartilhamento ou publicação de dados oferecem vantagens para os cientistas pois, quando os pesquisadores publicam seus dados, o seu trabalho pode ser compartilhado entre as fronteiras regionais, nacionais e internacionais (TENOPIR et al., 2015).

Para o pesquisador que busca melhorar seu status profissional e seu reconhecimento perante seus pares (agradecimentos e citações), o compartilhamento de seus dados propicia oportunidades para ser reconhecido como o autor, ser citado por membros mais proeminentes de seu campo de atuação e receber o reconhecimento formal (KIM; STANTON, 2013, 2016). Da mesma forma, a divulgação de dados fora do contexto científico impacta positivamente nas carreiras dos profissionais.

Os fatores apresentados instigam o compartilhamento dos dados, no entanto, os custos na geração ou coleta, no tratamento e na gestão de dados são relativamente dispendiosos e os detentores dos dados tem recorrido às estratégias para proteger a autoria dos dados. Um recurso utilizado para questões de proveniência e garantia da autoridade de dados é a tecnologia blockchain.

Segundo Kim e Laskowski (2018) blockchain é um registro público baseado em uma arquitetura distribuída, uniformemente replicado em todos os seus nós, à prova de adulteração, que fornece um método para estabelecer a existência de uma transação em um momento específico, podendo ser verificada por qualquer parte interessada, incluindo o rastreamento da proveniência dos dados.

Tecnicamente, blockchain é um sistema distribuído público que contém todas as transações que já foram executadas no sistema. No contexto da gestão de dados de pesquisa, blockchain permite gerir esses dados de forma descentralizada, com a possibilidade da auto-regulação por meio de uma infraestrutura compartilhada para transações ou fluxos dos dados. A tecnologia também permite que pesquisadores interajam com o conteúdo em qualquer etapa do ciclo de vida dos dados. Ainda, interessante ressaltar que, o uso de blockchain nas questões vinculadas à proteção do direito autoral:

> […] permite, por um lado, a criação de um registro permanente dos acordos entre os autores dos dados e os reutilizadores, com a possibilidade de verificar a conformidade a qualquer momento e, por outro lado, um maior nível de granularidade na definição das condições de reutilização. (PANESCU; MANTA, 2018)

Assim, o registro é fator significativo, na medida em que confere a autenticidade do protocolo original e a segurança jurídica ao autor, facilita a comprovação da criação da obra, assegura o direito autoral na publicação e a obtenção de um certificado de registro. Ainda, para Karafiloski (2017) quando se tem o registro de data e hora das transações, é possível obter prova no tribunal, no caso de uma disputa de propriedade.

2 Objetivos

No contexto desta pesquisa busca-se investigar a aplicação da tecnologia blockchain para proteção do direito autoral de dados e relatar como está sendo utilizado.

3 Procedimentos Metodológicos

A metodologia deste trabalho consiste em uma revisão sistemática de literatura a fim de verificar como a tecnologia blockchain tem sido aplicada para comprovação de direitos autorais em dados. As estratégias utilizadas nesta metodologia foram baseadas no protocolo de revisão sistemática de Kitchenham (2004). Para tanto, realizaram-se as seguintes estratégias:

- Base de dados: Foi escolhida a Scopus por fornecer um serviço eficaz na obtenção de informações de produção científica (NOBLEJAS; RODRIGUEZ, 2014), envolvida com diversas áreas de conhecimento, visto que a temática deste trabalho abarca questões da Computação, do Direito e da Ciência da Informação;
- Termo descritor: A busca foi realizada no dia 2 de outubro de 2018, por meio da seguinte estratégia de busca: (TITLE-ABS-KEY (BLOCKCHAIN) AND (TITLE-ABS-KEY ("intellectual property" OR copyright) AND TITLE-ABS-KEY (blockchain)). Os termos foram escolhidos considerando o foco da pesquisa na tecnologia blockchain como opção para proteção do direito autoral de dados;
- Tipos de documentos: Foram analisados todos os documentos recuperados compostos por artigos de periódicos, capítulos de livros e artigos publicados em anais de eventos;
- Ano de publicação: Foram considerados para a análise todos os documentos recuperados mediante a expressão de busca utilizada, assim, a coleta não foi delimitada por valor temporal;
- Critério de exclusão: Não foi excluído nenhum documento recuperado;
- Processo de seleção: Após a expressão de busca ser submetida à base de dados Scopus, os atributos referentes a cada documentos recuperados foram armazenados em software de planilhas, extraindo as seguintes informações: Ano de publicação, título do artigo, quantidade de citações, resumo e palavras-chaves; processo de análise Foi aplicado o método Análise de conteúdo, adotando a análise léxica, tendo como unidade de registro a palavra, utilizando a regra de enumeração presença (BARDIN, 1977). Para tanto, foi utilizado a ferramenta textalyser, que possibilita realizar a análise estatística de um texto, permitindo descobrir palavras-chave. Posteriormente utilizou-se a linguagem R para geração da nuvem de palavras;
- Mediante a leitura dos resumos realizou-se a análise categorial proposto no método Análise de conteúdo para verificar a principal abordagem no uso de blockchain no contexto de proteção de dados autorais. Esta atividade permitiu a construção do quadro no Apêndice A com as seguintes categorias: tipo de dado, técnica/processo e descrição do processo.

Foram utilizados quadros e figuras para representar os dados extraídos dos documentos, com a finalidade de demonstrar a frequência das palavras nos textos e a quantidade de trabalhos por ano. Por meio desses dados é possível inferir sobre o objeto de estudo deste trabalho.

4 Resultados

Foram recuperados 80 trabalhos na base de dados Scopus de acordo com a estratégia de busca blockchain and "copyright or intellectual property" and data. Após a coleta, os resumos foram agrupados em um único arquivo, resultando em um arquivo com 14 páginas de texto. Este arquivo foi inserido na ferramenta textalyser para realizar a análise de contagem de palavras e frequência.

O Quadro 1 apresenta as palavras com maior número de ocorrências, resultado da análise léxica realizada pela ferramenta textalyzer nos resumos e nas suas palavras-chaves. Observa-se que os termos descritores "dados" e "blockchain" são os mais recorrentes nos trabalhos recuperados, incluindo os termos tecnologia, sistema, bitcoin e segurança. Interessante ressaltar que termos relacionados à proteção dos direitos autorais não emergem entre os 20 primeiros termos recorrentes.

Quadro 1: Ocorrências de palavras nos resumos e nas palavras-chaves dos documentos.

Resumo			**palavras-chaves**		
Palavra	Qtd	Freq	Palavra	Qtd	Freq
data	164	2.7%	data	79	4.5%
blockchain	160	2.6%	systems	52	3%
technology	77	1.3%	block	35	2%
system	56	0.9%	information	34	1.9%
distributed	39	0.6%	chain	34	1.9%
information	37	0.6%	management	33	1.9%
management	34	0.6%	distributed	31	1.8%
peer	34	0.6%	blockchain	29	1.7%
systems	32	0.5%	peer	27	1.5%
digital	31	0.5%	electronic	26	1.5%
bitcoin	30	0.5%	privacy	26	1.5%
solution	29	0.5%	security	25	1.4%
security	28	0.5%	digital	25	1.4%
privacy	28	0.5%	money	22	1.3%
transactions	26	0.4%	internet	19	1.1%
energy	26	0.4%	storage	19	1.1%
smart	25	0.4%	things	15	0.9%
research	24	0.4%	computing	14	0.8%
network	23	0.4%	computer	14	0.8%
financial	23	0.4%	networks	14	0.8%

Fonte: Dados da pesquisa, 2018.

Ao realizar mineração de texto na linguagem R para proporcionar a visualização dos dados mais frequentes nos resumos dos trabalhos recuperados, obteve-se a Figura 1, que também corrobora os dados demonstrados na análise anterior (QUADRO 1).

Com as principais ocorrências de termos nas palavras-chaves dos documentos (Quadro 1) pode-se inferir que prevalecem questões voltadas a segurança dos dados, efetivado pelos termos "security", "privacy"; ressalta-se também que o uso de blockchain pode estar voltado para

proteção de transações que envolvem dinheiro digital, tal como bitcoin. Assim, nos 20 termos com mais ocorrências nas palavras-chaves não aparecem termos relacionados à proteção de direitos autorais.

Observa-se na figura 2 que os documentos recuperados relacionados à proteção autoral de dados e blockchain são publicados na base de dados Scopus a partir do ano de 2016, isso demonstra que a temática é recente na literatura e apresenta um crescimento de 260% do ano 2016 para o ano 2017.

Figura 1: Termos com maior ocorrência.

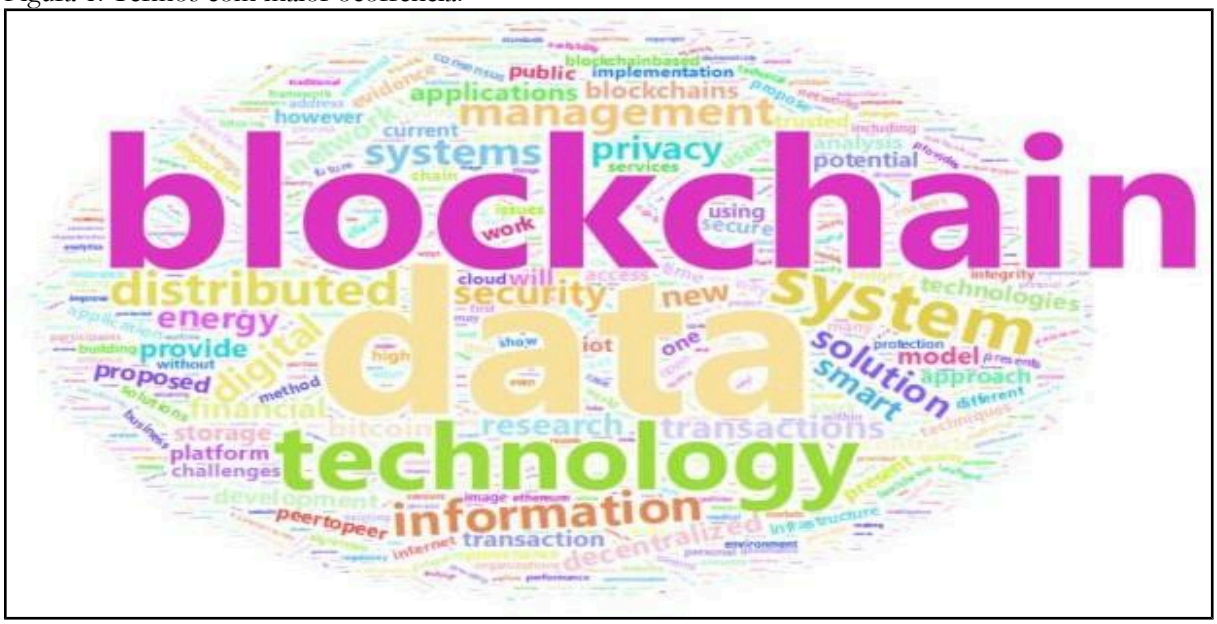

Fonte: Dados da pesquisa, 2018.

Figura 2: Ocorrência de publicação/ano.

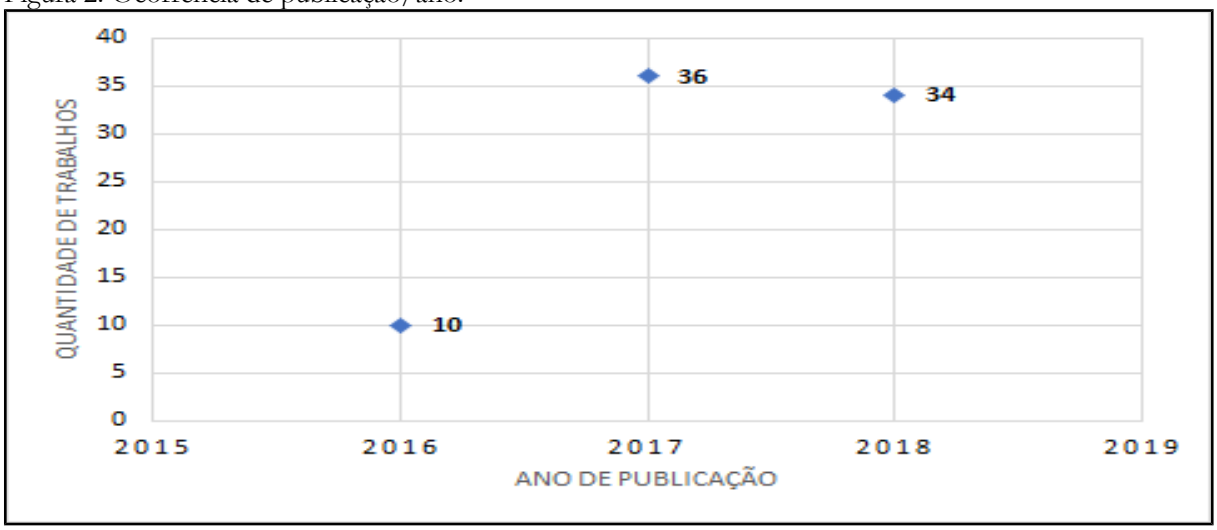

Fonte: Dados da pesquisa, 2018.

No apêndice A estão relacionados os trabalhos recuperados que relatam sobre o uso do blockchain para proteção de direitos autorais. Na primeira e segunda colunas estão os nomes dos

autores e os títulos dos documentos respectivamente, na terceira coluna estão indicados os tipos de dados abordados nos documentos, na quarta e quinta colunas estão as técnicas ou os processos aplicados com a tecnologia blockchain e, o resumo dos processos apresentados pelos autores.

Observa-se que blockchain é aplicado em dados identificados pelos autores como: dados de pesquisa, dados digitais ou simplesmente dados, explicitando o contexto dos quais os dados estão inseridos (MA; HUANG; GAO, 2018; PĂNESCU; MANTA, 2018), músicas e vídeos (GAO; NOBUHARA, 2017; O'DAIR; BEAVEN, 2017), imagens de obras de arte (ZHAOFENG; WEIHUA; HONGMIN, 2018) e timestamp (GIPP et al.2017).

Os artigos descrevem e discutem técnicas e/ou processos utilizados com a blockchain como a plataforma MyCelia para música, o CryptSubmite para manuscritos, contratos inteligentes e marca d'água para obras de artes (APÊNDICE A).

Dentre os principais benefícios e oportunidades relatados nos artigos destacam-se àqueles para ter precisão e acessibilidade dos dados de direitos autorais, a transparência nos processos, os meios para evitar a falsificação de dados e o gerenciamento de direitos autorais.

5 Considerações Finais

A revisão sistemática de literatura na base de dados Scopus revelou que apesar de serem recuperados 80 trabalhos, apenas oito apresentam a aplicação de blockchain para proteção autoral de dados. Mesmo os trabalhos que discutem aspectos relacionados à proveniência de dados, esses descrevem a facilidade da integração de dados de diversas fontes, o fornecimento de informações dessas fontes, a origem dos dados, a verificação de adulteração dos dados e em quais dados foram feitas as transformações, no entanto, não vinculam com o direito autoral.

Conclui-se que o uso de blockchain no contexto de proteção de dados autorais não é foco da maioria das pesquisas recuperadas, situação que torna essa temática uma oportunidade para pesquisas em diversas áreas do conhecimento, visto que, ao utilizá-la pode-se contribuir na proteção e comprovação do direito autoral de dados.

Referências

BARDIN, L. **Análise de conteúdo**. 4. ed. Lisboa: Edições 70, 1977.

CHEN, J.; XUE, Yi. Bootstrapping a blockchain based ecosystem for big data exchange. In: Big Data (BigData Congress), 2017 IEEE International Congress on. IEEE, 2017. p. 460-463.

GAO, Y.; NOBUHARA, H. A Decentralized Trusted Timestamping Based on Blockchains. **IEEJ Journal of Industry Applications**, Tokyo, v. 6, n. 4, p. 252-257, 2017.

GIPP, B. et al. CryptSubmit: introducing securely timestamped manuscript submission and peer review feedback using the Blockchain. In: Proceedings of the ACM/IEEE joint conference on digital libraries, 2017, Toronto. **Procedings…** 2017. Disponível em: <https://ieeexplore.ieee.org/document/7991588. Acesso em: 20 set. 2018.

KARAFILOSKI, E.; MISHEV, A. Blockchain solutions for big data challenges: A literature review. In: Smart Technologies, IEEE EUROCON International Conference on IEEE, 17., 2017. **Procedings…**2017. p. 763-768. Acesso em: 20 set. 2018.

KIM, H. M.; LASKOWSKI, M.Toward an ontology- driven blockchain design for supply-chain provenance. **Intelligent System in Accounting Finance e Management,** Hoboken, v. 25, n. 2, p. 18-27, Jan./Mar. 2018. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1002/isaf.1424>. Acesso em: 20 set. 2018.

KIM, Y.; STANTON, J. M. Institutional and individual influences on scientists' data sharing practices. **Journal of Computational Science Education**, v. 3, p. 47-56, 2013. Disponível em: <https://www.researchgate.net/publication/239522383_Institutional_and_Individual_Influences_on_Scientists'_Data_Sharing_Practices>. Acesso em: 29 set. 2018.

KIM, Y.; STANTON, J. M. Institutional and individual factors affecting scientists' data-sharing behaviors: A multilevel analysis. **Journal Of the Association for Information Science and Technology**, v. 67, n. 4, p. 776–799, 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1002/asi.23424>. Acesso em: 29 set. 2018.

KITCHENHAM, B. **Procedures for performing systematic reviews**: joint technical report. Keele: Keele University, 2004.

MA, Z.; HUANG, W.; GAO, H. Secure DRM Scheme Based on Blockchain with High Credibility. Chinese Journal of Electronics, v. 27, n. 5, p. 1025-1036, 2018.

NOBLEJAS, C. J.; RODRÍGUEZ, A. P. Recuperación y visualización de información en Web of Science y Scopus: una aproximación práctica. **Investigación Bibliotecológica:** archivonomía, bibliotecología e información, México, v. 28, n. 64, p. 15-31, 2014. Acesso em: 20 set. 2018.

O'DAIR M., BEAVEN Z. The networked record industry: How blockchain technology could transform the record industry. **Strategic Change**, Hoboken, v. 26, n. 5, p. 471-480, Sept. 2017. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1002/jsc.2147>. Acesso em: 20 set. 2018.

PĂNESCU, A-T.; MANTA, V. Smart Contracts for Research Data Rights Management over the Ethereum Blockchain Network. **Science & Technology Libraries**, p. 1-11, 2018.

TENOPIR C. et al. (2015) Changes in data sharing and data reuse practices and perceptions among scientists worldwide. **PLoS ONE**, San Francisco, v. 10, n. 8, Aug. 2015. Disponível em: <https://doi.org/10.1371/journal.pone.0134826>. Acesso em: 16 fev. 2018.

ZHAOFENG, M.; WEIHUA, H.; HONGMIN, G. A new blockchain-based trusted DRM scheme for built-in content protection. **EURASIP:** Journal on Image and Video Processing, v.

2018, n.91, p1-12, 2018. Disponível em:<https://link.springer.com/article/10.1186/s13640-018-0327-1>. Acesso em: 20 set. 2018.

Apêndice A

Quadro 1: Uso do blockchain para proteção autoral de dados.

Autores	Título do artigo	Tipo de dado	Técnica/Processo	Descrição do processo
O'DAIR; BEAVEN	The networked record industry: How blockchain technology could transform the record industry	Música	Plataforma Mycelia; banco de dados universal e único de direitos autorais de música; Aurovine; Global Repertoire Database (GRD); contratos inteligentes; micropagamentos; proof-of-work	Precisão e acessibilidade dos dados de direitos autorais; velocidade de pagamentos de royalties; e transparência da cadeia de valor.
GIPP et al.	CryptSubmit: Introducing Securely Timestamped Manuscript Submission and Peer Review Feedback Using the Blockchain	Timestamp	CryptSubmit - sistema de submissão de manuscritos para a publicação acadêmica	Sistema que cria automaticamente um timestamp descentralizado, à prova de falsificação e publicamente verificável para cada manuscrito submetido
PĂNESCU; MANTA	Smart Contracts for Research Data Rights Management over the Ethereum Blockchain Network	Dados de pesquisa	Solidity Contrato inteligente	Permite aos autores supervisionar como está sendo acessado e reutilizado.
MA; HUANG; GAO	Secure DRM scheme based on blockchain with high credibility	Dados digitais	Infraestrutura BaaS com plataforma DRM	Criação de blocos gênesis, definição de mecanismos de consenso, inicialização e execução de nós, gerenciamento de wallet, gerenciamento de endereços, blockchain explorer
CHEN; XUE	Bootstrapping a Blockchain Based Ecosystem for Big Data Exchange	Dados	Ecossistema para troca de dados	Visa cultivar um ecossistema, dentro do qual todos os participantes podem cooperar para trocar dados de maneira peer-to- peer
GAO; NOBUHARA	A decentralized trusted timestamping based on blockchains	Dados digitais (documentos, música e vídeos	Registro de data e hora	Usando o blockchain expandindo o espaço de armazenamento de 40 bytes para N * 20 bytes.
ZHAOFENG; WEIHUA; HONGMIN	A new blockchain-based trusted DRM scheme for built-in content protection	Imagem de obras de arte	Marca d'água com esquema DRMChain	Esquema de gerenciamento de direitos digitais de imagens de obras de arte para detecção de uso incorreto, incorporamos informações corretas de obras de arte, como autor, RightHolder, data e local
XU; ZHANG; ZHAO; PENG	Design of Network Media's Digital Rights Management Scheme Based on Blockchain Technology	Conteúdo multimídia	Mecanismo de consenso, contratos inteligentes baseados em cadeias de assinatura digital e hash	Projeção de um esquema de gerenciamento de direitos digitais para mídia de rede com uso de smart contract, em tempo real, permitindo os pagamentos de juros e participação nos lucros

Fonte: Dados da pesquisa, 2018.

Vídeo da apresentação

Título: Proteção autoral de dados: uso de Blockchain.

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=26

Transcrição da apresentação

Essa apresentação destina-se ao 2º Workshop de Informação Dados e Tecnologia – WIDAT de 2018. Eu sou Elizabeth Monteiro aluna do Programa de Pós-graduação em Ciência da Informação da UNESP campus de Marília no doutorado. Esse trabalho foi realizado junto com a Jaqueline Reis também do Programa de Pós-graduação em Ciência da Informação da UNESP de Marília no doutorado, com a Elaine Affonso docente da FATEC de Presidente Prudente e com o professor Ricardo Sant'Ana que é professor do Programa de Pós-graduação em Ciência da Informação da UNESP de Marília. Nosso trabalho tem o título de "Proteção autoral de dados: uso de Blockchain".

O avanço na ciência na produção de dados em diversas atividades podem proporcionar oportunidades no contexto da colaboração internacional, no entanto, pode trazer desafios vinculados à reutilização à proteção autoral desses dados. O compartilhamento e a publicação de dados oferece vantagens para os cientistas, pois quando os pesquisadores publicam seus dados o seu trabalho pode ser compartilhado entre fronteiras regionais, nacionais e internacionais.

Para o pesquisador que busca melhorar seu status profissional, o seu reconhecimento perante os seus pares, o compartilhamento dos seus dados propicia oportunidade para ser reconhecido como o autor, ser citado por membros mais proeminentes de seu campo de atuação e receber o reconhecimento formal.

Os fatores apresentados investigam compartilhamento dos dados, no entanto os custos na geração, coleta, no tratamento e na gestão desses dados são relativamente dispendiosos, os detentores dos dados têm recorrido a estratégias para proteger a autoria dos seus dados.

Um recurso utilizado para as questões de proveniência e garantia de autoridade dados e a tecnologia Blockchain. A tecnologia Blockchain ela pode apresentar um potencial para proteger o direito autoral dos dados, quando eles estão envolvidos em ambiente digital. O Blockchain fornece um método para estabelecer a existência de uma transação em um momento específico, podendo ser verificada por qualquer parte interessada, incluindo o rastreamento da proveniência dos dados.

O objetivo então deste trabalho busca investigar a aplicação da tecnologia Blockchain para a proteção do direito autoral de dados e relatar como está sendo utilizado. Como metodologia realizou-se uma revisão sistemática de literatura a fim de verificar como a tecnologia do Blockchain tem sido aplicada para comprovação dos direitos autorais de dados. As estratégias utilizadas nessa metodologia foram baseados no protocolo de revisão sistemática.

A metodologia então segue com a escolha da base de dados, então foi escolhido a base de dados Scopus, como termo descritor utilizou-se os termos Blockchain, intellectual property copyright e a tecnologia Blockchain. Os tipos de documentos foram analisados todos os documentos recuperados, composta por artigos de periódicos, capítulos de livros e artigos de anais de evento, o ano de publicação a coleta não foi delimitada por valor temporal, não foram excluídos nenhum tipo de documento, o processo de seleção dos atributos referentes a cada documento recuperado foram armazenados em um software de planilha extraindo as seguintes informações: ano de publicação, título do artigo, quantidade de citações, resumos e palavras-chaves.

O processo de análise, foi aplicado o método análise do conteúdo, adotando a análise léxica, tendo como unidade o registro da palavra, utilizando a regra de numeração de presença conforme descrito por Bardin. Para tanto foi utilizado a ferramenta Text Analyser, que possibilita realizar a análise estatística de um texto permitindo descobrir palavras-chave, posteriormente utilizou-se a linguagem R para geração da nuvem de palavras.

Mediante a leitura dos resumos realizou-se a análise categorial proposta no método de análise de conteúdo para verificar a principal abordagem do uso do Blockchain no contexto de proteção de dados autorais de direitos autorais. Essa atividade ela permitiu a construção de um quadro com as seguintes categorias: tipo de dado, técnica, processo e descrição do processo.

Foram recuperados 80 trabalhos na base de dados Scopus, após a coleta os resumos foram agrupados em um único arquivo resultando em um arquivo com 14 páginas de texto. A análise léxica realizada pela ferramenta Text Analyser nos resumos e nas suas palavras chaves demonstrou que os termos dados e Blockchain são os mais recorrentes nos trabalhos recuperados, incluindo os termos tecnologia, sistema, bitcoin e segurança.

A análise das palavras-chave dos documentos, então aí pode-se inferir que prevalece questões voltadas à segurança dos dados, efetivado pelos ternos e security e privacy. Ressalta-se também que o uso do Blockchain pode estar voltado para a proteção de transações que envolvem dinheiro digital como o bitcoin.

Os documentos recuperados relacionados à proteção autoral dos dados e o Blockchain são publicados na base de dados Scopus a partir de 2016, isso demonstra que a temática é recente na literatura e apresenta um crescimento de 260% do ano de 2016 para o ano de 2017.

Os trabalhos recuperados que relatam sobre o uso do Blockchain para a proteção de direitos autorais, então o Blockchain ele é aplicado em dados identificados pelos autores como dados de pesquisa, dados digitais ou simplesmente dados, explicitando com textos dos quais os dados estão inseridos. Os artigos descrevem e discutem técnicas e ou processos utilizados como Blockchain, MyCelia para a música, o CryptSubmite para manuscritos, os contratos inteligentes e marca d'água para obras de artes.

Os principais benefícios e oportunidades relatados nos artigos destaca-se aqueles para ter a precisão e a acessibilidade dos dados de direitos autorais, a transparência nos processos, o meio para evitar a falsificação dos dados e o gerenciamento dos direitos autorais.

Como considerações finais nós destacamos que dos 80 trabalhos recuperados, apenas oito apresentam a aplicação do Blockchain para proteção autoral de dados, mesmo os trabalhos que discutem aspectos relacionados à proveniência dos dados esses descrevem a facilidade de integração de dados de diversas fontes, o fornecimento de informações dessas fontes, a origem dos dados, a verificação de adulteração dos dados e em quais dados foram feitas as transformações, no entanto não vinculam diretamente com direito autoral.

Conclui-se que o uso do Blockchain no contexto de proteção de direitos autorais não é foco da maioria das pesquisas recuperados, situação que torna essa temática uma oportunidade para pesquisa em diversas áreas do conhecimento, visto que a utilizá-la pode-se contribuir com proteção e comprovação do direito autoral de dados.

Obrigada.

Slides da apresentação

Título: Proteção autoral de dados: uso de Blockchain.

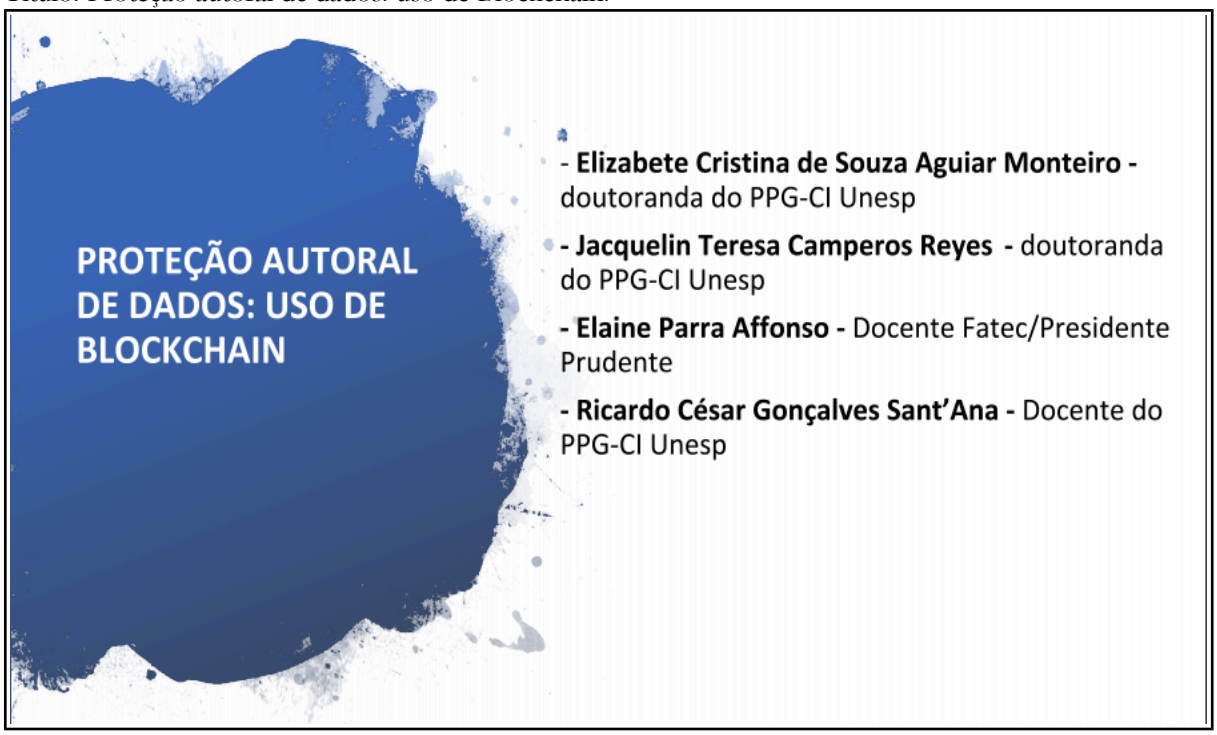

Disponível em: http://dadosabertos.info/enhanced_publications/idt/presentation.php?id=26

Tecnologia Blockchain: um novo paradigma no Ciclo de Vida dos Dados

Jailton Cardoso da Cruz[a]

Resumo: A tecnologia Blockchain, também denominada Distributed Ledger Technology, é uma inovação desruptiva, ou seja, ela representa um salto inesperado e de grande impacto no que diz respeito a gerenciamento de dados. Criado pela necessidade de um sistema eficiente, econômico, confiável e seguro para conduzir e registrar transações financeiras. Este trabalho apresenta a Tecnologia Blockchain, no contexto do Ciclo de Vida dos Dados, neste sentido, daremos uma ênfase à nova perspectiva de sua utilização para a preservação de dados e as diversas possibilidades de aplicação nas ciências abertas, bem como no ciclo de vida dos dados de pesquisa, para tal, utilizaremos uma estratégia de revisão bibliográfica com foco em estudos referentes à tecnologia Blockchain, bem como o referencial teórico sobre bibliotecas de dados e, a partir daí, fazer uma intersecção sobre o uso da tecnologia Blockchain nas diversas fases do ciclo de vida dos dados científicos com objetivo de apresentar o potencial da tecnologia Blockchain como infraestrutura tecnológica para a gestão de dados científicos. Ao final apresentamos algumas discussões a respeito do tema.

Palavras-chave: Tecnologia Blockchain. Ciências Abertas. Ciclo de Vida dos Dados.

Blockchain thecnology: a new paradigm in the Data Life Cycle

Abstract: Blockchain technology, also known as Distributed Ledger Technology, is a desruptive innovation, that is, it represents an unexpected and major leap in data management. Created by the need for an efficient, economical, reliable and secure system for conduct and record financial transactions. In this paper we present the Blockchain Technology, in the context of the Data Life Cycle, in this sense, we will emphasize the new perspective of its use for the preservation of data and the diverse possibilities of application in the open sciences, as well as in the life cycle of the To do this, we will use a literature review strategy focused on studies related to Blockchain technology, as well as the theoretical reference on data libraries and, from there, to make an intersection on the use of Blockchain technology in the various phases of the life cycle of scientific data in order to present the potential of Blockchain technology as a technological infrastructure for the management of scientific data. At the end we present some discussions on the subject.

Keyword: Blockchain Technology. Open Science. Data Life Cicle.

a Instituto Federal de Educação, Ciência e Tecnologia de Alagoas (IFAL). E-mail: jailtonccruz@gmail.com. ORCID: https://orcid.org/0000-0001-9285-7447. Currículo: http://lattes.cnpq.br/9366016044068759

1 Introdução

Com o desenvolvimento das tecnologias para o armazenamento, acesso e compartilhamento das informações científicas e, mais recentemente, com as possibilidades que surgiram com o advento da internet, a utilização das novas tecnologias tem sido um desafio para garantir a preservação da produção científica, desde sua origem bem como garantir todo o ciclo de vida dos dados científicos.

Segundo (ARELLANO,2008, p20, apud SOUZA, 2012),

> […] a preservação digital é uma preocupação dos profissionais da informação, devido principalmente ao uso extensivo que tem sido feito das tecnologias digitais e do registro de informações em soluções cada vez mais sofisticadas e complexas.

Dentre estes desafios referentes à utilização da tecnologia da informação na preservação da produção científica, surge a tecnologia Blockchain como um novo paradigma nesse campo. Blockchain, conforme (FORMIGONE, 2017, p6),

> Em linhas gerais, pode-se dizer que se trata de um sistema distribuído de base de dados em log, mantido e gerido de forma compartilhada e descentralizada (através de uma rede peer-to-peer, P2P), na qual todos os participantes são responsáveis por armazenar e manter a base de dados. A tecnologia foi construída tendo em mente quatro principais características arquiteturais: segurança das operações, descentralização de armazenamento e/ou computação, integridade de dados e imutabilidade de transações.

O relatório Ways to Use Blockchais in Libraries (ALMAN, 2017) publicado no site Blockchais for Information Professional, que faz parte do projeto de Sue Alman e Sandy Hirish, apresenta alguns cenários em que os profissionais da informação podem fazer com o uso da tecnologia no Blockchain:

- Criar um sistema de metadados aprimorado para bibliotecas e data centers;
- Controlar os direitos de primeira venda digital e propriedade;
- Conectar-se a uma rede de bibliotecas/universidades;
- Apoiar coleções baseadas na comunidade;
- Hospedar compartilhamento digital ponto a ponto;
- Facilitar a parceria entre centros e organizações.

2 Objetivos

Este artigo tem por objetivo apresentar uma visão geral da tecnologia Blockchain, e sua aplicação no campo das ciências de dados.

3 Procedimentos Metodológicos

Quanto ao percurso metodológico, a pesquisa foi desenvolvida uma pesquisa exploratória com objetivo de proporcionar maior conhecimento da tecnologia. Neste sentido, foi feito de uma revisão de literatura, onde traçamos as estratégias para desenvolvimento do método de pesquisa a ser utilizado com as seguintes fases:

- Revisão das referências bibliográficas referentes ao tópico Gestão de Dados Científicos na Perspectiva da e-Science

- Estudo da tecnologia Blockchain a partir do referencial teórico;
- Estudo das bibliotecas de dados, o ciclo de vida dos dados científicos, Gestão de Dados de Pesquisa (GDP);
- Pesquisa bibliográfica sobre a utilização da tecnologia Blockchain nas bibliotecas de dados e nas ciências;
- Analise sobre como a tecnologia Blockchain poderia ser aplicada no ciclo de vida dos dados científicos.

Neste sentido desenvolvemos o trabalho que, devido a característica desruptiva da tecnologia Blockchain traz uma reflexão sobre seu uso no campo da e-Science.

4 A Tecnologia Blockchain

Instrumentos de confiança, tais como papel-moeda, moedas cunhadas, carta de crédito e sistemas bancários surgiram para facilitar a troca de valor e proteger compradores e vendedores. Esses métodos tradicionais de transações conforme (GUPTA, 2017) pode ser caro, em parte porque envolve intermediários que cobram taxas por seus serviços. É claramente ineficiente devido a atrasos na execução de contratos e à duplicação de esforços necessários para manter vários livros. Também é vulnerável porque, se um sistema central (por exemplo, um banco) for comprometido, devido a fraude, ataque cibernético ou um simples erro, toda a rede comercial será afetada

Tais transações vêm aumentando exponencialmente, seja em sistemas bancários, cartões de crédito, transações e-commerce, bem como outras transações entre fornecedores e consumidores via internet, e proporcionalmente a preocupação com questões relativas a segurança, vulnerabilidade e confiabilidade.

Blockchain é uma tecnologia relativamente nova, também conhecida como Distributed Ledger Technology (DTL). Em 2008 um indivíduo com o pseudonimo Satosh Nakamoto (NAKAMOTO, 2008) publicou um whitepaper seminal, apresentado ao grupo de discussão "The Cryptography Mailing", que delineou o conceito de uma criptomoeda denominada Bitcoin, cuja proposta, conforme (FORMIGONE, 2017), era a criação de uma moeda digital que funcionasse em uma rede peer-to-peer (P2P) que permitisse o envio de pagamentos online e forma totalmente segura, sem o envolvimento de instituições financeiras, para todos os participantes da rede. Nesse sentido, Blockchain foi criado motivado pela necessidade de um sistema eficiente, econômico, confiável e seguro para conduzir e registrar transações financeiras. Daí surge a pergunta: qual a relação entre Blockchain e Bitcoin? Blockchain é a plataforma utilizada para o funcionamento da rede Bitcoin e de várias outras criptopmoedas. Ainda de acordo com (FORMIGONE, 2017, p.3),

> "Após a implantação das primeiras criptomoedas, vários especialistas observaram que propriedades intrínsecas à tecnologia Blockchain (tais como segurança, resiliência, inviolabilidade e imutabilidade) poderiam ser usadas em vários outros tipos de aplicações. Neste sentido, as plataformas de desenvolvimento Blockchain evoluíram e permitiram a inserção de transações mais complexas através dos contratos inteligentes denominados (smart contracts).

O Blockchain deve seu nome à forma como armazena dados de transações – em blocos (blocks) que são vinculados para formar uma cadeia (chain). Blockchain, de acordo com (LEMIEUX, 2017 apud NARAYANAN, 2016 p. 2271),

> "é um tipo de tecnologia de contabilidade distribuída na qual, conjuntos confirmados e validados de transações são mantidos em blocos, e os blocos são encadeados de uma forma que dificulta a adulteração e permite que um participante apenas acrescente blocos adicionais de forma sequencial. Assim, cada cadeia começa com um bloco original, ou gênese, seguido por uma sequência ordenada por tempo de blocos, em que cada bloco contém um hash - um número aleatório de 256 bits gerado computacionalmente a partir de informações de entrada do bloco anterior na cadeia. Isso forma uma longa cadeia contínua de hashes, daí o nome Blockchain (veja a Fig. 1). O comprimento do Blockchain é referido como altura do bloco, isto é, a distância entre o gênesis e o último bloco da cadeia".

Figura 1: Estrutura do Blockchain.

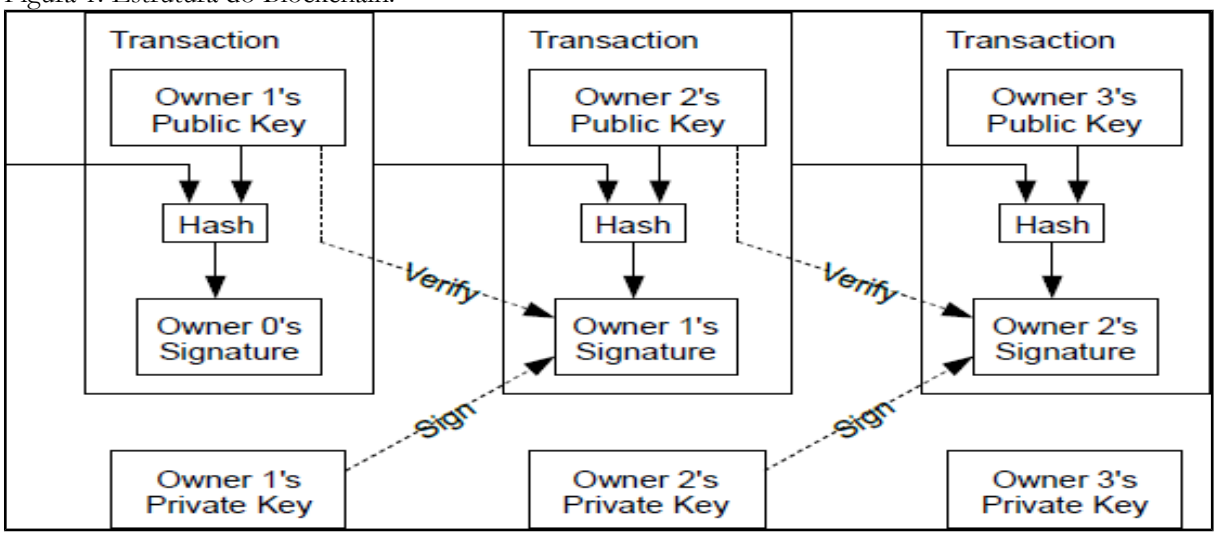

Fonte: Nakamoto (2008).

Blockchain pode ser visto com uma "leadger of facts", ou livro razão, replicada em computadores que participam e uma rede peer-to-peer onde, conforme (FORMIGONI, 2017):

- O ledger é um livro de registros digital, no qual uma vez validado um registro, este nunca mais poderá ser apagado;
- Um fato (fact) pode significar várias coisas, desde uma transação monetária, a um conteúdo de determinado documento, ou até mesmo um programa de computador, contendo, em algumas plataformas, até uma base de dados pequena;
- Os membros participantes da rede podem, ou não ser anônimos e são chamados peers ou "nós";
- Toda operação ou transação dentro da ledger é protegida por tecnologias criptográficas de assinatura digital, inclusive para identificar os nós emissores e receptores das transações;
- Quando um nó deseja adicionar ao ledger um fato novo, é necessário um consenso entre todos ou alguns nós previamente determinados da rede, para decidir se um fato pode ser registrado no ledger;

- Havendo consenso, o fato será escrito e nunca mais poderá ser apagado, em tese, um processo levemente semelhante à escritura e registro de um imóvel no Brasil.

A tecnologia Blockchain, além das criptomoedas, pode ser utilizada em diversas áreas de negócio tais como: serviços financeiros, seguros, saúde, internet das coisas. Como visto, a possibilidade de aplicação da tecnologia Blockchain nas diversas áreas de atividade tem despertado o interesse, não só da área financeira, neste sentido, o renomado jornal The Economist (ECONOMIST, 2015) crava a tecnologia Blockchain como A Próxima Grande Coisa, "The Next Big Thing". Portanto, devemos acompanhar o desenvolvimento desta tecnologia e identificar de quais formas podemos usufruir dela.

5 Ciclo de Vida dos Dados

Em geral, a vida útil dos dados de pesquisa não se encerra ao final da pesquisa. Tais dados devem ser preservados para compartilhamento e reúso. Neste sentido várias propostas de ciclo de vida de dados científico foram apresentadas com objetivo de descrever todas as etapas do processo de curadoria dos dados. Dentre os diversos Ciclos de Vida dos Dados Científicos, podemos destacar o ciclo de vida dos dados DataOne (Sayão e Sales, 2015), o Ciclo de Vida de Dados para Ciência da Informação Sant'Ana (Sant'Ana, 2016, p4).

Durante o processo de pesquisa, os dados, muitas vezes, ficam armazenados localmente computadores particulares dos pesquisadores, em algum meio digital de armazenamento ou em repositórios dos laboratórios de pesquisa. Estes dados ficam vulneráveis a perda, uso indevido por pessoas não autorizadas, não permitindo assim que se cumpram todas as fases do ciclo de vida dos dados, conforme o ciclo de vida exemplificado na (Fig. 2). Por outro lado, existe uma necessidade latente dos pesquisadores com relação ao compartilhamento e preservação dos seus dados. Neste sentido, Sales e Cavalcanti (2015) recomendam que sejam adotadas práticas de preservação dos dados digitais e que a curadoria de dados de pesquisa se apresenta como uma solução a ser adotada para se atingir o objetivo de ter segurança na preservação e compartilhamento dos dados, sendo o desenvolvimento de repositórios de dados uma alternativa para tal preservação e o exercício da curadoria digital.

Figura 2. Ciclo de Vida dos Dados.

Fonte: Sayão e Sales (2015).

Em 2017, foi publicado no Digital Science Report um artigo com título "Blockchain for Research", (ROSSUM, 2017), que pretende, conforme dito em sua introdução, ampliar o potencial do Blockchain transformar a comunicação acadêmica e a pesquisa em geral, destacando as possibilidades de como a Tecnologia Blockchain pode tocar muitos aspectos críticos da comunicação acadêmica, incluindo transparência, confiança, reprodutibilidade e crédito.

6 Possíveis Usos do Blockchain pelos Profissionais da Informação

A utilização da tecnologia Blockchain tem sido objeto de estudos de vários pesquisadores. De acordo com (BRAW, 2018), a tecnologia promete uma maneira nova e descentralizada de gravar e armazenar dados. Aplicação da tecnologia Blockchain nas diversas áreas de atividade tem despertado o interesse, não só da área financeira, bem como nas áreas médicas, governo, segurança. Dentre outras áreas.

7 Blockchain e o Ciclo de Vida dos Dados

Devido a sua característica de tornar ativos digitais imutáveis, transparentes, externamente prováveis, validos e distribuídos (e potencialmente permanentes), blockchain apresenta-se como a tecnologia que pode ser utilizada em todo o ciclo de pesquisa, desde sua criação até catalogação e armazenamento, sendo assim, em todas as fases do ciclo de vida pode ocorrer em um sistema Blockchain. Este tópico está baseado em (BARTLING, 2018).

Alguns sistemas de banco de dados possuem características Blockchain. BigchainDB é um exemplo de banco de dados distribuído big data com características Blockchain (controle descentralizado, imutabilidade, e a transferência de ativos digitais). Tais bancos de dados podem ser utilizados para realizar todas as fases do ciclo de vida dos dados além de permitir o acesso aos dados conforme as condições de acesso já apresentadas.

Aquisição de dados

Todos os dados de pesquisa que são adquiridos podem ir para um banco de dados Blockchain. Todos os dados que são adquiridos durante um experimento podem estar disponíveis primeiro para um determinado público (secure access). Poderia se tornar abertamente disponível e poderia ser reutilizado por outros pesquisadores (open access). No entanto, isso não deve necessariamente ser o caso, pois um pesquisador pode controlar quem pode acessar os dados (managed access).

Gerenciamento dos dados e análise

A análise dos dados, pós-processamento e estatística pode ser protocolizada no banco de dados Blockchain e comprovada aos pares.

Compartilhamento dos dados

Através de bancos de dados Blockchain, os dados podem ser armazenados e compartilhados. As tecnologias Blockchain podem fornecer uma redundância e disponibilidade de dados, por ex. IPFS, que de acordo com IPFS (2018), é um novo protocolo de distribuição hipermídia, endereçado por conteúdo e identidades. A criptografia associada pode assegurar que os dados estejam disponíveis apenas para certas pessoas, grupos e a partir de pontos de tempo definidos.

Publicação e arquivamento

A tecnologia Blockchain pode ser usada para "assinar" publicações anônimas com credibilidade fornecendo "assinaturas". Avaliação de pesquisa

Um Blockchain (por exemplo, Namecoin) pode ser usado para registrar e manter identificadores de pesquisa exclusivos como (ORCID) ou links para publicações ou conjuntos de dados (como o DOI).

Fundo de pesquisa

Blockchain poderia permitir muitas novas maneiras de distribuir dinheiro para pesquisa. Por exemplo, o provedor de financiamento de pesquisa pode escolher uma combinação de características de diferentes tipos de comportamento do pesquisador que deseja apoiar.

Embora seja uma tecnologia cuja aplicação já é bastante difundida mercado de criptomoedas, seu uso no ciclo de vida dos dados carece de uma maior investigação.

8 Considerações Finais

Pelo exposto, percebe-se que a tecnologia Blockchain, tem características que se adequam a resolver alguns dos problemas da gestão de dados científicos, cujo problema é a forma multifacetada de sua gestão, onde cada fase do ciclo de vida necessita de uma tecnologia ou método para ser aplicado.

Com a tecnologia Blockchain pode-se envolver todo do ciclo de dados de forma descentralizada desde a criação, gerenciamento, armazenamento, publicação e reúso.

Sendo uma tecnologia nova, muitos desafios ainda deverão ser superados, tais como, a necessidade de um maior conhecimento da tecnologia, adicionar mais recursos, como acesso a banco de dados e como medir a produtividade dos pesquisadores, seja através dos institutos de pesquisa ou um banco de dados de pesquisadores.

Olhando para um novo horizonte, o Blockchain, como uma tecnologia desruptiva ainda necessita de muitos estudos e investimentos e as universidades, institutos de pesquisa e órgãos fomentadores de pesquisa devem investigar o potencial da tecnologia Blockchain e sua aplicação no Ciclo de Vida dos Dados.

Referências

ALMAN S. e HIRISH S. Ways to Use **Blockchain in Libriries em Blockchain for Information Profession**, 2017 [Online] Disponível em https://ischoolblogs.sjsu.edu/Blockchains/Blockchains-applied/applications. Acessado em: 09 jul. 2018.

BARTLING S. **Blockchain for Science and Knowledje Creation em Blockchain for Science**. Disponível em https://docs.google.com/document/d/1Uhjb4K69l0bSx7UXYUStV_rjuPC7VGo0ERa-7xEsr58/edit#. Acessado em 22 jul. 2018.

BROWN, Jessica Leigth, Blockchain in the Libririan? Researcheres Explore Potential Applications. EdSurge, 2018 [on line]. Disponível em https://www.edsurge.com/news/2018-02-

01-blockchain-in-the-library-researchers-explore- potential-applications Acessado em 09/07/2018.

ECONOMIST The, **The Next Bit Thing: or is it,** 2015. Disponível em: https://www.economist.com/special- report/2015/05/09/the-next-big-thing Acessado em: 01 out 2018.

FORMIGONI, J. R. F.; BRAGA, A. M.; LEAL, R. L. V. **Tecnologia Blockchain: uma visão geral**. 2017. Disponível em: https://www.cpqd.com.br/wp- content/uploads/2017/03/cpqd-whitepaper-Blockchain-impresso.pdf. Acessado em: 01 jul. 2018.

GUPTA, M. **Blockchain for Dummies®**, IBM Limited Edition. Wiley Brand John Wiley & Sons, Inc., 2017 IPFS – **The Permanent Web**, 2018 . Disponível em https://github.com/ipfs/ipfs. Acessado em 17 set. 2018.

LEMIEUX, V. L. **A Typology Blockchain Recordkeeping Soluctions and Some Reflections on their Implications for the Future of Archival Preservation**, 2017 [online]. Disponível em http://dcicblog.umd.edu/wp-content/uploads/sites/13/2017/06/Lemieux.pdf. Acessado em: 20 jul 2018.

SAYÃO, L. F., SALES, L. F. **Guia de gestão de dados de pesquisa para bibliotecários e pesquisadores**. Comissão Nacional de Energia Nuclear: Rio de Janeiro. 2015. Disponível em: http://carpedien.ien.gov.br/bitstream/ien/1624/1/GUIA_DE_DADOS_DE_PESQUISA.pdf. Acesso em: 29 set. 2018.

SOUZA, A. H. R. L.; OLIVEIRA A. F.; D'Avila R. T. **O Modelo de Referência OAIS e a Preservação Digital Distribuída** Ci. Inf., Brasília, DF, v. 41 n. 1, p.65-73, jan./abr., 2012 Acesso em 28 set. 2018.

NAKAMOTO, S. **A Peer-to-peer Electronic Cash System**, 2008. Disponível em: https://bitcoin.org/bitcoin.pdf Acessado em: 28 set 2018.

ROSSUM, J. V., **Blockchain for Researh: Perspectives on a New Paradigm for Scholarly Communication**. DIGITAL SCIENCE REPORT, Nov/2017 DOI: https://org/IO.6084/m9.figshare.5607778 Acessado em 02 jul 2018**.**

SALES, L. F., CAVALCANTI, M. T. **Seleção e avalição de coleções de dados digitais de pesquisa: uma possível abordagem metodológica**. Informação & Tecnologia (ITEC): Marília/João Pessoa, 2(2): 88-105, jul./dez., 2015. Disponível em: http://periodicos.ufpb.br/index.php/itec/article/view/34134/17537. Acesso em: 29 set. 2018.

Vídeo da apresentação

Título: Tecnologia Blockchain: um novo paradigma no Ciclo de Vida dos Dados.

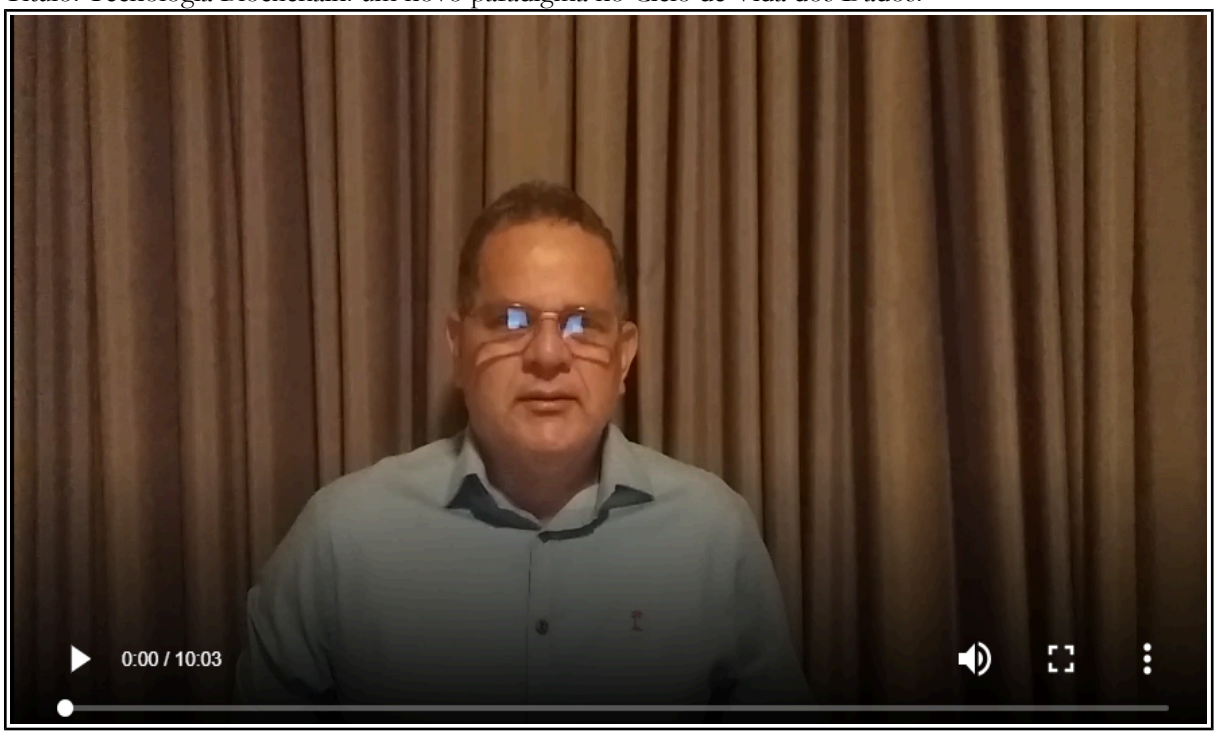

Disponível em: http://dadosabertos.info/enhanced_publications/idt/video.php?id=27

Transcrição da apresentação

Senhores alunos e professores, meu nome é Jailton Cardoso da Cruz, estou apresentando o artigo "Tecnologia Blockchain: um novo paradigma nas ciências abertas" apresentado no 2º Workshop de Informação, Dados e Tecnologia – WIDAT 2018 da Universidade Federal da Paraíba.

O que seria a tecnologia Blockchain? Então uma das finalidades do Blockchain e garantir a preservação da produção científica desde sua origem, e garantir todo o ciclo de vida dos dados, ou seja, neste artigo nós queremos aplicar, estudar a aplicação da tecnologia Blockchain para garantir a preservação na produção científica, e garantir todo o ciclo de vida dos dados científicos.

Então o que seria a tecnologia Blockchain? Em linhas gerais posso dizer que trata-se de um sistema distribuído em de base de dados enorme, mantida e gerida de forma compartilhada e descentralizada através de uma rede peer-to-peer, p2p, na qual todos os participantes são responsáveis por armazenar e manter a base de dados. Então alguma de suas características arquiteturais eram uma base de dados descentralizar, criptografada onde os dados são criptografados e existe um consenso entre os participantes.

A tecnologia Blockchain pode ser vista como um "leadger of facts" ou seja um livro razão. Qual a ideia do livro razão? E que após a informação ser inserida do livro razão ela não pode ser mais excluída ou alterada, então nesse sentido a tecnologia Blockchain ela seria um livro razão aplicado a rede de computadores que participam da rede peer-to-peer, onde toda operação ou transação dentro desse livro razão é protegido por tecnologia criptográficas e assinatura digital, inclusive para identificar os novos emissores e receptores das transações.

Quando nó adicionar um novo leadger, ou seja, um novo registo ou um novo fato é necessário o consenso entre todos ou alguns dos previamente destinados a ele, para decidir se o fato pode ou não ser registrado no leadger, ou seja, no livro razão. Havendo consenso o fato será escrito e nunca mais poderá ser apagado, ou seja, em tese um processo levemente semelhante à escritura de registro de imóvel no Brasil.

Então essa característica da tecnologia Blockchain faz com que os dados sejam preservados, possa preservar dados sem que possam ser alterados ou excluídos, dessa forma nós podemos utilizar todo o ciclo de vida de dados, desde o seu planejamento até a sua distribuição e reúso.

Então alguns problemas que existem atualmente em relação à ciência de dados e a apresentação de dados científicos, em questão do armazenamento, questão se são vulneráveis a perda, uso indevido por pessoas não autorizadas, o compartilhamento dos dados, a forma multifacetada de sua gestão e cada fase do ciclo de vida de dados necessita de uma tecnologia um método para ser aplicada. Então esses problemas fazem com que os dados científico fiquem descentralizados, desestruturados e fragmentados em diversas tecnologias e em diversas plataformas, outro problema é que com relação ao armazenamento é que os dados hoje são armazenadas em laboratórios ou equipamentos dos pesquisadores, vulneráveis a perdas, por exemplo se um computador o equipamento do pesquisador tem algum problema aqueles dados que estão vulneráveis a perda e aí você perde o sentido da preservação e reúso, de ser reutilizado por outros pesquisadores.

Algumas aplicações que poderiam ser na Blockchain na ciência de dados, seria biblioteca de dados, ciências sociais, gerenciamento das pesquisas, preservação digital e gerenciamento de dados. Nesse sentido a tecnologia Blockchain ela pode tornar os ativos digitais e mutáveis, então motivação para a utilização da tecnologia, tornar a sua pesquisa transparente, extremamente provável você pode utilizar o armazenamento para provar que aquele dado de pesquisa foi realmente um dado verdadeiro, provar a validade daquele dado até que o Blockchain possa aplicar em todo o ciclo de vida de pesquisa desde a sua criação até catalogação e armazenamento, ou seja, todas as fases do ciclo de vida podem ocorrer no Blockchain.

Então referenciando-se ao ciclo de vida dos dados de pesquisa onde temos desde a criação e entrega dos dados, ou seja, a parte com o momento do planejamento, criação e captação dos dados, nós podemos usar a tecnologia Blockchain para armazenar os dados que foram capturados, por exemplo, por um sensor, gerenciar os dados você permitir o acesso a eles através do acesso aberto, semiaberto ou gerenciado, criar os repositórios e arquivo de dados, arquivar os dados em repositório e futuro reúso dos dados.

Então algumas aplicações não podemos utilizar a tecnologia Blockchain seria por exemplo a publicação e arquivamento onde a tecnologia pode ser usado para assinar a publicações com credibilidade e fornecendo assinaturas digitais através de certificados criptográficos.

Avaliação de pesquisa Blockchain, por exemplo, pode ser usado para extrair e manter indicadores de pesquisas exclusivas como a Siri ou links para publicações em conjunto de dados como dói, ou seja, você pode usar um identificador tanto para os dados como para o pesquisador.

Gerenciamento de dados de análises dos dados pós-processamento e estatística, pode-se ser protocolizada no banco de dados Blockchain e comprovada por pares, ou seja, a avaliação por pares dos artigos e dados de pesquisa podem ser feitos através da tecnologia Blockchain, os avaliadores dos dados de pesquisa podem utilizar a cadeia de Blockchain para avaliar e assegurar que aqueles dados são verdadeiras. Também temos a questão da curadoria onde permite utilizar o mecanismo de gerenciamento de acesso aos dados quais sejam, acesso aberto, gerenciado, seguro e fechado, acesso aberto para o público tanto o dado quanto o artigo, gerenciado permitir que níveis de acesso para os dados, seguro, ou seja, você para acessar aqueles dados você precisa ser identificado, autenticado e fechado apenas pessoas autorizadas têm acesso àqueles dados.

Outra aplicação seria o financiamento de pesquisas, com o Blockchain ele é utilizado como uma tecnologia utilizada para o bitcoin, então a origem da tecnologia blockchain é o bitcoin, poderia usar as criptomoedas para financiamento de pesquisa, além de avaliar a produção dos pesquisadores para financiamento.

Então o que eu posso fazer? O que poderia ser feito? Em cada fase por exemplo na durante o processo de revisão por pares, você poderia querer um hash e os avaliadores assinarem aqueles hash para poderem fazer a sua avaliação. Então nós poderemos utilizar a tecnologia Blockchain em todos ciclos de vida dos dados, são apenas forma de mostrar que a tecnologia pode aplicada nas ciências abertas.

Gostaria de agradecer a audiência e citar aqui acessem o site da Universidade Federal da Paraíba e meu contato é jailtonccruz@gmail.com. Obrigado.

A disseminação de informações associadas a epidemia do Zika Vírus: uma pesquisa a partir de dados coletados no Twitter

Guilherme Ataíde Dias[a], *Denysson Axel Ribeiro Mota*[b], *André Luiz Dias de França*[c] *e Eduardo de Santana Medeiros Alexandre*[d]

Resumo: A pesquisa apresentada, no momento em andamento, investiga de que maneira a Ciência da Informação pode fornecer suporte para entendimento de questões que emergem a partir da disseminação de informações acerca do Zika vírus postadas na rede social Twitter. O objetivo principal é investigar a disseminação de informações através de canais formais e informais como redutora de incertezas de uma população imersa em epidemia de Zika Vírus. A pesquisa configura-se com relação aos procedimentos técnicos como bibliográfica, com relação aos objetivos é exploratória e possui natureza quantitativa e qualitativa. O corpus estudado constituiu-se de mensagens disseminadas (tweet) através da rede social Twitter com conteúdos relacionados ao Zika Vírus no período compreendido entre outubro de 2017 até março de 2018. A partir dos dados coletados é possível mencionar que os usuários do Twitter que postam mensagens com o termo "zica" e strings equivalentes, não estão na maioria das vezes fazendo referência às questões de saúde associadas com a epidemia de Zika Vírus. O termo zica (zika) é usado em uma grande variedade de contextos que transcendem o domínio específico da área da saúde. A continuidade da pesquisa possibilitará uma compreensão mais aprofundada do fenômeno.

Palavras-chave: Twitter, Disseminação de dados, Zika vírus.

The dissemination of information associated with the zika virus epidemic: A research based on data collected from the Twitter

Abstract: The ongoing research presented investigates how Information Science can provide support for understanding issues that emerge from the dissemination of information about the Zika virus posted on the social network Twitter. The main objective is to investigate the dissemination of information through formal and informal channels as an element capable of reducing of uncertainties on a population immersed in a Zika Virus epidemic. The research is characterized in relation to the technical procedures as being bibliographic, with regard to the objectives is exploratory and has a quantitative and qualitative nature. The studied corpus consisted of tweet messages disseminated through the social network Twitter with contents related to the Zika Virus in the period between October 2017 until March 2018. From the data collected it is possible to mention that Twitter users who post messages with the term "zica" and equivalent strings are not often referring to the health issues associated with the Zika Virus epidemic. The term zica (zika) is used in a wide variety of contexts that transcend the specific domain of health. The continuity of the research will allow a deeper understanding of the phenomenon.

Keyword: Twitter; Data dissemination; Zika virus.

a Universidade Federal da Paraíba (UFPB). E-mail: guilhermeataide@ccsa.ufpb.br. ORCID: https://orcid.org/0000-0001-6576-0017. Currículo: http://lattes.cnpq.br/9553707435669429

b Universidade Federal da Paraíba (UFPB). E-mail: denysson.mota@ufca.edu.br. ORCID: https://orcid.org/0000-0003-2069-134X. Currículo: http://lattes.cnpq.br/1273037072033521

c Universidade Federal da Paraíba (UFPB). E-mail: andreluizjpb@gmail.com. ORCID: https://orcid.org/0000-0002-8278-3664. Currículo: http://lattes.cnpq.br/5684942906411942

d Instituto Federal da Paraíba (IFPB). E-mail: eduardo.ufpb@gmail.com. Currículo: http://lattes.cnpq.br/6047383716536661

1 Introdução[73]

Vários temas relacionados com a área da saúde possuem ligação com a Ciência da Informação. Exemplos de trabalhos que referendam este pensamento podem ser encontrados nos materiais organizados por Duarte e Farias (2009), Galvão e Ricarte (2012) e Pinto e Campos (2013).

De forma mais ampla ilustramos a essência das intersecções entre a Ciência da Informação e a área da saúde através do discurso de Gomez (DIAS, 2016):

> A convergência de questões de informação e questões em saúde é de longa data, sendo a área de informação em saúde rica e pioneira na inovação e pesquisa em informação e em tecnologias de informação. A otimização e atualização de dispositivos e ações de informação têm de responder às demandas intensivas de informação e comunicação que satisfação, em quantidade e qualidade, às metas e finalidades da promoção da saúde e do atendimento clínico. A Ciência da Informação compõe uma das muitas redes inter e transdisciplinares onde essas questões e temáticas são objeto de pesquisa e reflexão (GOMEZ, 2013, p.29).

É de amplo conhecimento que o mundo, e de forma mais marcante os países da América Central e do Sul estão sendo atingidos por uma série de enfermidades atribuídas ao Zika Vírus (Vide Figura 1), como por exemplo, a microcefalia e a Síndrome de Guillain– Barré (DIAS, 2016). Este é um exemplo de fenômeno que pode ser estudado através do prisma da Ciência da Informação.

Figura 1: Distribuição do Zika Vírus – Américas.

Fonte: Organização Mundial de Saúde Apud Dias(2016).

73 Pesquisa financiado pelo CNPq. Processo 427308/2016-0

O Zika Vírus tem como vetores de transmissão os mosquitos denominados de Aedes aegypti e Aedes albopictus, o primeiro com abrangência apenas em regiões tropicais e subtropicais, o segundo podendo sobreviver e hibernar em regiões de clima mais frio (WHO, 2016).

O Zika Vírus tem como vetores de transmissão os mosquitos denominados de Aedes aegypti e Aedes albopictus, o primeiro com abrangência apenas em regiões tropicais e subtropicais, o segundo podendo sobreviver e hibernar em regiões de clima mais frio (WHO, 2016).

No Brasil, a eclosão de casos de doenças hipoteticamente associadas ao Zika Vírus, de forma mais notória a microcefalia, tem como epicentro os estados de Pernambuco e da Paraíba (DIAS, 2016).

A disseminação de informações sobre o Zika Vírus, tanto nos círculos acadêmicos e científicos formais, como nos informais na mídia de massa através das plataformas de rede social, apresentam inúmeras oportunidades de investigação para o pesquisador em Ciência da Informação. É nesta vertente que esta pesquisa está estruturada, através da análise de dados através da Análise de Redes Sociais (ARS) e de ferramentas de visualização que possibilitam a compreensão da disseminação de informações relacionadas com a epidemia de Zika Vírus, contribuindo com os resultados obtidos para o campo científico e para a sociedade, visto a urgência e relevância da temática (DIAS, 2016).

2 Objetivos

A pesquisa em tela investiga de que maneira a Ciência da Informação pode fornecer suporte para entendimento de questões que emergem a partir da disseminação de informações acerca do Zika vírus postadas na rede social Twitter. O objetivo principal é investigar a disseminação de informações através de canais formais e informais como redutora de incertezas de uma população imersa em epidemia de Zika Vírus. Os objetivos específicos são: Mapear o fluxo informacional sobre o Zika Vírus no âmbito do Twitter; Identificar as especificidades da disseminação das informações acerca do Zika Vírus no Twitter; Desenvolver software para coletar dados sobre o tema Zika Vírus no Twitter; Produzir visualizações de dados a partir dos dados coletados para gerar novos padrões associativos; Gerar métricas associadas aos dados coletados no Twitter (DIAS, 2016).

3 Procedimentos metodológicos

A pesquisa ora em andamento, configura-se com relação aos procedimentos técnicos como bibliográfica, com relação aos objetivos é exploratória e possui natureza quantitativa e qualitativa (GIL, 2008).

O corpus estudado constituiu-se de mensagens disseminadas (tweets[74]) através da rede social Twitter com conteúdo relacionado ao Zika Vírus. Diversos padrões de grafias associados ao Zika Vírus foram utilizados nas capturas da mensagem. Esta estratégia teve como por objetivo possibilitar a coleta do maior número de mensagens possível relacionadas com o Zika Vírus.

Para a captura dos tweets foi elaborado um script[75] na linguagem de programação Ruby[76]. Esta linguagem foi escolhida por permitir o desenvolvimento rápido de aplicações através de

74 Um tweet é considerado uma postagem na rede social Twitter.
75 Script Disponível a partir do link http://wrco.ccsa.ufpb.br/zika.rb
76 https://www.ruby-lang.org/pt/

acesso simplificado a Application Programming Interface (API) do Twitter e por ser de fácil aprendizado. Os tweets foram obtidos no padrão JavaScript Object Notation[77](JSON).

O script para a captura dos tweets foi implantado em um servidor Debian Linux[78] e capturou mensagens postadas no período compreendido entre outubro de 2017 até março de 2018, integralizando um total de 6 (seis) meses. Os tweets capturados foram armazenados em banco de dados PostgreSQL através do tipo de dados JSON. O script capturou durante o seu período de execução um total de 2.907.720 tweets, das quais mais de 82% são mensagens escritas nas línguas portuguesa, inglesa e espanhola. As consultas ao corpus foram feitas através da Structured Query Language (SQL). Indicamos como obstáculo para a captura dos tweets as eventuais quedas do servidor Debian Linux em virtude de interrupções no fornecimento de energia elétrica na Universidade Federal da Paraíba nos finais de semanas e as interrupções no acesso à internet. Esta situação foi minimizada com ajustes na configuração de parâmetros entre o sistema operacional Debian Linux e a aplicação Ruby para que esta segunda tentasse se recuperar após alguma condição de instabilidade do sistema.

Os tweets capturados foram processados mediante o uso da Linguagem SQL, no ambiente provido pelo Sistema Gerenciador de Bancos de Dados (SGBD) PostgreSQL[79], com a função de exportação dos resultados em formato CSV. Os arquivos com os dados eram então, posteriormente, visualizados ou tratados no SublimeText[80] e/ou OpenOffice[81].

De modo a facilitar a análise dos tweets, foram criados dois arquivos em formato texto. Um arquivo constituído de tweets na língua portuguesa e outro composto por tweets na língua inglesa. Devido à estrutura JSON do tweet conter, em caso de retweet, toda a estrutura de dados do tweet original, o comando SQL buscava por combinações distintas de data/hora e texto, conforme exposto no código da Figura 2. Com isto, garante-se que os tweets originais apareçam apenas uma vez, mas também permite que no caso de dois tweets onde o texto seja o mesmo, por ter os dados de data/hora distintos, ambos sejam recuperados.

Figura 2: Comando SQL para recuperar data/hora de criação e texto do tweet.

```
select
  distinct(
  dados->'created_at', texto)
from tweets
where dados->>'lang' = 'en' or
      dados->>'lang' = 'pt');
```

Fonte: Desenvolvimento nosso.

Para recuperar as hashtags de cada tweet, foi utilizado o comando SQL aqui exibido na Figura 3.

77 https://www.json.org/
78 https://www.debian.org/
79 https://www.postgresql.org/
80 https://www.sublimetext.com/3
81 https://www.openoffice.org

Figura 3: Comando SQL para recuperar hashtags dos tweets.

```
select dados->'lang',
  upper(jsonb_array_elements(
      dados->'entities'-
        >'hashtags')->>'text'),
      count(*)
from tweets
where
      dados->'entities'-
      >'hashtags' != '""' and
      dados->'entities'-
      >'hashtags' != '"[]"'
group by 1, 2;
```

Fonte: Desenvolvimento nosso.

4 Resultados preliminares

As análises iniciais dos arquivos de tweets revelaram alguns fatos curiosos. As postagens de tweets na língua portuguesa continham pouca relação com a questão da Zika e assuntos que remetesse ao tema saúde, a vasta maioria das postagens estão relacionadas com o uso do termo "Zika" em questões coloquiais do dia-adia das pessoas. O Quadro 1 ilustra esta situação.

Quadro 1: Amostra dos conteúdos das mensagens dos tweets capturados.

Mensagem do tweet
Hoje a sessão foi zika
@saladeredacao Caiu por causa do Baldasso, homem Zika
Quando eu casar vou entrar na igreja com um Nike Zika no pé, nada de sapato social...
essa semana que vou ficar sozinho em casa vai ser mais que zika
será q saiu minha zika do fifa
meu gatinho curioso vai dar dengue de tão parado
Hoje foi zika
Meu treinador é Deus, que me botou pra jogar olhou pro campo e disse zica vai lá
Minha vida sexual tá mais parada que Água pra dengue
Hoje a sessão foi zika

Fonte: Dados de pesquisa.

O arquivo texto com tweets em língua portuguesa também foi investigado para se identificar quais as tags mais frequentes no contexto das postagens associadas ao tema Zika. O Quadro 2, apresentado a seguir ilustra os resultados encontrados.

Além das informações relacionadas com o sentido das mensagens disseminadas no Twitter e das hashtags mais frequentes encontradas no corpus, os pesquisadores associados à pesquisa estão investigando parâmetros relacionados com a localização geográfica das mensagens e a aderência dos tweets a assuntos que remetam a questões de saúde.

Quadro 2: Hashtags mais frequentes nos tweets em Língua Portuguesa.

Hashtag	Qtd
MALHAÇÃO	3023
FLAMENGO	1860
DENGUE	1840
ZIKA	1787
ZICO	1770
ZICAÇO	1759
ZICÃO	1751
BBB18	1666
VIVAZICO	1612
TREZEDIASLONGEDOSOL	863

Fonte: Dados de pesquisa.

5 Considerações parciais

Até o estágio atual do desenvolvimento da pesquisa os objetivos específicos elencados foram parcialmente atingidos. Em uma primeira instância é possível mencionar que os usuários do Twitter que postam mensagens com o termo "zica" e strings equivalentes, não estão na maioria das vezes fazendo referência às questões de saúde associadas com a epidemia de Zika Vírus.

O termo zica (zika) tem uso em uma grande variedade de contextos que transcendem o domínio específico da área da saúde. Este uso mostrou-se predominante. É preciso empreender estudos mais aprofundados para entender os motivos que levam a população de Língua Portuguesa (Brasil) a não usar o Twitter como uma ferramenta que possibilite a disseminação de mensagens acerca de um problema de saúde pública, ferramenta esta que poderia ser útil na obtenção de informações sobre o combate ao mosquito vetor do Zika Vírus, bem como no tratamento das enfermidades associadas a este vírus.

Referências

DIAS, G. A. A **Ciência da Informação e a disseminação de informações associadas a epidemia de Zika vírus: uma investigação baseada na Análise de Redes Sociais.** João Pessoa. Universidade Federal da Paraíba. 2016. Projeto de Pesquisa. Chamada Universal – MCTI/CNPq N. 01/2016

DUARTE, Z.; FARIAS, L. (Orgs). **A medicina na era da informaçã**o. Salvador: EDUFBA, 2009.

GALVAO, M. C. B.; RICARTE, I. L. M. **Prontuário do Paciente**. Rio de Janeiro: Guanabara Koogan, 2012.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2008.

GOMEZ, M. N. G. O Domínio das Informações em Saúde. In: PINTO, V. B.; CAMPOS, H. H. (Org). **Diálogos Paradigmáticos sobre informação para a área da saúde**. Fortaleza: Edições UFC, 2013.

PINTO, V. B.; CAMPOS, H. H. (Org). **Diálogos Paradigmáticos sobre informação para a área da saúde**. Fortaleza: Edições UFC, 2013.
WHO. (2016). **Zika virus disease: Questions and answers.** Disponível em: <http://www.who.int/features/qa/zika/en/ >. Acesso em: 03 fev. 2018.

Ciência Aberta: os desafios para concepção da ciência cidadã

Luciana Gonçalves Silva Souza[a], *Izabel Antonina de Araújo*[b] *e Júlia Rocha Ribeiro*[c]

Resumo: Nas últimas décadas, a ciência aberta é tema discutido nas agendas dos governos e organizações mundiais. Esta ciência envolve vários aspectos do processo de pesquisa que se baseia nas novas formas de produção de pesquisa colaborativa, interativa e compartilhada com o cidadão. Nesta perspectiva, países como Nova Zelândia, Reino Unido, Colômbia, Japão, entre outros, estão desenvolvendo vários projetos que promovem o engajamento dos cidadãos na ciência como alternativa para o desenvolvimento de uma cultura de conscientização científica. Esta participação nas decisões e nos processos de seleção dos fluxos de pesquisa que se dá não apenas como observadores e coletores de dados, mas também como profissionais planejadores e avaliadores. Para isso, necessitam de informações de qualidade, plataformas interativas, gestão de dados, entre outros. Nesse sentido, o objetivo deste trabalho pontuar aspectos relacionados aos pilares que compõem a ciência aberta e identificar as ações desenvolvidas por alguns países que visam envolver o cidadão no fazer científico. Trata-se de uma pesquisa qualitativa, de caráter exploratório a partir de uma revisão bibliográfica sobre o tema. Observa a importância da participação cidadã na definição das práticas a serem desenvolvidas no âmbito da ciência, tecnologia e inovação. Considera que pensar em uma ciência aberta requer outras dimensões e condições consideradas essenciais para uma ciência cidadã, como acesso aberto, plataformas abertas, agenda de pesquisas abertas, além da informação de qualidade e literacia científica.

Palavras-chave: Ciência aberta; Ciência cidadã; acesso aberto; dados abertos; participação cidadã.

Open Science: the challenges for the conception of citizen science

Abstract: In the last decades, open science is a topic discussed in the agendas of governments and organizations worldwide. This science involves several aspects of the research process that is based on the new forms of production of collaborative, interactive and shared research with the citizen. In this perspective, countries such as New Zealand, the United Kingdom, Colombia, Japan, Brazil among others, are developing several projects that promote citizen engagement in science as an alternative to the development of a culture of scientific awareness. This participation in the decisions and in the process of selection of the research flows that occurs not only as observers and collectors of data, but also as professional planners and evaluators. For this, they need quality information, interactive platforms, data management, among others. In this sense, the objective of this work is to highlight aspects related to the pillars that compose open science and to identify the actions developed by some countries that aim to involve the citizen in the scientific making. This is a qualitative research, exploratory in nature, based on a bibliographical review on the subject. It observes the importance of citizen participation in defining the practices to be developed in the scope of science, technology and innovation. It considers that thinking about an open science requires other dimensions and conditions considered essential for a citizen science, such as open access, open platforms, open research agenda, and quality information and scientific literacy.

Keyword: Open Science; Citizen science; open access; open data; citizen participation.

a Universidade Federal de Minas Gerais (UFMG). E-mail: lucianags9@gmail.com. Currículo: http://lattes.cnpq.br/3789650380011335

b Universidade Federal de Minas Gerais (UFMG). E-mail: antoninaizabel@gmail.com. ORCID: https://orcid.org/0000-0002-3257-0441. Currículo: http://lattes.cnpq.br/9338705446765393

c Universidade Federal de Minas Gerais (UFMG). E-mail: julia34rr@gmail.com. Currículo: http://lattes.cnpq.br/8948572797557519

1 Introdução

A pesquisa científica produz diversos dados e instrumentos que subsidiam o seu desenvolvimento. Com o avanço da ciência e das tecnologias de informação e comunicação, a produção de grandes volumes de dados passa a se configurar como uma preocupação com relação à organização, guarda e difusão das informações para a sociedade. O movimento de disponibilização dos produtos utilizados e resultantes das investigações científicas passa a ser ressaltado com o conceito de ciência aberta, que pode ser entendida a partir dos seguintes pilares:

- Acesso aberto;
- Dados abertos;
- Investigação / Inovação aberta;
- Redes abertas de ciência;
- Ciência cidadã (PORTUGAL, c2016b).

Dessa forma, constitui a abertura de todo o processo científico, ressaltando, também, o compromisso da ciência com a sociedade. A implantação da ciência aberta impulsiona a inovação e desenvolvimento de produtos, serviços e oportunidades de negócios (PORTUGAL, c2016a). Compreender esses diferentes propósitos da ciência aberta constitui importante caminho para o desenvolvimento de práticas mais inclusivas para compreensão e participação da sociedade nos processos científicos.

2 Objetivos

Este trabalho tem como objetivo pontuar aspectos relacionados aos pilares que compõem a ciência aberta, enfatizando o desenvolvimento da ciência cidadã, por razão de sua importância para a aproximação entre comunidade científica e sociedade, buscando fazer com que seja compreensível a importância de ambos no desenvolvimento das ações cotidianas.

3 Procedimentos metodológicos

O presente artigo foi desenvolvido utilizando como método a pesquisa qualitativa, de caráter exploratório, pois o tema ainda é pouco explorado no cenário nacional. Foi realizada uma revisão bibliográfica tendo por referência artigos científicos e documentos governamentais orientadores, buscando compreender a ciência aberta e ciência cidadã e a aplicação prática desse conceito, bem como a identificação de alguns projetos de ciência cidadã praticados por alguns países.

4 Resultados

Apresenta-se, nessa sessão, as informações obtidas a partir do levantamento bibliográfico proposto.

4.1 Ciência aberta

A ciência aberta propõe a abertura e a divulgação das atividades vinculadas ao campo científico, fazendo com que todos os atores envolvidos nas investigações compreendam com clareza e acompanhem todo o processo realizado. As ações de ciência aberta precisam incluir aspectos relacionados aos denominados pilares de sua sustentação: acesso aberto, dados abertos, investigação / inovação aberta, redes abertas de ciência e ciência cidadã, conceitos que serão brevemente apresentados a seguir.

O acesso aberto diz respeito à livre disponibilização de documentos científicos na internet, seja por meio de sua difusão em plataformas digitais, como os repositórios, que podem ser institucionais ou temáticos (chamada via verde, conforme a Budapest Open Access Iniciative), ou pela publicação dos conteúdos em periódicos de acesso aberto (via dourada) (MARRA, 2014).

Essas estratégias de acesso aberto aumentam a visibilidade, o acesso e o uso das produções científicas, favorecendo o progresso da ciência e o acompanhamento das atividades realizadas, ao oferecer à sociedade acesso facilitado aos documentos produzidos. O processo de abertura de dados parte de um movimento ocasionado pela identificação da necessidade de disponibilizar conteúdos produzidos por segmentos sociais como agências governamentais, órgãos de pesquisa e indústrias, constituindo informações fundamentais para o desenvolvimento científico (SANTOS, 2017).

A investigação / inovação aberta compreende aspectos relacionados à docência e às práticas educativas voltadas à melhoria do ensino e aprendizagem, promovendo retorno científico a partir da compreensão e aplicação de diferentes práticas com resultados positivos desenvolvidas em diferentes países, contextos e formas de ensino (POMBO, 2018).

As redes abertas de ciências constituem grupos de investigadores em colaboração que compartilham e constroem novos conhecimentos. São desenvolvidas pesquisas e projetos que buscam integrar especialidades e conhecimentos diferentesem prol de um objetivo (PEREIRA, 2018).

A ciência cidadã, assunto que permeia as discussões do presente artigo, compreendendo a participação da sociedade na construção de conteúdos científicos, será detalhado na próxima sessão, com o objetivo de definir e ilustrar o conceito com algumas iniciativas mundiais.

4.2 Ciência Cidadã

A ciência cidadã está relacionada ao envolvimento do cidadão nos processos científicos, abrange uma grande variedade de atividades, algumas mais ligadas à educação, outras à prática, e alguns que misturam ambos - como educação, aprendizagem, ensino e prática em ciências. Esse envolvimento se estrutura de forma dinâmica em diferentes aspectos de engajamento que tem sido identificado com relação ao grau de participação do público e o papel dos cidadãos na tomada de decisão e processo de seleção dos fluxos de pesquisa que receberão financiamento público.

Para Tiago (2012), o envolvimento de não cientistas na investigação científica teve um grande crescimento e desenvolvimento nos últimos anos. Para a autora, algumas questões científicas só podem ser respondidas com a recolha e tratamento de uma grande quantidade de dados, mas, devido a uma escassez de recursos humanos e financeiros, a contribuição dos cidadãos na realização de tarefas relacionadas aos projetos de pesquisa auxilia o trabalho dos pesquisadores.

Conforme Maida (2007), nos últimos anos a revolução digital está mudando o estilo de vida da sociedade, principalmente no que se refere a capacidades de cidadania e progresso científico. A exploração de recursos naturais aumentou a necessidade de um desenvolvimento sustentável que atenda às necessidades dos usuários sem comprometer a capacidade de atender as necessidades das gerações futuras.

Goodchild (2007) apud Tiago explana que os projetos de pesquisa utilizam os cidadãos como "sensores" que contêm informações locais ricas e com potencial para fornecer informações em grandes áreas ou para ser atualizada em tempo hábil. Sobre este aspecto, Albagli (2015), observa a diversidade que caracteriza a ciência cidadã em seus amplos aspectos e significados que podem ser compreendidos em duas vertentes: "uma delas, conhecida como crowdsourcing , reúne iniciativas que buscam mobilizar contribuições voluntárias, de vários tipos, em esforços de pesquisa, por parte de não cientistas, incluindo desde compartilhamento de recursos computacionais até coleta de informações de relevância científica" (p.15). Na outra vertente, conforme elucida Albagli, estão iniciativas orientadas para "maior participação, intervenção e empoderamento de cidadãos não só nas formas de produção e uso, mas nos próprios rumos da pesquisa" (p. 15).

Sob o entendimento de que o interesse e a participação do público nas ações científicas aumenta a confiança nas pesquisas e contribui para o avanço científico, muitos países vêm desenvolvendo projetos científicos em que o cidadão tem um papel importante, conforme descrito no tópico seguinte.

4.3 Exemplos de projetos de desenvolvimento da ciência cidadã

Alguns exemplos de grandes projetos de ciência cidadã executados a nível mundial são relatados no documento Open research agenda setting, da Organisation for Economic Co-operation and Development (OECD), publicado em dezembro de 2017. A organização realizou seis estudos de caso, que são relatados abaixo.

Caso 1 - Projeto CIMULACT, Citizen and Multi-Actor Consultation on Horizon 2020 - projeto realizado em 30 países europeus, envolvendo mais de 1000 cidadãos, buscando estabelecer o entendimento sobre políticas, pesquisa e inovação, possibilitando diálogos que promovem a pesquisa científica. Para capacitar os cidadãos foram realizados workshops e conferências, com recriação de cenários de pesquisa, fazendo com que os cidadãos compreendessem como poderiam contribuir com suas visões, necessidades e preocupações (ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, 2017).

Caso 2 - Great New Zealand Science Project (GNZSP). Desenvolvido na Nova Zelândia, o projeto teve como objetivo incentivar a participação pública nas pesquisas, por meio de desafios científicos nacionais em diversas áreas, como biodiversidade, alterações climáticas, alimentos, saúde. A atividade proposta pelo Ministério dedicado às questões de inovação e emprego do país foi veiculada na mídia, com a participação de um jovem e um pesquisador, que indicavam um site que apontava os desafios e propunha ao cidadão a construção de um projeto científico próprio. Ao final do projeto, todas as sugestões foram analisadas e avaliadas pelo setor de ciência e inovação. A iniciativa teve por objetivo possibilitar a socialização de ideias e a compreensão dos desafios da ciência, permitindo ao governo compreender as necessidades da sociedade (ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, 2017).

Caso 3 - Ideas for Change (IFC) . O projeto, desenvolvido na Colômbia, buscou incentivar a participação de comunidades vulneráveis no desenvolvimento de práticas científicas. Os cidadãos foram convidados a contribuir especificando suas necessidades e fornecendo desafios concretos, além de participando das etapas de seleção e desenvolvimento de soluções inovadores em ciência

e tecnologia. Buscou integrar as comunidades vulneráveis e os membros da comunidade científica, contando com o apoio técnico e financeiro de órgãos governamentais e organizações do país. As iniciativas possibilitaram a confiança, coesão social e inclusão no contexto da ciência, tecnologia e inovação (ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, 2017).

Caso 4 - James Lind Alliance (JLA) . O projeto foi iniciado em 2004 pelo National Institute for Health Research Evaluation da University of Southampton no Reino Unido, mas teve suas atividades expandidas para o Canadá, Holanda e Alemanha. As atividades têm como objetivo identificar e priorizar questões levantadas por pacientes, médicos e demais profissionais da saúde com relação aos tratamentos médicos e doenças. As principais perguntas orientam workshops com participação de pacientes e profissionais de saúde. Com a realização das atividades é possível identificar questões que necessitam de investimento em pesquisa, conforme evidências e dúvidas que precisam ser priorizadas (ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, 2017).

Caso 5 - RISTEX. A RISTEX é uma agência japonesa de financiamento de projetos em pesquisa e desenvolvimento que incentiva soluções inovadoras de enfrentamento de problemas sociais. A agência realiza, a cada dois anos, a seleção cuidadosa de questões sociais que necessitam de investimento. As propostas devem se enquadrar em critérios como envolvimento de todas as partes interessadas na implementação das ações, adoção de abordagens multidisciplinares em pesquisa e inovação, aplicação em várias regiões e comunidades, ampla divulgação dos resultados. O objetivo é estreitar a relação entre pesquisadores e cidadãos, mas segundo análise da OECD esse impacto ainda é limitado, devido à necessidade de adaptação da metodologia e ampliação dos incentivos para participação dos pesquisadores (ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, 2017).

Caso 6 - X-Project . O projeto, desenvolvido na Coreia, parte da apresentação de problemas de pesquisa pelo cidadão, que são resolvidos cientificamente pelos pesquisadores. Busca favorecer o envolvimento de toda a sociedade na identificação de problemas que necessitam de solução científica, ampliando a comunidade de pesquisa. O projeto apresenta princípios que devem ser seguidos, como o respeito e recompensa a todas as ideias, a busca de solução a todos os problemas, a abertura do conteúdo do projeto ao público, a simplicidade na estrutura e metodologia de solução. O objetivo do projeto é buscar o interesse e a participação do público nas ações científicas, aumentando a confiança nas pesquisas realizadas e o entendimento das práticas científicas (ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, 2017).

Como iniciativas brasileiras relacionadas à ciência cidadã elencam-se as definidas no domínio do Sistema de Informação sobre a Biodiversidade Brasileira (SiBBr), serviço do Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC). Esse sistema agrega uma infraestrutura de dados e conteúdos em biodiversidade e busca integrar e capacitar interessados, incluindo segmentos de pesquisadores, estudantes, educadores, sociedade civil, órgãos governamentais, não governamentais e empresas do setor privado. O SiBBr apresenta vários projetos em biodiversidade, dados ecológicos, catálogo de espécies, registro de coleções

brasileiras. São listados 16 projetos brasileiros relativos à ciência cidadã, os quais estão sintetizados no Quadro 1, abaixo.

Assim, as ações de ciência cidadã desenvolvidas buscam estabelecer, de formas diferentes, a integração entre a comunidade científica e o cidadão, fazendo com que esse compreenda as ações que são realizadas pelos pesquisadores e a importância de sua participação na definição das práticas a serem desenvolvidas no âmbito da ciência e tecnologia.

Quadro 1 – Projetos brasileiros de desenvolvimento da ciência cidadã.

Projeto	**Objetivo**
Observatório de Imprensa, Avistamento e Ataques (OIAA Onça)	Ampliar o conhecimento sobre carnívoros silvestres brasileiros.
Portal de Zoologia de Pernambuco	Compartilhamento de informações sobre animais selvagens, realizando um inventário da biodiversidade de forma lúdica e divertida.
EXOSS	Registro de meteoros na atmosfera, utilizando uma rede de voluntários, para a pesquisa de chuvas de meteoros e identificação de seus corpos parentais.
Sistema Urubu	Avaliar os efeitos de infraestrutura viária na biodiversidade mundial. Nesta fase o principal foco é o atropelamento de animais selvagens.
Táxeus	Promover da biodiversidade brasileira a partir de listas de espécies.
WIKIAVES	Apoiar, divulgar e promover a atividade de observação de aves, fornecendo gratuitamente ferramentas avançadas para controle de fotos, sons, textos, identificação de espécies.
Atlas de Registros de Aves Brasileira	Atlas reúne informações referentes à biologia das espécies e ações de conservação.
Eu vi uma ave usando pulseira?!	Compreender qual é o tamanho da área de vida de cada ave na paisagem agrícola por meio da ação de observadores de aves brasileiros.
Cidadão Cientista	Realizar monitoramentos participativos de aves em Unidades de Conservação e parques urbanos.
AETRAPP	Engajar comunidades no monitoramento de populações de mosquitos Aedes, vetores de zika, dengue, chikungunya e febre amarela urbana, por meio de uma armadilha caseira, um aplicativo e um mapa online.
Guardiões da Chapada	Monitorar os visitantes florais e flora associada na Chapada Diamantina, sensibilizar o público acerca da importância do serviço de polinização e comunicar temas relacionados à ecologia e conservação.
Brydes do Brasil	Elaborar uma base de dados sobre as baleias-de-bryde identificadas individualmente a partir de fotos da espécie em águas brasileiras.
Blue Change	Conservar ambientes marinhos e costeiros com o auxílio de pesquisadores, instituições e organizações sociais. Conecta pessoas com a ciência, levando demandas da sociedade para que os pesquisadores as transformem em objeto de investigação.
Onde estão as baleias e os golfinhos?	Incentivo à postagem de fotos e/ou vídeos de cetáceos (baleias, botos e golfinhos) em águas costeiras do Rio de Janeiro.
ECOA	Auxiliar comunidades tradicionais e assentados da reforma agrária na identificação de áreas com potencial de reflorestamento e/ou restauração e no mapeamento de árvores frutíferas nativas de relevância ambiental e econômica para a coleta de frutos e sementes.
Ciência Cidadã – UFABC	Implantar o programa de educação científica em diferentes contextos com a criação, aplicação e avaliação de protocolos de ciência cidadã visando promover a alfabetização científica de diferentes públicos, trabalhar a sua percepção ambiental e possibilitar a coleta de dados sobre a biodiversidade

Fonte: BRASIL, (2018).

5 Considerações finais

A ciência aberta está sendo discutida dentro de um processo de mudança social em que busca-se fazer a interlocução da ciência com a sociedade considerando os diversos tipos de saberes para o enfrentamento dos problemas sociais que se tornaram desafios globais da humanidade.

A evolução da ciência cidadã é evidenciada pelos projetos apresentados neste trabalho, os quais elucidam ações estratégicas realizadas em vários países na tentativa de envolver os cidadãos nas questões científicas. Essa participação se dá por meio de observação, coleta, registros, análise de dados em diversas áreas do conhecimento. Essa socialização de ideias, além de aproximar o cidadão do fazer científico, promove a visibilidade de grupos afetados, diminui os custos das pesquisas e emerge uma cultura de compartilhamento. A contribuição do cidadão é primordial para evolução coletiva dos problemas e formulação de hipóteses, uma vez que a grande quantidade de dados impossibilita que as equipes de pesquisa consigam explorar todas as possibilidades de investigação.

Dessa forma, observa-se que o cidadão pode contribuir muito para o avanço científico, mas para essa contribuição ser igualitária e eficiente é necessário pensar em outras dimensões consideradas bases para a ciência cidadã como acesso aberto, plataformas abertas, agenda de pesquisas abertas, além da informação de qualidade e literacia científica.

Referências

ALBAGLI, Sarita. Ciência aberta, questões abertas. In: ALBAGLI, Sarita; MACIEL, Maria Lucia; ABDO, Alexandre Hannud (Org.). **Ciência aberta, questões abertas**. Brasília: IBICT; Rio de Janeiro: UNIRIO, 2015. 312 p.

BRASIL. **Ministério da Ciência, Tecnologia, Inovações e Comunicações**. Sistemas de Informação sobre a Biodiversidade Brasileira. Ciência cidadã: projetos. [2018]. Disponível em: <http://www.sibbr.gov.br/cienciacidada/>. Acesso em: 12 nov. 2018.

MAIDA, C. A. (Ed.). **Sustainability and communities of place**. New York and Oxford: Berghahn. 2007.

MARRA, Patrícia dos Santos Caldas. Visibilidade dos repositórios institucionais brasileiros: análise de diretórios internacionais de acesso aberto. **Revista Eletrônica de Comunicação, Informação e Inovação em Saúde**, v. 8, n. 3, mar. 2014. Disponível em:<https://www.reciis.icict.fiocruz.br/index.php/reciis/article/view/672>. Acesso em: 03 out. 2018.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). **Open research agenda setting**. 21 Dec. 2017. Disponível em: <http://www.oecd.org/about/> Acesso em: 23 ago. 2018.

PEREIRA, Luísa Álvares. O desenvolvimento da escrita ao longo do currículo: do ensino básico ao ensino superior. In: **II FÓRUM CIDTFF:** construindo um compromisso com a ciência

aberta: livro de posters. Universidade de Aveiro, 2018. p. 36. Disponível em: <https://ria.ua.pt/bitstream/10773/23715/3/documento.pdf>. Acesso em: 05 out. 2018.

POMBO, Lúcia et al. Práticas de ciência aberta no EduPark. In: **II FÓRUM CIDTFF**: construindo um compromisso com a ciência aberta: livro de posters. Universidade de Aveiro, 2018. p. 22. Disponível em: <https://ria.ua.pt/bitstream/10773/23715/3/documento.pdf>. Acesso em: 05 out. 2018.

PORTUGAL. **Ministério da Ciência, Tecnologia e Ensino Superior. Fundação para a Ciência e a Tecnologia**. Glossário. Lisboa, c2016a. Disponível em: <http://www.ciencia-aberta.pt/glossario>. Acesso em: 22 ago. 2018.

PORTUGAL. **Ministério da Ciência, Tecnologia e Ensino Superior. Fundação para a Ciência e a Tecnologia. Sobre ciência aberta.** Lisboa, c2016b. Disponível em:<http://www.ciencia-aberta.pt/sobre-ciencia-aberta>. Acesso em: 22 ago. 2018.

TIAGO, Patrícia Maria Nunes. Improving citizen science as a tool for biodiversity monitoring. **Tese** (Doutorado em Biologia)–Faculdade de ciências, Universidade de Lisboa, 2012. Disponível em: <http://repositorio.ul.pt/bitstream/10451/34139/1/ulsd731841_td_Patricia_Tiago.pdf>.
SANTOS, Paula Xavier (Coord.). **Livro Verde Ciência aberta e dados abertos: mapeamento e análise de políticas, infraestruturas e estratégias em perspectiva nacional e internacional.** Rio de Janeiro: Fiocruz, 2017. 141 p.

Metadados e Twitter: uso do Tweet Object para identificação de local

Denysson Axel Ribeiro Mota[a] *e Gracy Kelli Martins*[b]

Resumo: Esta pesquisa apresenta um estudo, com base nos Estudos Métricos da Ciência da Informação, sobre a disseminação de informações na plataforma Twitter. Este trabalho teve como objetivos identificar elementos para análises métricas nos Tweets, utilizando como recorte mensagens coletadas na ferramenta via API. Para alcançar estes objetivos, utilizou dados obtidos via API do Twitter, usando sistema operacional Debian Linux e uma aplicação Ruby, armazenados em formato JSON em uma base de dados no SGBD PostGreSQL, e manipulados no SublimeText 3 e OpenOffice quando necessário. Apresenta como resultados a distribuição geográfica em cada uma das etiquetas analisadas, mostrando que mesmo que existem diferenças em valores totais, a distribuição em geral se mantém parecida. Conclui-se que as etiquetas disponíveis no JSON são extremamente úteis, mas que é necessário mais estudo sobre as possíveis formas de identificação de metadados úteis para os processos métricos de informação.

Palavras-chave: Disseminação de dados; Geolocalização; Tweet Object; Twitter.

Metadata And Twitter: use of Tweet Object for location identification

Abstract: This research proposes to study, based on the Metric Studies of Information Science, the dissemination of information on the Twitter platform. This work aimed to identify elements for metric analysis in Tweets, using as clipping messages collected in the tool via API. To achieve these goals, it used data obtained via the Twitter API, using Debian Linux operating system and a Ruby application, stored in JSON format in a database in PostGreSQL DBMS, and manipulated in SublimeText 3 and OpenOffice when required. It presents as results the geographical distribution in each of the analyzed tags, showing that even if there are differences in total values, the distribution in general remains similar. It is concluded that the tags available in JSON are extremely useful, but that more study is needed on possible ways of identifying metadata useful for metric information processes.

Keyword: Data dissemination; Geolocation; Tweet Object; Twitter.

a Universidade Federal da Paraíba (UFPB). E-mail: denysson.mota@ufca.edu.br. ORCID: https://orcid.org/0000-0003-2069-134X. Currículo: http://lattes.cnpq.br/1273037072033521

b Universidade Federal da Paraíba (UFPB). E-mail: gracykmg@gmail.com. ORCID: https://orcid.org/0000-0002-1805-9292. Currículo: http://lattes.cnpq.br/7431498333122929

1 Introdução

Em momentos de grande comoção, como desastres naturais, surtos epidêmicos e eleições, por exemplo, a sociedade busca por informações relevantes para guiar suas decisões no dia a dia, sejam em rádios, jornais e programas televisivos, e em especial pela internet, em portais de notícias, serviços de vídeo, blogs e redes sociais.

As redes sociais em ambiência digital são ferramentas de comunicação que surgiram no final do século XX, iniciando em 2003 com Myspace, que buscava integrar artistas com fãs, e LinkedIn, criada especificamente como uma rede social de negócios. Posteriormente, em 2004, surgiram duas redes: Orkut, baseado na teoria do mundo pequeno, também conhecida como a teoria dos seis graus de separação, de Stanley Milgram (1967), e Facebook, atualmente a rede social mais utilizada, com cerca de 2.2 bilhões de usuários mensais (STATISTA, 2018a). Em 2006 surge o Twitter, que dentre estes últimos, é um serviço que se caracterizou pela rápida velocidade de disseminação de informações.

O Twitter, desde sua criação em 2006, tem passado por diversas mudanças ao longo de sua história. No entanto algo que se mantém constante é o seu poder como ferramenta de comunicação, principalmente devido à sua estrutura de organização em formato de seguidores, em vez de contatos e/ou amigos como as demais. Criado como uma ferramenta para simular um serviço deSMS1 na Web, passando para a estrutura de microblog, e evoluindo para ferramenta de rede social, o Twitter conta atualmente com 330 milhões de usuários ativos mensais em todo o mundo (TWITTER, 2018; STATISTA, 2018b), e por ela são enviadas cerca de 500 milhões de novas mensagens por dia (OMNICORE, 2018), entre estas mensagens informativas enviadas por diversos perfis governamentais oficiais.

Todo este fluxo de mensagens não é composto apenas pelos textos enviados. Junto com a mensagem, o Twitter armazena alguns metadados que permitem identificar além das mensagens e outras características, por meio de uma estrutura que permite sua consulta posterior, chamada de Tweet Object (TWITTER, 2017a). O Tweet Object, que será chamado daqui em diante de TO, contém em sua estrutura dados como a identificação do usuário que realizou o tweet, dia e hora do tweet, se é uma mensagem original ou uma replicação (chamado de retweet), se outros usuários foram citados, entre outros.

Esse tráfego de dados pode ser acessado via API2 do Twitter, que fornece acesso à base de dados retornando a solicitação via documento texto em formato JavaScript Object Notation (TWITTER, 2017b). A JavaScript Object Notation, mas mais conhecido pelo seu acrônimo: JSON3, é um padrão de notação para intercâmbio de dados estruturados na internet via texto, criado em 2001 e adotado em diversas plataformas devido a ser independente de linguagem, suas definições podem ser encontradas na RFC8259 e ECMA-404 (BRAY, 2017; ECMA, 2017).

2 Objetivos

Este trabalho tem como objetivo principal identificar elementos para análises métricas nos tweets, utilizando como recorte mensagens coletadas na ferramenta via API. Como objetivos específicos, temos: a) identificação dos elementos no Tweet Object; b) manipulação dos objetos JSONB na base de dados; c) exportação dos dados para ferramentas de mapas online.

3 Procedimentos metodológicos

A captura dos tweets foi realizada via acesso à API usando script4 na linguagem Ruby5, que foi executado em um servidor Debian6 no período compreendido entre outubro de 2017 até março de 2018, e armazenados em banco de dados PostgreSQL7 em formato JSON.

Após os estudos da API e da estrutura do Tweet Object, o elemento que despertou a curiosidade no primeiro momento a possibilidade de descobrir a distribuição geográfica desses tweets.

Para isto inicialmente foram selecionados os tweets onde a tag [coordinates] não estava vazia ou nula. Esta etiqueta retorna a localização onde o tweet foi realizado, em coordenadas com longitude e latitude, nesta ordem. O Comando SQL, que busca todos os registros de coordenadas que não estiverem vários ou nulos, está exposto na Figura 1.

Figura 1 – Distribuição de Tweets via Etiqueta [coordinates].

```
select
  dados->'coordinates' as coord
from tweets
where
  dados->'coordinates' != '"[]"' and
  dados->'coordinates' != 'null';
```

Fonte: Dados da Pesquisa, 2018.

Após a extração destes dados, foi realizado mapeamento das coordenadas na ferramenta MapMakerApp8, retornando o mapa exibido no Apêndice A. Esta plataforma mapa permite a navegação por área, detalhando as quantidades de tweets por local, com zoom e navegação interativa.

No entanto apenas 2.125, do total de 2.907.720 de tweets, contém a etiqueta [coordinates] preenchida, pois é um campo opcional e recomendado o não preenchimento por organizações de segurança. Foi realizada então uma extração usando a subetiqueta [location] dentro da etiqueta [user]. Esta etiqueta também é opcional, mas está preenchida em 2.003.336 dos tweets coletados.

Utilizando o comando exposto na Figura 2, foram obtidos 2.003.338 tweets que têm esta etiqueta, que posteriormente foram importados na plataforma Google Maps, que permite a inserção de locais em texto, e mediante a API de Geocoding disponível marca a localização em latitude e longitude no mapa.

Os primeiros 12 mil registros foram inseridos no site Google Maps9, pois ele permite a inserção de locais por nome e a própria plataforma faz a conversão para coordenadas, resultando no mapa exibido aqui no Apêndice B.

No entanto, devido ao grande número de registros, e ao limite de upload da ferramenta, que apenas permite que 2.000 registros sejam lançados por vez, foi decidido seguir por um caminho de marcar apenas uma vez por local.

Considerando que o preenchimento é livre, podendo inclusive conter caracteres especiais, os registros foram então tratados e filtrados usando funcionalidades do Sublime Text 310 de busca usando expressões regulares, em conjunto com o pacote Remove Non Ascii Chars11 para remover todos os caracteres especiais que o Twitter permite incluir na localização, como emoticons, por exemplo. É importante ressaltar que isto também elimina os registros de cidades que tenham sido redigidos usando ideogramas, como de países da Ásia, mas que devido aos pesquisadores não conhecerem os caracteres não seria possível filtrar o que de fato é cidade e o que não é.

Figura 2– Distribuição de Tweets via Etiqueta [user]→[location].

```
select
  dados->'user'->'location' as loc
from tweets
where
  dados->'user'->'location' != ""
  and
  dados->'user'->'location' != 'null';
```

Fonte: Dados da Pesquisa, 2018.

Utilizando a ferramenta de substituição de texto do Sublime Text 3, foram utilizadas expressões regulares para excluir, do início e do final da linha, usando os caracteres ^ e $, respectivamente, todos os caracteres não alfanuméricos e espaços em branco ou tabulação. Esta substituição foi realizada de forma repetitiva até que a busca não encontrasse mais registros que atendessem os requisitos.

Posteriormente a esta busca foram excluídas todas as linhas vazias, também utilizando a ferramenta de busca textual e informando a expressão regular ^\n e deixando o campo {Replace:} vazio. Depois disto, foram excluídas as linhas duplicadas no menu {Edit}>{Permute Lines}>{Unique}. Com estes mecanismos, foi possível reduzir o número de registros de locais para 129.875, dos 2.003.338 registros recuperados anteriormente.

Mesmo reduzindo o número total de registros, a limitação da plataforma Google Maps ainda é uma barreira para o adequado uso dela, sendo necessária a realização de 65 processos de importação, além das correções e validações necessárias nos casos em que a plataforma não compreenda o local.

Por fim, foram realizadas extrações usando a etiqueta [place]. Esta etiqueta indica a qual local o tweet está relacionado, mas não indica, necessariamente, onde ele foi realizado. Dentro desta etiqueta existem duas outras que são interessantes: [full_name] e [bounding_box]. A primeira tem o local em formato texto, passível de importação no Google Maps, enquanto a segunda tem uma outra etiqueta aninhada chamada de [coordinates], que contém as coordenadas para formar uma caixa de exibição do local. O comando SQL utilizado pode ser visto na Figura 3.

Google Maps, decidiu-se usar esta segunda opção, tratando as coordenadas no OpenOffice para obter o ponto central indicado. Após a extração destas coordenadas, as mesmas foram importadas na plataforma MapMakerApp, resultando no mapa exibido no Apêndice C.

Figura 3– Distribuição de Tweets via Etiqueta [place]→[bounding_box]→[coordinates].

```
select
  dados->'place'->'bounding_box'-
        >'coordinates' as lugar
from tweets
where
  dados->'place' != '""' and
  dados->'place' != 'null';
```

Fonte: Dados da Pesquisa, 2018.

4 Resultados

É possível afirmar, com a análise apresentada, que os três objetivos foram alcançados de forma total, mas que ainda permitem a expansão da pesquisa com novas etiquetas e análises.

As diferentes possibilidades de coleta de localização dos tweets mostram a flexibilidade da ferramenta. Mesmo com as diferenças entre os valores obtidos, como pode ser visto nos Apêndices A, B e C, os grandes aglomerados de tweet permanecem (Brasil, EUA, India e Tailândia).

Isto pode demonstrar alguma consistência dos metadados coletados automaticamente pela plataforma com os informados livremente pelos usuários, mas mais testes são necessários considerando as possibilidades de representação na etiqueta [user]→[location].

5 Considerações finais

A plataforma disponibilizada pelo Twitter nos permite avaliar diversos metadados para estudos métricos da informação. No entanto, é necessária a identificação das etiquetas disponíveis, para saber onde ir para buscar a informação necessária, e quais as possibilidades de combinação entre elas para enriquecimento da análise.

Nesta perspectiva, buscou-se aqui estudar as etiquetas e geolocalização, de forma relativamente simples, mas é possível realizar posteriores pesquisas que envolvam cruzamentos destes dados com outras etiquetas, e com isso obter novas possibilidades de análise.

De forma semelhante, podem ser feitas comparações entre os metadados das etiquetas [coordinates] da raiz do tweet com os da etiqueta [place]->[bounding_box]->[coordinates] dos tweets que tenham ambas.

A possibilidade de importação destes metadados em plataformas de mapas que permitem navegação é um caminho interessante de disponibilização de dados de pesquisa para uso posterior.

Referências

BRAY, T. (Ed.). **The JavaScript Object Notation (JSON) Data Interchange Format.** 2017. Disponível em < https://www.rfc-editor.org/info/rfc8259 > Acesso em: < 25 mar. 2018 >.

ECMA INTERNATIONAL (ECMA). **The JSON Data Interchange Syntax. 2017**. Disponível em < https://www.ecma-international.org/publications/files/ECMA-ST/ECMA-404.pdf > Acesso em: < 25 mar. 2018 >.

MILGRAM, S. **The small world problem. Psychology Today**, v. 2, p. 60-67, 1967.

STATISTA. **Most popular social networks worldwide as of April 2018, ranked by number of active users (in millions).** 2018a. Disponível em <https://www.statista.com/statistics/272014/global-social-networks-ranked-by-number-of-users/ > Acesso em: < 6 abr. 2018 >.

STATISTA. **Twitter: number of monthly active users 2010-2017.** 2018b. Disponível em <https://www.statista.com/statistics/282087/number-of-monthly-active-twitter-users/> Acesso em: < 6 abr. 2018 >.

TWITTER. **Q1 2018 – Letter to Shareholders**. 2018. Disponível em <http://files.shareholder.com/downloads/AMDA-F526X/6236645277x0x978181/2FD6D58F-A930-4EB2-90B0-9C3A120648DE/Q1_2018_Shareholder_Letter.pdf> Acesso em: < 03 maio 2018 >.

TWITTER. **Tweet Object – Twitter Developers.** 2017a. Disponível em <https://developer.twitter.com/en/docs/tweets/data-dictionary/overview/tweet-object> Acesso em: < 25 mar. 2018 >.

TWITTER. **Introduction to Tweet JSON – Twitter Developers.** 2017b. Disponível em <https://developer.twitter.com/en/docs/tweets/data-dictionary/overview/intro-to-tweet-json> Acesso em: < 25 mar. 2018 >.

Apêndice A

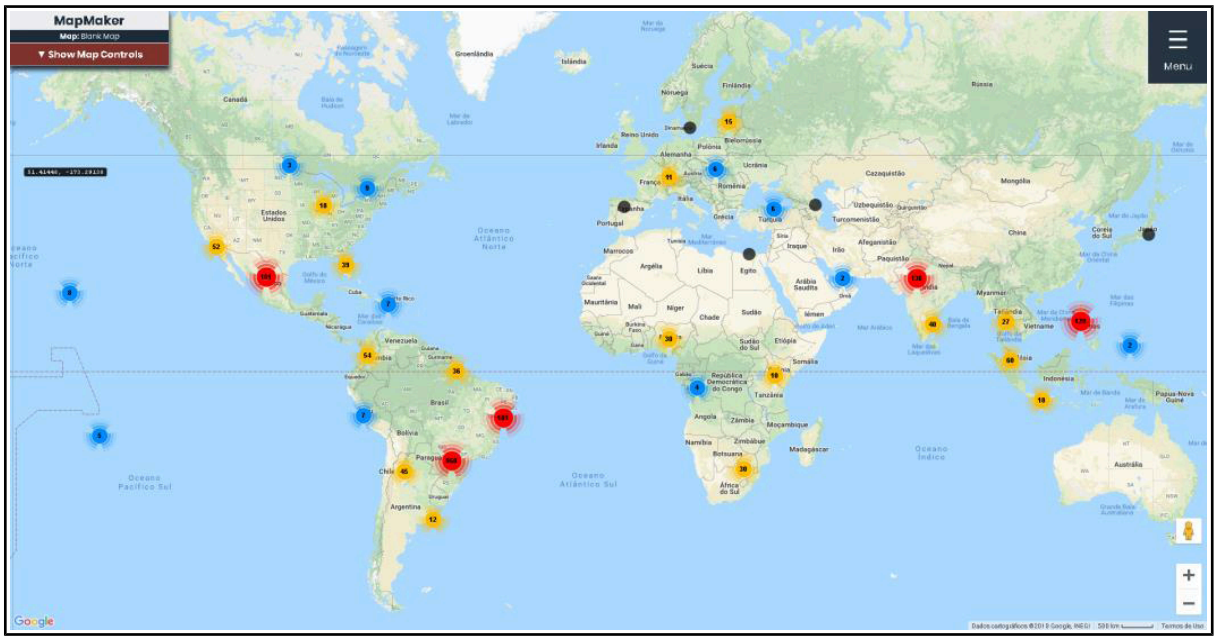

Fonte: Dados da pesquisa, 2018.

Apêndice B

Fonte: Dados da pesquisa, 2018.

Apêndice C – Distribuição de Tweets via Etiqueta [place]→[bounding_box]→[coordinates]

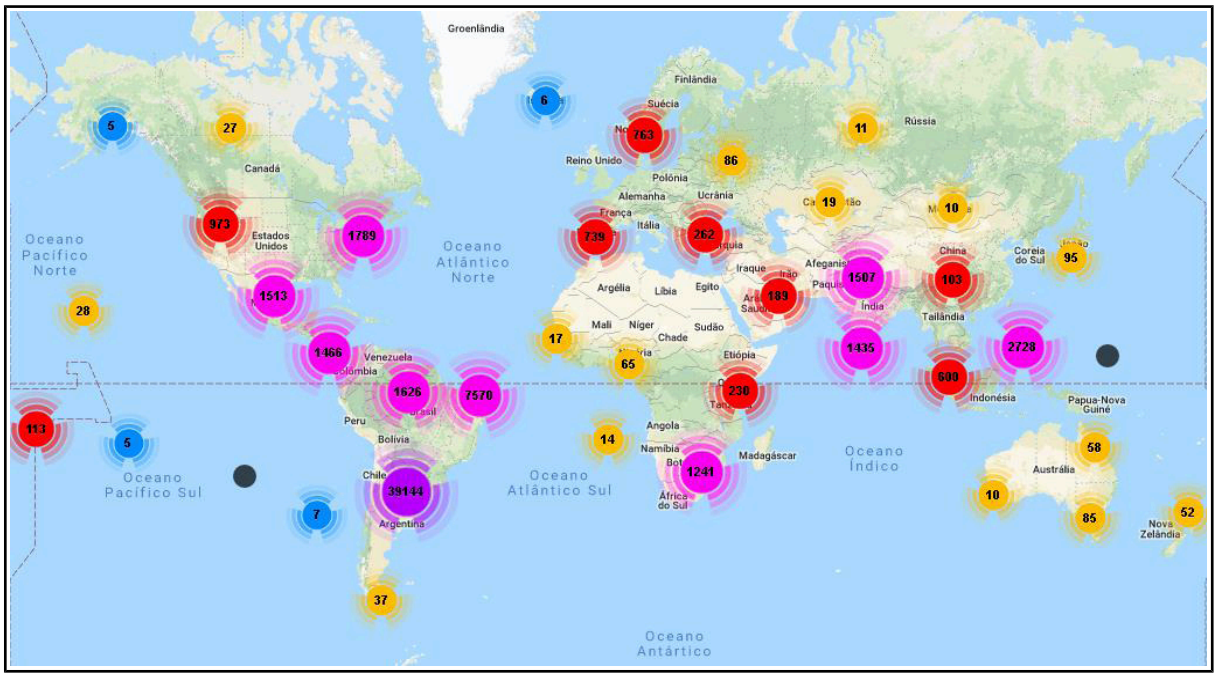

Fonte: Dados da pesquisa, 2018.

O papel do bibliotecário no processo de recuperação da informação

Miriam Cândida de Jesus[a], *Nina Cláudia Mendonça Campos de Miranda*[b] *e Célia da Consolação Dias*[c]

Resumo: Este trabalho aborda o papel do profissional bibliotecário no processo de recuperação da informação no ambiente de bibliotecas universitárias. O objetivo principal deste estudo é revisar na literatura o papel que o bibliotecário exerce como mediador informacional na educação e no desenvolvimento da competência informacional do usuário no processo de recuperação da informação. A proposta é fazer um link entre as competências desejáveis do profissional da informação e sua influência no processo de recuperação da informação pelo usuário. Para tanto, foi feita uma busca na literatura sobre a atividade de auxílio/orientação aos usuários, visando torná-lo usuário competente na recuperação da informação. O conhecimento do que a literatura recomenda no tocante às habilidades profissionais e o que se espera do bibliotecário pode contribuir para a adoção de uma postura mais ousada do bibliotecário, indo de encontro às expectativas do usuário no que se refere à recuperação da informação.

Palavras-chave: Recuperação da informação; Papel do bibliotecário; Usuário.

The role of the librarian in the information recovery process

Abstract: This work addresses the role of the professional librarian in the process of information retrieval in the university library environment. The main objective of this study is to review in the literature the role that the librarian exercises as an informational mediator in education and in the development of user informational competence in the information retrieval process. The proposal is to link the desirable competencies of the information professional and their influence on the process of information retrieval by the user. To do so, a search was made in the literature on the activity of assistance / guidance to users, aiming to make it a competent user in the information retrieval. Knowledge of what literature recommends regarding professional skills and what is expected of the librarian can contribute to the adoption of a more bold librarian's posture, meeting the expectations of the user with regard to information retrieval.

Keyword: Information retrieval; Role of the librarian; User.

a Universidade Federal de Minas Gerais (UFMG). E-mail: miriamcandidadejesus@gmail.com. Currículo: http://lattes.cnpq.br/3918495077516416

b Universidade Federal de Minas Gerais (UFMG). E-mail: ninacm.nm@gmail.com. ORCID: https://orcid.org/0000-0003-3324-8507. Currículo: http://lattes.cnpq.br/6056782437134367

c Universidade Federal de Minas Gerais (UFMG). E-mail: celiadias@gmail.com. ORCID: https://orcid.org/0000-0003-0891-6454. Currículo: http://lattes.cnpq.br/0933539682074676

1 Introdução

As bibliotecas universitárias devem estar atentas quanto à explosão informacional e ao avanço tecnológico a fim de contribuírem para o pleno desenvolvimento da habilidade do usuário em recuperar a informação obtendo os melhores resultados, em tempos de recursos eletrônicos e internet.

Esta nova realidade sugere que o usuário desenvolva, aperfeiçoe e use cada vez mais suas habilidades em buscar e usar a informação. Tais habilidades os capacitam não somente a aprender de forma autônoma e a construir seu próprio conhecimento, mas, sobretudo a dar suporte ao usuário na busca por informação.

Neste contexto a oferta de serviços de informação e a atuação educacional e de suporte do bibliotecário na biblioteca universitária merecem destaque. Este destaque está relacionado ao desafio de desenvolver mecanismos, serviços e atividades visando promover à independência e autonomia de seus usuários, tanto na identificação das fontes de informação quanto ao acesso e uso destes recursos.

Sadi et al (1985) enfatiza que, nas últimas décadas, as bibliotecas deixaram de ser apenas depositárias do conhecimento e passaram a ter um aspecto mais ativo, ou seja, suas atividades são desenvolvidas com foco no usuário, desenvolvendo sistemas de informação e outros serviços visando sua satisfação.

Observou-se muitas vezes que os usuários desconhecem a existência de fontes de informação disponíveis em meio eletrônico ou impresso, bem como as formas e técnicas de pesquisa.

Segundo Belluzo e Macedo (1993), as bibliotecas universitárias têm a necessidade de acompanhar a evolução das informações e das tecnologias, oferecendo melhor qualidade nos seus serviços. A biblioteca, como uma unidade de informação, se preocupa com o aperfeiçoamento de suas atividades, investe no desenvolvimento tanto dos seus recursos de informação quanto na sua equipe interna, bem como na implementação e no uso de tecnologias de informação que possibilita o acesso, a busca e a recuperação de informação pelos usuários.

Neste sentido, a biblioteca universitária desempenha um papel relevante como gestora e mediadora atuando na seleção, organização, disponibilização e recuperação de informação para dar suporte à geração de novos conhecimentos produzidos para o tripé que sustenta a universidade, isto é, o ensino, a pesquisa e a extensão. Para atender as inúmeras demandas a partir deste tripé cabe à biblioteca universitária lidar com recursos de informação que podem ser caracterizados como híbridos, formados por objetos informacionais de uma diversidade muito grande e que varia desde o acervo tradicional, aos objetos digitais, imagéticos, sonoros até os dados digitais, entre outros. A gestão destes recursos de informação para atender aos objetivos tão amplos das universidades demanda um grande esforço das bibliotecas universitárias e dos seus bibliotecários.

Com o foco no usuário, o papel do bibliotecário é de extrema relevância. Esta relevância está respaldada na ampliação da atuação do bibliotecário, sujeito mediador, que conhece as fontes de informação e responsável por criar estratégias para que o usuário possa conquistar autonomia na direção da construção do próprio conhecimento.

O termo mediação deve ser usado em substituição ao termo intermediário, tal como apontado por Kuhlthau (1994). Para a autora a mediação pressupõe uma interação humana entre os envolvidos no processo de busca da informação e o intermediário intervém entre a informação e o usuário sem haver interação entre eles. A interação é justamente o que pode ser proposto pela biblioteca universitária no que diz respeito ao à oferta de serviços de informação e a disponibilização dos recursos.

Além deste papel de mediador apontado anteriormente por Kuhlthau (1994), outra função atribuída ao bibliotecário é a de professor. Campello (2003) destaca esta função nos aspectos que compreendem tanto o ensino, como o pensamento crítico. Assim a autora afirma que, neste papel o bibliotecário está:

> "[…] encarregado de ensinar não apenas as habilidades que vinha tradicionalmente ensinando […] mas está envolvido no desenvolvimento das habilidades de pensar criticamente, […] ensinando o aprender a aprender."

O que motivou a realização deste estudo foi o frequente questionamento sobre a profissão do bibliotecário em relação ao seu papel no processo de recuperação da informação, visto que o profissional responsável por esta ação está em contato permanente com o usuário.

Promover o uso dos serviços e dos recursos da biblioteca tem sido o foco dos inúmeros treinamentos de usuários nas bibliotecas universitárias. Essa preocupação é destacada por Grogan (1991), quando ele enfatiza a importância de dar autonomia aos usuários e, ao mesmo tempo possibilitar que os treinamentos auxiliem os usuários a se tornarem pessoas confiantes em si mesmas para fazer a busca pela informação desejada. Neste sentido, o autor afirma que "criar uma forma de instrução que seja eficaz enquanto modelo de educação de modo a tornar o usuário autossuficiente, é o grande desafio", para os bibliotecários, sintetiza Grogan (1991, p. 16).

Com isso posto, a questão que motivou a realização deste trabalho compreendeu: qual o papel do bibliotecário na recuperação da informação?

2 Objetivos

O objetivo principal deste estudo é revisar na literatura o papel que o bibliotecário exerce como mediador informacional na educação e no desenvolvimento da competência informacional do usuário no processo de recuperação da informação.

3 Procedimentos metodológicos

Os procedimentos metodológicos deste estudo teórico compreenderam o levantamento bibliográfico, realizado por meio de pesquisa exploratória atemporal, acerca do tema em análise, bem como a seleção dos materiais, feita pela leitura dos resumos e observação de referências utilizadas, que permitiram a criação de um referencial teórico sobre a temática. Este levantamento possibilitou às autoras deste trabalho ampliar a compreensão sobre as habilidades do bibliotecário que podem contribuir para o processo de recuperação da informação.

4 Resultados

Destacam-se a seguir os resultados identificados na literatura sobre a temática em discussão.

4.1 Recuperação da informação

Em relação à recuperação da informação recorreu-se a Mooers (1951) e Saracevic (1991). O termo recuperação da informação foi cunhado por Calvin Mooers (1951). Para o autor a recuperação da informação "engloba os aspectos intelectuais da descrição de informações e suas especificidades para a busca além de quaisquer sistemas, técnicas ou máquinas empregados para o desempenho da operação". Da mesma forma Saracevic (1991) frisou que, certamente, a recuperação da informação não foi a única responsável pelo desenvolvimento da Ciência da Informação, mas pode ser considerada como o principal fator, ao longo do tempo. Isso significa dizer que, a CI ultrapassou a recuperação da informação, mas os problemas principais tiveram sua origem aí e ainda constituem seu núcleo. Da mesma forma, ressalta-se que uma das grandes preocupações da CI é dar acesso aos usuários das unidades de informação aos recursos de informação.

Observou-se que a recuperação da informação pode ser otimizada com a implementação de atividades de educação de usuários ou competência em informação, temática que será abordada no próximo tópico.

4.2 Competência em informação

Para Takahashi "a sociedade da informação não é um modismo e representa uma profunda mudança na organização da sociedade e da economia, havendo quem a considere um novo paradigma técnico-econômico. É um fenômeno global com elevado potencial transformador das atividades sociais e econômicas, uma vez que a estrutura e a dinâmica dessas atividades inevitavelmente serão, em alguma medida, afetadas pela infraestrutura de informações disponíveis." (2000), p.5).

Neste cenário informacional, pode-se identificar a necessidade de acionar ferramental e técnicas de acessar a informação, de maneira a aperfeiçoar a sua busca e uso. Confirmando esta teoria, Hatschbach (2002, p. 10) afirma que:

> Os indivíduos que pretendem ser agentes de transformação e conquistar seu espaço na sociedade da informação necessitam adquirir habilidades específicas para o trato com a informação no que se refere a sua localização, acesso, uso, comunicação e, principalmente, para a geração de novos conhecimentos.

Percebeu-se na literatura os termos "information literacy", ou competência em informação e "alfabetização informacional" que são tratados a seguir. Neste ponto, surge o tema de estudo que trata especificamente das questões relacionadas à aquisição de competências e conjunto de conhecimentos requeridos na busca, uso e compreensão da informação, voltada para a formação estudantil, profissional e social, denominada information literacy, ou competência em informação.

Antes de abordar especificamente o termo competência em informação apresenta-se a seguir a definição para information literacy. Para isso, recorreu-se à Dudziak (2003). A autora discutiu a definição de information literacy com ênfase no aprendizado ao longo da vida. Para Dudziak (2003, p. 28) Information literacy "é o processo contínuo de internalização de fundamentos conceituais, atitudinais e de habilidades necessárias à compreensão e interação permanente com o

universo informacional e sua dinâmica, de modo a proporcionar um aprendizado ao longo da vida".

A expressão information literacy foi utilizada pela primeira vez, de acordo com Dudziak (2003, p. 23), no relatório do bibliotecário americano Paul Zurkowski, intitulado "The information service environmental relation ships and priorities" de 1974. Neste estudo identificou-se o termo que é considerado como a evolução da educação de usuários. Assim, Zurkowski apud Hatschbach (2002, p. 16) afirma que:

> pessoas treinadas para a utilização de fontes de informação em seu trabalho podem ser chamadas de 'competentes em informação' (information literacy). Elas aprendem técnicas e ferramentas informacionais como fontes primárias para encontrarem informação, visando à solução de seus problemas.

O processo de pesquisa, habitualmente exige instrução e o suporte profissional para auxiliar a busca e o uso da informação no ambiente educacional para possibilitar a construção do conhecimento.

A competência informacional é abrangente e a sua implementação demanda o emprego de vários tipos de ferramentas que compreende desde a instrução, o treinamento, a apresentação de interfaces informacionais até a orientação bibliográfica para a realização dos levantamentos necessários para a construção de referenciais teóricos.

De acordo com a American Library Association (1989), os itens essenciais para que a pessoa seja competente em informação são: saber realizar uma busca por informação, fazer a avaliação do resultado, filtrar este resultado e saber usar a informação quando necessário.

Caregnato (2000) define "alfabetização informacional" como atividade, principalmente das bibliotecas acadêmicas, de desenvolver nos alunos as habilidades necessárias para a pesquisa no mundo digital. Da mesma forma, surge destacado o conceito de aprendizagem ao longo da vida, citado por Kuhlthau (2002) apud Hatschbach (2002, p. 18):

> A busca de informação é um processo de construção que envolve a experiência de uma vida, os sentimentos, bem como os pensamentos e as atitudes de uma pessoa.

4.3 O papel do bibliotecário na recuperação da informação.

As atividades técnicas de processamento da informação fazem parte do papel do bibliotecário tanto quanto as relacionadas com o processo de transmitir o processo de aprender a aprender, ou seja, compartilhar e multiplicar o que se sabe, visando a formar cidadãos que sabem interagir e usufruir da informação em todos os seus suportes e formas. Essa transferência da informação exige que o bibliotecário se mostre capacitado, aberto a auferir novas habilidades demandadas pelo atual contexto informacional.

Trata-se de um profissional comprometido com a sua vocação, que valoriza a si e ao seu trabalho, segue na educação contínua aliada a novos comportamentos, com novas formas de pensar, que trabalha suas qualidades de criatividade, curiosidade, liderança, empreendedorismo, inovação e sensibilidade para com o público que ele está servindo.

Ao bibliotecário é requerido mais que o domínio dos saberes da biblioteconomia, tendo em vista a complexidade social moderna, a maior necessidade de informação das pessoas, o

surgimento de novas tecnologias de informação, a disponibilidade de informação na internet, entre outros fatores.

Com o propósito de auxiliar o bibliotecário a concretizar este amplo espectro de comportamentos profissionais validados por especialistas em programas e projetos para aplicação da competência informacional, que pode resultar em uma recuperação da informação eficaz levou Dudziak (2005) a apresentar um conjunto de elementos que são relevantes e que são indicados a seguir:

- O bibliotecário deve seu um campeão de causa;
- O centro do processo é o aluno;
- O bibliotecário deve ser um agente educacional;
- É preciso haver cooperação entre docentes e bibliotecários.
- A cultura do livre acesso à informação deve ser enfatizada;
- A inserção no projeto pedagógico;
- Definição clara de objetivos e metas;
- Planejamento é essencial;
- A transdisciplinaridade e o currículo integrado como marcos para a competência em informação;
- Incorporar diferentes espaços de aprendizagem;
- As melhores práticas se constroem no decorrer do processo;
- Avaliação constante e controle do processo.

Além disso, destaca-se que o papel do bibliotecário envolve também, desenvolver projetos pedagógicos na área da competência em informação, com o objetivo de educar os usuários para a busca, recuperação e uso da informação, fazendo o papel de um agente educacional em trabalho conjunto com os professores da instituição.

5 Considerações finais

Percebeu-se neste estudo, que uma importante mudança se passa no perfil do profissional bibliotecário, ele deve estar atento e buscar inserção nesse novo cenário. E o profissional moderno está diante de uma ótima oportunidade, para, munido dos requisitos necessários, ampliar a visão da profissão e se lançar aos desafios da competência informacional.

Os mediadores da informação, no caso os bibliotecários, e o papel desempenhado por eles junto aos usuários, em vista da recuperação da informação, recebem enorme valorização na atualidade, marcada por informação em excesso, emitida por canais diversos e crescentemente modernos. Essa lacuna é ocupada pela habilidade do profissional em filtrar o que realmente é útil aos usuários e também capacitá-los a serem bem sucedidos no universo informacional moderno.

Na sociedade da informação, o tema educação de usuários/competência informacional e a recuperação da informação, é visto como essencial. Um grande contingente de informação é ofertado aos usuários, porém, geralmente ele não está apto a realizar busca e recuperação que atenda às suas reais necessidades.

Verificado este fato, este trabalho mostrou como deve ser aplicada a educação de usuários na atualidade, com vistas à recuperação da informação. Constatou-se que o desenvolvimento da

competência informacional, que é a educação de usuários expandida, é de suma importância, pois vai além da biblioteca, viabilizando o aprender por toda a vida.

O papel do bibliotecário neste processo também foi abordado. Apresentou a importância capital do profissional da informação no desenvolvimento da habilidade informacional dos usuários e as novas competências requeridas atualmente para um excelente trabalho junto aos mesmos.

Desta forma, o trabalho respondeu às questões propostas, por meio da exposição da relevância da obtenção da competência informacional e o papel do bibliotecário que, de fato, com os seus saberes, contribui para aprimorar o processo de recuperação da informação.

Referência

AMARAL, S. A. do. **Marketing: abordagem em unidades de informação**. Brasília: Thesaurus, 1998, 224 p.

BELLUZZO, R. C. B., MACEDO, N. D. de. **A gestão da qualidade em serviços de informação**: contribuição para uma base teórica. Ciência da Informação, v. 22, n. 2, p. 124-132, maio/ago., 1993.

BELLUZZO, R. C. B.; ROSETTO, M. Contribuição da competência em informação em bibliotecas públicas paulistas: uma experiência com apoio de oficinas de trabalho. In: **CONGRESSO BRASILEIRO DE BIBLIOTECONOMIA, DOCUMENTAÇÃO E CIÊNCIA DA INFORMAÇÃO**, 21., 2005. Anais... Curitiba: FEBAB, 2005.

CAMPELLO, B. A competência informacional na educação para o século XXI. In: **biblioteca escolar: temas para a prática pedagógica**. Belo Horizonte: Autêntica, 2002. p. 9-11.

CAMPELLO, B. O movimento da competência informacional: uma perspectiva para o letramento informacional. **Ciência da Informação**, Brasília, v. 32, n. 3, p. 28-37, set./dez. 2003.

CAREGNATO, S. E. O desenvolvimento de habilidades informacionais: o papel das bibliotecas universitárias no contexto da informação digital em rede. **Revista de Biblioteconomia & comunicação**, Porto Alegre, v. 8, p. 47-55, 2000.

DUDZIAK, E. A. Information literacy: princípios, filosofia e prática. **Ciência da Informação**, Brasília, v. 32, n. 1, p. 23-35, 2003.

DUDZIAK, E. A.; GABRIEL, M. A.; VILLELA, M. C. A educação de usuários de bibliotecas universitárias frente à sociedade do conhecimento e sua inserção nos novos paradigmas educacionais. In: **SEMINÁRIO NACIONAL DE BIBLIOTECAS UNIVERSITÁRIAS**, 11., 2000, Florianópolis. Anais. Florianópolis: UFSC, 2000. Disponível em: <http://snbu.bvs.br/snbu2000/parallel.html>. Acesso em 28 set. 2018.

GROGAN, D. **A prática do Serviço de Referência**. Brasília. Briquet de Lemos, 1995. 196 p.

HATSCHBACH, M. H. DE L. Information literacy: aspectos conceituais e iniciativas em ambiente digital para o estudante de nível superior. Rio de Janeiro, 2002. 108 f. **Dissertação** (Mestrado em Ciência da Informação) – UFRJ/ECO-MCT/IBICT, Rio de Janeiro, 2002.

KUHLTHAU, C. **Seeking meaning**. Norwood: Ablex, 1993.

KUHLTHAU, C. **Como usar a biblioteca na escola: um programa de atividades para o ensino fundamental.** 2. ed. Belo Horizonte: Autêntica, 2004.

LANCASTER, F. W. Avaliação da instrução bibliográfica. In: _____. **Avaliação de serviços de bibliotecas**. Brasília: Briquet de Lemos Livros, 1996. Cap. 12, p. 226-262.

MÜELLER, S. P. M. Perfil do bibliotecário, serviços e responsabilidades na área de informação e formação profissional. **Revista de Biblioteconomia de Brasília**, v. 17, n. 1, p. 63-70, jan./jul. 1989.

PASQUARELLI, M. L. R. P**rocedimentos para busca e uso da informação**: capacitação do aluno de graduação. Brasília: Thesaurus, 1996. 86 p.

PASQUARELLI, M. L. R. O papel da universidade na capacitação do estudante de graduação para busca e uso da informação: a disciplina Orientação Bibliográfica em revisão. 1993. 115f. **Tese** (Doutorado em Ciências da Comunicação) – Escola de Comunicação e Artes. Universidade de São Paulo, São Paulo, 1993.

SADI, B. S. C. et al. Satisfação e frustração do usuário em obter documentos em uma biblioteca acadêmica de saúde pública. In: **SEMINÁRIO NACIONAL DE BIBLIOTECAS UNIVERSITÁRIAS** 4., 1985, Campinas. Anais. Campinas, 1985.

SANTOS, J. P. O moderno profissional da informação: o bibliotecário e seu perfil face aos novos tempos. **Informação & Informação**, Londrina, v. 1, n. 1, p. 5-13, jan./jun. 1996.

SARACEVIC, T. Ciência da informação: origem, evolução e relações. **Perspect. ciênc. inf.,** Belo Horizonte, v. 1, n. 1, p. 41-62, jan./jun. 1996. Disponível em: <http://portaldeperiodicos.eci.ufmg.br/index.php/pci/article/view/235/22>. Acesso em: 28 set. 2018.

TAKAHASHI, T. (Org.) **Sociedade da informação no Brasil: livro verde.** Brasília: Ministério da Ciência e Tecnologia, 2000. 203 p.

TARAPANOFF, K. P**erfil do profissional da informação no Brasil:** diagnóstico de necessidade de treinamento e educação continuada. Brasília: IEL/DF, 1997. 137 p.

TARGINO, M. G. Quem é o profissional da informação? **Transinformação**. Campinas, v. 12, n. 2, p. 61-69, jul./dez. 2000.

Sobre os Autores

Ana Alice Baptista

Concluiu Tecnologias e Sistemas de Informação pela Universidade do Minho em 2003. É Professor Auxiliar na Universidade do Minho. Publicou 15 artigos em revistas especializadas e 36 trabalhos em atas de eventos, possui 8 capítulos de livros e 5 livros publicados. Possui 16 softwares e outros 88 itens de produção técnica. Participou em 31 eventos no estrangeiro e 24 em Portugal. Orientou 1 tese de doutoramento e coorientou 2, orientou 10 dissertações de mestrado, além de ter orientado 3 trabalhos de conclusão de curso de bach./licenciatura e 14 trabalhos de iniciação científica nas áreas de Engenharia Eletrotécnica, Eletrônica e Informática, Ciências da Computação e da Informação e Outras Ciências Sociais. Entre 2001 e 2010 participou em 3 projetos de investigação, sendo que coordenou 2 destes. Atua na área de Ciências Exatas com ênfase em Ciências da Computação e da Informação. Nas suas atividades profissionais interagiu com 78 colaboradores em coautorias de trabalhos científicos. No seu curriculum DeGóis os termos mais frequentes na contextualização da produção científica, tecnológica e artístico-cultural são: Metadados, Web semântica, Dublin Core, Comunicação científica, Sistemas de Informação, RDF, Acesso Livre, Publicação Eletrônica, Repositórios Institucionais e Bibliotecas Digitais.

Fábio Mosso Moreira

É mestre e doutorando em Ciência da Informação pelo Programa de Pós-Graduação em Ciência da Informação pela UNESP. Também é graduado em Administração de Empresas pela UNESP. Também atua como membro do Grupo de Pesquisa Novas Tecnologias em Informação – GPNTI e Grupo de Pesquisa Tecnologia de Acesso a Dados – GPTAD. É membro do Projeto Competências Digitais para Agricultura Familiar (CoDAF).

Fernando de Assis Rodrigues

Professor Adjunto no Instituto de Ciências Sociais Aplicadas, lotado na Faculdade de Arquivologia da Universidade Federal do Pará. Doutor e Mestre em Ciência da Informação pela UNESP – Universidade Estadual Paulista. Especialista em Sistemas para Internet pela UNIVEM – Centro Universitário Eurípides de Marília. Bacharel em Sistemas de Informação pela USC – Universidade do Sagrado Coração. Membro dos grupos de pesquisa GPNTI – Novas Tecnologias em Informação e GPTAD – Tecnologias de Acesso a Dados (UNESP), GPIDT – Informação, Dados e Tecnologia (USP) e GPDM – Dados e Metadados (UFSCar). Editor do periódico RECoDAF – Revista Eletrônica Competências Digitas para a Agricultura Familiar. Atua nas áreas da Ciência da Informação e da Ciência da Computação, com ênfase em Engenharia de Software, Bancos de Dados, Tecnologia de Informação e Comunicação e Ambientes Informacionais Digitais, focado principalmente nos seguintes temas: Coleta de Dados, Dados, Acesso a Dados, Serviços de Redes Sociais Online, Linked Data, Linked Open Data, Metadados, Internet Applications, Linguagens de Programação, Banco de Dados e Bases de Dados, Privacidade, Governo eletrônico, Open Government Data e Transparência.

Guilherme Ataíde Dias

Graduado em Ciência da Computação pela Universidade Federal da Paraíba – UFPB Campus II (1990), Bacharel em Direito pelo Centro Universitário de João Pessoa – UNIPE (2010), Mestre em Organization & Management pela Central Connecticut State University – CCSU (1995), Doutor em Ciência da Informação (Ciências da Comunicação) pela Universidade de São Paulo – USP (2003) e Pós-Doutor pela UNESP (2011). Atualmente é professor Associado III na Universidade Federal da Paraíba, lotado no Departamento de Ciência da Informação. Está envolvido com a Pós-Graduação através do Programa de Pós-Graduação em Ciência da Informação e Programa de Pós-Graduação em Administração, ambos da UFPB. Tem interesse de pesquisa nas seguintes temáticas: Representação do Conhecimento; Arquitetura da Informação; Segurança da Informação; Tecnologias da Informação e Comunicação; Informação em Saúde; Redes Sociais; Software Livre; Direito, Ética e Propriedade Intelectual no Ciberespaço; Gestão de Dados Científicos; Informação Jurídica; Atualmente é Bolsista de Produtividade em Pesquisa (PQ) do CNPq.

Luís Fernando Sayão

Possui graduação em Física pela Universidade Federal do Rio de Janeiro (1978), mestrado em Ciência da Informação pela Universidade Federal do Rio de Janeiro/Instituto Brasileiro de Informação em Ciência e Tecnologia (UFRJ/IBICT) e doutorado em Ciência da Informação pela UFRJ/IBICT (1994). Trabalha desde 1980 na Comissão Nacional de Energia Nuclear onde já exerceu os cargos de: chefe do Centro de Informações Nucleares (CIN); chefe da Divisão de Tecnologia da Informação; coordenador-geral de Informática; representante do Brasil no INIS – International Nuclear Information System (AIEA/ONU); coordenador-geral da RRIAN – Red Regional de Información en el Área Nuclear. É conselheiro do CONARQ – Conselho Nacional de Arquivos, membro do Câmara Técnica de Documentos Eletrônicos do CONARQ; docente do Programa de Pós-Graduação em Biblioteconomia da UNIRIO – Universidade Federal do Estado do Rio de Janeiro e do Programa de Pós-Graduação em Memória e Acervos da Fundação Casa de Rui Barbosa. Foi membro do Comitê Técnico-Científico do IBICT e da Comissão de Ensino da CNEN.

Luana Farias Sales Marques

Doutora em Ciência da Informação pelo Programa de Pós-Graduação do IBICT/UFRJ (2011-2014). Mestre em Ciência da Informação pelo convênio UFF/IBICT (2004 – 2006), Graduação em Biblioteconomia e Documentação pela Universidade Federal Fluminense (2003). Atuou como Analista em C & T da CNEN, no Instituto de Engenharia Nuclear, participando da criação da linha de pesquisa de Gestão do Conhecimento Nuclear. Atuou ainda como docente do curso de graduação em Biblioteconomia da Universidade Federal do Estado do Rio de Janeiro – UNIRIO e Universidade Federal Fluminense, ministrando disciplinas relacionadas à Organização do Conhecimento. Atualmente é Analista em C & T do MCTIC/IBICT, atuando como docente do Programa de Pós-graduação em Ciência da Informação do convênio IBICT-UFRJ.

Marcos Vinícius Ferreira Cesário

Possui graduação em Direito pela UEPB (2009), sendo Especialista em Gestão Pública também pela UEPB, além de, atualmente, ser aluno do Mestrado Profissional em Gestão das Organizações Aprendentes pela UFPB. Atualmente é Servidor Público efetivo do Ministério Público da Paraíba, ocupando o cargo de Diretor Administrativo da instituição. No MPPB, também já ocupou os cargos de Chefe do Departamento de Assessoria Jurídica, Diretor de Planejamento Orçamentário e Diretor Financeiro, além de ter sido Membro da Comissão Organizadora do III Concurso para Provimento de Cargos no Quadro de Serviços Auxiliares. Junto ao Instituto de Arquitetos do Brasil – Departamento da Paraíba, participou, na qualidade de Consultor Jurídico, do Concurso Público Nacional de Anteprojetos Arquitetônicos para a Contratação do Projeto Arquitetônico do Ministério Público da Paraíba em João Pessoa. Foi nomeado pelo Tribunal Regional Federal da 5ª Região para exercer o cargo efetivo de Técnico Judiciário. Atualmente, foi designado pelo Conselho Nacional do Ministério Público como Coordenador do Comitê de Políticas de Gestão Administrativa. Professor de Direito Administrativo do Curso de Formação de Oficiais e da Especialização em Segurança Pública, da Polícia Militar – PB.

Marcello Peixoto Bax

Professor Titular do Programa de Pós-Graduação em Gestão e Organização do Conhecimento (PPG-GOC/UFMG). Atualmente em estágio pós-doutoral (pela CAPES) no Tetherless World Constellation Lab, no Rensselaer Polytechnic Institute (RPI). Doutor em Ciência da Computação pela Universidade de Montpellier II, França. Possui Diploma de Estudos Aprofundados em Matemática e Computação e Diploma de Estudos Superiores Especializados em Informática pela Université d'Aix Marseille II, França. Bacharel em Ciência da Computação pela Pontifícia Universidade Católica de Minas Gerais (PUC-MG). Foi líder da Linha de Pesquisa Gestão da Informação e do Conhecimento no PPGCI da ECI/UFMG (2015-2016). Coordenou projeto PD&I em Gestão da Informação e do Conhecimento em convênio UFMG/CEMIG, com financiamento da ordem de R$ 2 milhões (cemig.eci.ufmg.br). Foi coordenador por dois mandatos do Núcleo de Informação Gerencial e Tecnológica – NITEG (ECI/UFMG, 2008-2012 e 2014-2016). Foi coordenador do Curso de Especialização (360 h) "Gestão Estratégica da Informação" por dois mandatos. Participou por dois mandatos como membro do Comitê Assessor da área de Ciências Sociais Aplicadas da Pró-Reitoria de Pesquisa da UFMG e de várias comissões e órgãos colegiados da ECI e da UFMG.

Maurício Barcellos Almeida

Doutor em Ciência da Informação (UFMG), com pós-doutorado pela State University of New York, Mestre em Ciência da Informação (UFMG), Especialista em Administração (UNA), Especialista em Engenharia de Software (PUCMINAS), graduado em Engenharia Civil (UFMG), possui ainda o título Microsoft System Engineer. Atualmente é Professor Associado da UFMG, Departamento de Teoria e Gestão da Informação, onde mantém pesquisas em Representação do Conhecimento.

Moisés Lima Dutra

Professor Adjunto da Universidade Federal de Santa Catarina, Departamento de Ciência da Informação. Doutor em Computação pela Universidade de Lyon 1, França (2009). Mestre em Engenharia Elétrica, subárea Automação e Sistemas (2005) e Bacharel em Computação (1998) pela Universidade Federal de Santa Catarina. Suas atuais linhas de pesquisa estão relacionadas a Inteligência Artificial Aplicada (Machine Learning, Deep Learning, Web Semântica, Linked Data) e a Data Science (Text Mining, Big Data, IoT). Está vinculado ao grupo de pesquisa ITI-RG (Inteligência, Tecnologia e Informação – Research Group).

Pedro Luiz Pizzigatti Corrêa

Possui graduação em Ciência da Computação pela Universidade de São Paulo (1987), mestrado em Ciência da Computação e Matemática Computacional pela Universidade de São Paulo (1992), doutorado em Engenharia Elétrica pela Escola Politécnica da Universidade de São Paulo (2002), pós-doutoramento em Data Science na University of Tennessee (2015) e Livre Docência pela Universidade de São Paulo (2017). Atualmente é Livre Docente do Departamento de Engenharia de Computação e Sistemas Digitais da Escola Politécnica da Universidade de São Paulo.

Plácida Leopoldina Ventura Amorim da Costa Santos

Livre-docente em Catalogação pela UNESP (2010), doutora em Letras – Semiótica e Linguística Geral pela FFLCH/USP (1994), mestre em Ciência da Informação pela PUC de Campinas (1983) e bacharel em Biblioteconomia pela UNESP (1980). Docente permanente do Programa de Pós-Graduação em Ciência da Informação da FFC/UNESP, na linha de pesquisa Informação e Tecnologia. Vice-líder do Grupo de Pesquisa Novas Tecnologias em Informação (GP-NTI). Desenvolve suas pesquisas nas temáticas: Metadados, Catalogação e Tecnologias, Intersemiose Digital, Redes de Informação, Mapa do Conhecimento Humano. Pesquisadora CNPq, coordenadora do GT8 – Informação e Tecnologia, da Associação Nacional de Pesquisa e Pós-Graduação em Ciência da Informação – ANCIB (2013-2016). Editora da revista Informação & Tecnologia (Itec), membro do corpo editorial das revistas Brazilian Journal of Information Science: research trends e Revista Eletrônica Informação e Cognição. Parecerista ad hoc de agências de fomento e de periódicos científicos, participa como revisora e como membro de Comitês Científicos de periódicos científicos em Ciência da Informação no Brasil e no exterior. Membro da Associação Nacional de Pesquisa e Pós-Graduação em Ciência da Informação – ANCIB e membro da Diretoria da Sociedade Brasileira de Ciência Cognitiva – SBCC.

Ricardo César Gonçalves Sant'Ana

Professor Associado da Universidade Estadual Paulista – UNESP, Faculdade de Ciências e Engenharias – FCE, Campus de Tupã, em regime de dedicação exclusiva, onde é Presidente da Comissão de Acompanhamento e Avaliação dos cursos de Graduação – CAACG, Coordenador Local do Centro de Estudos e Práticas Pedagógicas – CENEPP e Ouvidor Local. Professor do Programa de Pós-Graduação em Ciência da Informação da Universidade Estadual Paulista, Campus de Marília. Graduado em Matemática e Pedagogia, Mestrado em Ciência da Informação (2002), Doutorado em Ciência da Informação (2008) e Livre-Docente em Sistemas de Informações Gerenciais pela UNESP (2017). Possui especializações em Orientação a Objetos (1996) e Gestão de Sistemas de Informação (1998). Parecerista ad hoc de periódicos e de agências de fomento. Membro do Grupo de Pesquisa – Novas Tecnologias em Informação GPNTI-UNESP. Tem experiência na área de Ciência da Computação, atualmente realiza pesquisas com foco em: ciência da informação e tecnologia da informação, investigando temas ligados ao Ciclo de Vida dos Dados, Transparência e ao Fluxo Informacional em Cadeias Produtivas. Atuou como professor na Faccat Faculdade de Ciências Contábeis e Administração de Tupã, onde coordenou curso de Administração com Habilitação em Análise de Sistemas por dez anos e o curso de Licenciatura em Computação. Atuou no setor privado como consultor, integrador e pesquisador de novas tecnologias informacionais de 1988 a 2004.

Sandra de Albuquerque Siebra

Possui doutorado em Ciências da Computação pela Universidade Federal de Pernambuco (2007), mestrado em Ciência da Computação pela Universidade Federal de Pernambuco (1998) e graduação no curso de Bacharelado em Ciência da Computação pela Universidade Federal da Paraíba. Atualmente é professora-adjunta da Universidade Federal de Pernambuco (UFPE), lotada no Departamento de Ciência da Informação (DCI). É professora do Programa de Pós-graduação em Ciência da Informação e pesquisadora do Laboratório LIBER/UFPE. Atua também como colaboradora nos projetos de educação à distância do Instituto Aggeu Magalhães/Fiocruz, no papel de design instrucional. Tem interesse, principalmente, nos seguintes temas: Curadoria Digital, Preservação Digital, Repositórios Digitais, Arquitetura da Informação, Interação Humano-Computador, Design Instrucional, Educação a Distância, Objetos Culturais e Aprendizagem Colaborativa.

Wagner Junqueira de Araújo

Doutor em Ciência da Informação pela Universidade de Brasília (2009), mestre em Ciência da Informação – UNB (2001), especialista em Sistemas de Informação (1995) e Bacharel em Ciência da Computação pela Universidade do Oeste Paulista (1993). Professor do Programa de Pós-graduação em Ciência da Informação – PPGCI-UFPB. Professor do Programa de Pós-Graduação em Gestão nas Organizações Aprendentes. Professor Associado – I do Departamento de Ciência da Informação da Universidade Federal da Paraíba.

Organização Geral do Evento

Guilherme Ataíde Dias	Coordenador geral do evento	UFPB – Universidade Federal da Paraíba
Moisés Lima Dutra	Vice-coordenador	UFSC – Universidade Federal de Santa Catarina
Ricardo C. G. Sant'Ana	Coordenador da Comissão Científica	UNESP – Universidade Estadual Paulista
André Luiz Dias de França	Coordenador do Cerimonial	UFPB – Universidade Federal da Paraíba
Laerte P. da Silva Júnior	Coordenador da Equipe Técnica Local	UFPB – Universidade Federal da Paraíba

Comissão Científica

Adilson Luiz Pinto	UFSC – Universidade Federal de Santa Catarina
Ana Alice Baptista	UMinho – Universidade do Minho
Ana Carolina Simionato	UFSCar – Universidade Federal de São Carlos
Ângela Maria Grossi de Carvalho	UNESP – Universidade Estadual Paulista
Bernardina Juvenal Freire	UFPB – Universidade Federal da Paraíba
Cristian Berrio-Zapata	UFPA – Universidade Federal do Pará
Dalton Lopes Martins	UnB – Universidade de Brasília
Denysson Axel Ribeiro Mota	UFCA – Universidade Federal do Cariri
Douglas Dyllon Jeronimo de Macedo	UFSC – Universidade Federal de Santa Catarina
Ed Porto Bezerra	UFPB – Universidade Federal da Paraíba
Edgar Bisset Alvarez	UFSC – Universidade Federal de Santa Catarina
Edna Brennand	UFPB – Universidade Federal da Paraíba
Edna Gomes Pinheiro	UFPB – Universidade Federal da Paraíba
Elaine Parra Affonso	FATEC – Faculdade de Tecnologia de São Paulo
Elvis Fusco	UNIVEM – Centro Universitário Eurípides de Marília
Enrique Muriel-Torrado	UFSC – Universidade Federal de Santa Catarina
Evandro de Barros Costa	UNESP – Universidade Estadual Paulista
Fábio Paraguaçu	UFAL – Universidade Federal do Alagoas
Fernando de Assis Rodrigues	UFPA – Universidade Federal do Pará
Gustavo Medeiros de Araújo	UFSC – Universidade Federal de Santa Catarina
Henry Pôncio	UFPB – Universidade Federal da Paraíba
Joana Coeli Ribeiro Garcia	UFPB – Universidade Federal da Paraíba
José Eduardo Santarém Segundo	USP – Universidade de São Paulo
Leonardo Castro Botega	UNIVEM – Centro Universitário Eurípides de Marília
Luana Farias Sales Marques	UFRJ – Universidade Federal do Rio de Janeiro
Marckson Roberto Ferreira de Sousa	UFPB – Universidade Federal da Paraíba
Luís Fernando Sayão	CNEN – Comissão Nacional de Energia Nuclear
Marcelo Morandini	USP – Universidade de São Paulo
Márcio Matias	UFSC – Universidade Federal de Santa Catarina
Marcos Mucheroni	USP – Universidade de São Paulo
Marynice M. M. Autran	UFPB – Universidade Federal da Paraíba

Maurício B. Almeida	UFMG – Universidade Federal de Minas Gerais
Moisés Lima Dutra	UFSC – Universidade Federal de Santa Catarina
Plácida Leopoldina Ventura Amorim da Costa Santos	UNESP – Universidade Estadual Paulista
Pedro Luiz Pizzigatti Corrêa	USP – Universidade de São Paulo
Renata Baracho	UFMG – Universidade Federal de Minas Gerais
Ricardo César Gonçalves Sant'Ana	UNESP – Universidade Estadual Paulista
Robson Rodrigues Lemos	UFSC – Universidade Federal de Santa Catarina
Rogério Ramalho	UFSCar – Universidade Federal de São Carlos
Ryan Ribeiro de Azevedo	UFRP – Universidade Federal Rural de Pernambuco
Sandra de Albuquerque Siebra	UFPE – Universidade Federal de Pernambuco
Sandro Rautenberg	UNICENTRO – Universidade Estadual do Centro-Oeste
Silvana Ap. Borsetti Gregorio Vidotti	UNESP – Universidade Estadual Paulista
Virgínia Bentes Pinto	UFC – Universidade Federal do Ceará
Wagner Junqueira de Araújo	UFPB – Universidade Federal da Paraíba
Zaira Regina Zafalon	UFSCar – Universidade Federal de São Carlos

Equipe Técnica Local

Adriana Alves Rodrigues	UFPB – Universidade Federal da Paraíba
Antônio Felipe dos Santos	UFPB – Universidade Federal da Paraíba
Débora Gomes de Araújo	UFPB – Universidade Federal da Paraíba
Pedro Augusto de Lima Barroso	UFPB – Universidade Federal da Paraíba
Pollianna Marys de Souza e Silva	UFPB – Universidade Federal da Paraíba
Renata Lemos dos Anjos	UFPB – Universidade Federal da Paraíba

Apoio:

UFPB UFSC unesp GPTAD Grupo de Pesquisa Tecnologias de Acesso a Dados CNPq Conselho Nacional de Desenvolvimento Científico e Tecnológico CAPES