

Indexação automática de imagens na web: tendências e desafios no contexto *Deep Learning*

Luciana de Souza Gracioso

Universidade Federal de São Carlos, Departamento de Ciência da Informação, São Carlos, SP, Brasil
lgracioso@yahoo.com.br

Ana Carolina Simionato

Universidade Federal de São Carlos, Departamento de Ciência da Informação, São Carlos, SP, Brasil
ac.simionato@gmail.com

Luís Miguel Oliveira Machado

Universidade de Coimbra, Coimbra, Faculdade de Economia, Biblioteca, Coimbra Portugal
luismmachado70@gmail.com

Maria da Graça Melo Simões

Universidade de Coimbra, Faculdade de Letras, Departamento de Filosofia, Comunicação e Informação, Coimbra, Portugal
gsimoesuc@gmail.com

DOI: <https://doi.org/10.26512/rici.v11.n2.2018.8342>

ARTIGOS DE REVISÃO

Resumo: O objetivo deste estudo é investigar em que medida as pesquisas na Ciência da Informação (CI) tem aproximado às das técnicas de *Deep Learning*, sendo relacionadas à representação, descrição e recuperação de imagens na *Web*, e assim, aferir da mais valia destas pesquisas quando aplicadas aos métodos da área da CI. A partir de uma revisão integrativa de literatura nacional e internacional de modo contextualizado na CI, os documentos recuperados foram analisados conforme os critérios da revisão integrativa, identificando um conjunto de operações que poderiam ser integrados nas metodologias de representação e descrição de imagens desenvolvidas e consolidadas no campo da CI. Conclui-se que ainda há uma lacuna nas pesquisas em CI tanto no âmbito nacional como internacional sobre *Deep Learning* e que recursos desta nova estrutura de programação podem ser aproximados aos métodos já validados pela área.

Palavras-chave: *deep learning*; indexação de imagens; *machine learning*; recuperação de imagens na *web*.

Automatic indexing of web images: trends and challenges in deep learning context

Abstract: The objective of this study is to investigate the extent to which research in Information Science (IS) has approximated those techniques of the *Deep Learning*, being related to representation, description and retrieval of images on the *Web*, and thus, to assess the value of these researches when applied to IS methods. From an integrative review of national and international literature contextualized in the IS, the recovered documents were analyzed according to the criteria of the integrative review, identifying a set of operations that could be attached in the methodologies of representation and description of images developed and consolidated in the field of IS. It is concluded that there is still a gap in research of IS area both at national and international level on *Deep Learning* and that resources of this new programming structure can be approximated to the methods already validated by the area.

Keywords: *deep learning*; image retrieval on the web; indexing of images; machine learning.

Indexación automática de imágenes en la web: tendencias y desafíos en el contexto *deep learning*

Resumen: El objetivo de este estudio es investigar en qué medida las investigaciones en la Ciencia de la Información (CI) han aproximado a las de las técnicas de Deep Learning, siendo relacionadas la representación, descripción y recuperación de imágenes en la Web, y así, aferir de la plusvalía de estas investigaciones cuando aplicados a los métodos del área de la CI. A partir de una revisión integrativa de la bibliografía nacional e internacional contextualizada en el CI, los documentos recuperados se analizaron de acuerdo con los criterios de la revisión integrativa, identificando un conjunto de operaciones que podrían ser integrado en las metodologías de representación y descripción de imágenes desarrolladas y consolidadas en el campo de CI. Se concluye que todavía existe una brecha en la investigación de CI tanto a nivel nacional como internacional sobre el aprendizaje profundo y que los recursos de esta nueva estructura de programación pueden aproximarse a los métodos ya validados por el área.

Palabras clave: deep learning; indización de imágenes; machine learning; recuperación de imágenes em la web.

1 Introdução

Diante dos novos espaços virtuais e interativos mediados por tecnologias da informação, que suscitam novas formas de comunicação, se faz necessário revisitar as práticas e as técnicas de organização do conhecimento, pensando se seria necessário, ainda, alargar as possibilidades de localização, uso e retroalimentação da informação na *Web*. Essas práticas, orientadas por normas e padrões de descrição, estão sendo cada vez mais embutidas nas programações de sistemas complexos programados a partir de lógicas convolucionais que possibilitam um nível de aprendizagem profunda pelo próprio sistema.

No ambiente computacional a compreensão sobre o conceito de informação significa atribuir uma contextualização aos dados e neste contexto tem sido desenvolvido um conjunto de técnicas e operações que resumiremos neste momento enquanto *Deep Learning*, que tem como base o uso de orientações oriundas da compreensão das redes convolucionais na programação tornando possível promover a detecção, a percepção e o reconhecimento automático de objetos. Para Ceci (2015) o *Deep Learning* seria “[...] a aplicação de técnicas na área de aprendizagem de máquina (*Machine Learning*) para a aprendizagem de novos padrões” (2015, p. 78). Os algoritmos utilizados podem ser treinados a partir de dados iniciais de aprendizagem (AREL; ROSE; KARNOWSKI, 2010). O *Deep Learning* tem sido explorado, na prática computacional, principalmente para otimizar o processamento de linguagem natural, os recursos de reconhecimento automático de voz e principalmente, a descrição e indexação automática de imagens.

Sobre a representação, descrição e indexação de imagens na *Web*, a Ciência da Informação (CI), mais pontualmente, no que se refere aos estudos de organização do conhecimento, tem larga trajetória na representação documental de fotografias e documentos gráficos. As classificações por elementos de destaque na imagem são realizadas por métodos de análise sistemáticos realizando agrupamentos temáticos no intuito de uma recuperação eficiente

das mesmas. Mas estas práticas, mesmo orientadas por normas, são dinâmicas e potencialmente abertas para complementações. As atividades de indexação social, por exemplo, têm se confirmado como ações, cuja aproximação com as práticas já validadas de indexação, que resultam em recuperações mais relevantes para o usuário.

Elucidadas pela prática, a indexação social (*tagueamento* ou *folksonomia*) pode ser advindo de uma indexação profissional ou mesmo criado a partir de linguagem natural com a colaboração dos usuários. Os estudos sobre a indexação social, como afirma Cordeiro (2018, p. 25) “[...] são importantes e fazem parte da sociedade contemporânea que vivemos, contudo, esses estudos sobre a nomeação de conceitos e emoções abstratos identificados nos documentos já levantaram questões sobre sua utilidade.”

Ainda na primeira década dos anos 2000, fase em que as plataformas interativas virtuais ampliaram seu alcance e desempenho, pesquisadores já se dedicaram a refletir e operacionalizar atividades de indexação colaborativa às práticas sistêmicas. Algumas das práticas internacionais desta fase que destacamos são as pesquisas feitas por Angus, Helwall e Stuart (2008); Choi e Rasmussem (2003); Matusiak (2006); Trant (2006); Plangprasopchok e Lerman (2009); Sigurbjörnsson e Zwol (2008). Havendo interesse, uma análise destes trabalhos também pode ser vista em Gracioso (2014), apenas para não nos dedicamos com muita ênfase a esta faceta de indexação social, neste momento.

No cenário brasileiro, as pesquisas que introduziram discussões mais interdisciplinares sobre a indexação social (*folksonomias*) foram as de Caldas e Moreira, (2009); Aquino (2007), Reis (2013), Moreira e Romão (2008), Moura (2009) e Mejias, (2005); Galdo; Viera; Rodrigues (2009). Mais recentemente, ainda no Brasil, avanços tem sido alcançado sobre a temática. Em 2014, Sousa, Fujita e Gracioso organizaram a obra: “A imagem na Ciência da Informação: reflexões teóricas, experiências práticas”. Nesta coletânea, foram apresentados exercícios de naturezas diversas que analisam criticamente e prospectivamente ações de indexação de imagens no contexto web, ou fora dele. Além desta obra, trabalhos mais recentes têm desse destacado como os de Tartarotti; Dal’Evedove; Fujita (2016); Vignoli; Almeida; Catarino (2014); Strehl (2011); Guedes; Moura; Dias (2011); Gracioso (2010). Assim, mesmo não esgotando a apresentação de todos os estudos desenvolvidos sobre o tema da indexação social, percebe-se a continua dedicação do campo para analisar e operacionalizar ações e práticas de indexação e recuperação da informação que validem estas ações sociais.

Somam-se a estas práticas sociais de indexação de conteúdos na Web, o contínuo desenvolvimento de lógicas computacionais que operacionalizam automaticamente a indexação de imagens na Web. Assim, face ao impacto causado pela aplicação das novas lógicas de aprendizagem profunda das máquinas na representação e recuperação da informação na Web,

entende-se que uma aproximação destes conceitos e métodos aos da CI, seria uma mais-valia para otimizar as propostas de representação da imagem na *Web*. No entanto, diante da atualidade do assunto, a hipótese inicial elencada neste estudo foi a de que não haveria ainda um conjunto expressivo de publicações da área da CI sobre o tema, mas que, uma vez identificado trabalhos nesta envergadura, os mesmos demandariam ainda de identificação, agrupamento, sistematização e análise de seus conteúdos, vislumbrando-se com isto, poder oferecer ao campo da CI, um conjunto de subcategorias temáticas de investimento e desenvolvimento de pesquisas, produtos e serviços. Assim, neste primeiro momento, este trabalho se propôs a mapear e discutir inicialmente o estado da arte sobre o tema na Ciência da Informação, sem ser possível ainda, dada a recentidade do assunto, aferir relações metodológicas concretas para a Ciência da Informação, ficando este objetivo mais empírico, dedicado às pesquisas futuras do grupo.

Neste cenário, foi objetivo deste estudo, identificar e analisar, em que medida o campo da CI, dedicado à descrição, representação e recuperação de imagens na *Web*, têm adotado as técnicas de *Deep Learning* para aferir da mais valia destas quando aplicadas aos métodos deste campo. Pretende-se, deste modo, diagnosticar o que se afigura ser uma emergente lacuna de conhecimento no que diz respeito aos estudos desta área e ao mesmo tempo, identificar estratégias que poderiam ser integrados nos recursos de representação e descrição de imagens já desenvolvidas na CI.

Foram objetivos específicos da pesquisa: I) apresentar e analisar pesquisas básicas que conceituam o *Deep Learning*, dando principal ênfase na sua interface com as ações de descrição e recuperação de imagens na *Web*; II) identificar e recuperar os principais estudos voltados à representação descritiva e temática de imagens na *Web* recorrendo a técnicas associadas ao *Deep Learning*, no âmbito da CI, num cenário nacional e internacional; III) categorizar e analisar os conteúdos dos artigos identificados, sistematizando potenciais categorias temáticas já investigadas e promovendo uma discussão sobre potenciais desdobramentos sobre o tema na CI.

2 Desenvolvimento

2.1 Machine Learning: definições introdutórias

Machine Learning (ML) pode ser definido como um campo de estudo da Inteligência Artificial - AI (sendo esta uma área disciplinar da Ciência da Computação), relacionado com o desenvolvimento de sistemas computacionais capazes de fazer previsões e tomar decisões a partir de um conjunto de dados (DEHAVEN, 2017; HOSCH, 2009; VALENZUELA, 2017; WALDRON, 2015). Outras definições apresentam o conceito de ML como sendo o

desenvolvimento de algoritmos computacionais capazes de *aprender* e fazer previsões com base num conjunto de dados (ÁVILA, 2013; CALSAVERINI, 2016; LOPES, 2016).

Segundo Tom Mitchell (2006), ML surge da intersecção da Ciência da Computação com a Estatística, na medida em que pretende construir máquinas que resolvam problemas e extrair inferências confiáveis de dados, acrescentando questões próprias como, por exemplo, a autoprogramação computacional.

Embora as definições apresentadas auxiliem ao entendimento do conceito, levantam uma questão fundamental: o que se pode entender por *uma máquina capaz de aprender*? Tom Mitchell, na sua apresentação da disciplina de ML, expõe a seguinte resposta:

[...] dizemos que uma máquina aprende em relação a uma determinada tarefa T, métrica de desempenho P e tipo de experiência E, se o sistema confiável melhora seu desempenho P na tarefa T, seguinte E. Dependendo de como especificamos T, P e E de experiência, a tarefa de aprendizagem também pode ser chamada por nomes como mineração de dados, descoberta autônoma, banco de dados de atualização, programação, por exemplo, etc. (MITCHELL, 2006, p. 1. Tradução livre dos autores).

Poder-se-á exemplificar esta aprendizagem através de uma aplicação informática cuja tarefa seja detectar e prever padrões de trânsito em determinada intersecção rodoviária, esta ‘aprenderá’ com sucesso quando, através da análise de dados relativos a padrões de trânsito anteriores, melhora consistentemente as suas posteriores previsões.

A principal distinção entre os processos de aprendizagem usados em ML diz respeito à aprendizagem supervisionada ou não supervisionada (ÁVILA, 2013). Na primeira, o sistema faz previsões com base num ‘treino’ com um conjunto de amostras previamente rotuladas. Na segunda, as amostras não são rotuladas e o sistema necessita, por si só, identificar relações ou padrões nos dados apresentados. (ÁVILA, 2013; JOST, 2016; REBELO, 2008). Exemplos típicos da aprendizagem supervisionada são a classificação ou a regressão, quando o alvo a prever é, respetivamente, uma categoria ou um valor (como o preço de cotações, por exemplo). Uma tarefa típica da aprendizagem não supervisionada é o *clustering*, consistindo no agrupamento de pontos de um conjunto de dados em ‘grupos naturais’ ou proceder ao ‘agrupamento hierárquico’ desses mesmos pontos (CALSAVERINI, 2016, p. 8).

Dentre as abordagens de ML com melhores resultados no processamento de informação imagética, Ávila (2013) aponta: *k-Nearest Neighbor Classification* e *Support Vector Machines* (como exemplos que utilizam processos supervisionados), o modelo *Bag-of-Visual-Words* (que usa um algoritmo não supervisionado na obtenção do imprescindível ‘dicionário visual’ para o seu funcionamento) e as *Convolutional Neural Network* com arquitetura *Deep Learning* (que apresentam variações operando com um ou outro processo). De acordo com Carvalho (2015) o modelo *Bag-of-Visual-Words* era, até meados da década de 2000, o

esquema com maior sucesso na classificação de imagens, atualmente, este e outros investigadores (BEZERRA, 2016; CALSAVERINI, 2016; DENG; YU, 2014; FERGUS, 2016; JOST, 2016; SHAO et al., 2017; VITORINO, 2016; WALDRON, 2015; YANG et al., 2017) apontam as Redes Neurais Artificiais (RNA) com arquitetura *Deep Learning*, em particular as *Deep Convolutional Neural Network*, como sendo o sistema com melhor desempenho em nível do reconhecimento de imagens.

2.1.2 Do Machine Learning ao Deep Learning:

Dado a abrangência do conceito *Deep Learning*, o mesmo será usado, no contexto do presente estudo, como reportando-se a um conjunto de técnicas de ML que recorre à utilização de múltiplas camadas (mínimo de quatro) de processamento de informação, dispostas em arquiteturas hierárquicas, para análise de padrões e extração de características (*features*), isto é, representações parciais específicas dos dados em questão (AREL; ROSE; KARNOWSKI, 2010; CALSAVERINI, 2016; CECI, 2015; DENG; YU, 2014; JOST, 2016).

As RNAs, assim denominadas por se inspirarem no funcionamento do córtex cerebral humano, não são uma novidade no campo do ML, sendo o sistema *Perceptron*, criado em 1957 por Rosenblatt, considerado como o primeiro passo rumo às atuais RNAs (DEHAVEN, 2017). Contudo, o desenvolvimento deste tipo de redes ficou comprometido pelas capacidades computacionais da época, nomeadamente no que concerne à utilização de uma arquitetura *Deep Learning* uma vez que a mesma implica múltiplas camadas de unidades de processamento, também chamadas de neurónios artificiais (BEZERRA, 2016; CALSAVERINI, 2016; JOST, 2016).

O renovado interesse, ocorrido a partir de meados da década de 2000, nas RNAs com arquitetura *Deep Learning*, a que se pode chamar de *Deep Neural Networks* (DNNs) (DENG; YU, 2014), foi possível devido a uma combinação de vários fatores. Os três mais determinantes foram: os avanços significativos no desenvolvimento de *hardware*, especialmente nas unidades de processamento gráfico; o desenvolvimento de algoritmos e técnicas mais eficientes para treinar redes neuronais; e a disponibilização crescente de grandes conjuntos de dados, nomeadamente bancos de imagens rotuladas como *ImageNet* ou *Places* (BEZERRA, 2016; CALSAVERINI, 2016; DENG; YU, 2014).

A razão para as DNNs apresentarem melhor desempenho tanto na classificação de imagens como no reconhecimento de objetos contidos nas mesmas, reside no facto de tornarem possível extrair automaticamente e com elevado grau de fiabilidade, informação visual de médio e alto nível, tal como a detecção de limites de objetos que se intersectam e partes de um objeto (DENG; YU, 2014).

2.1.3 Machine Learning, Deep Learning e a representação de imagens na Web

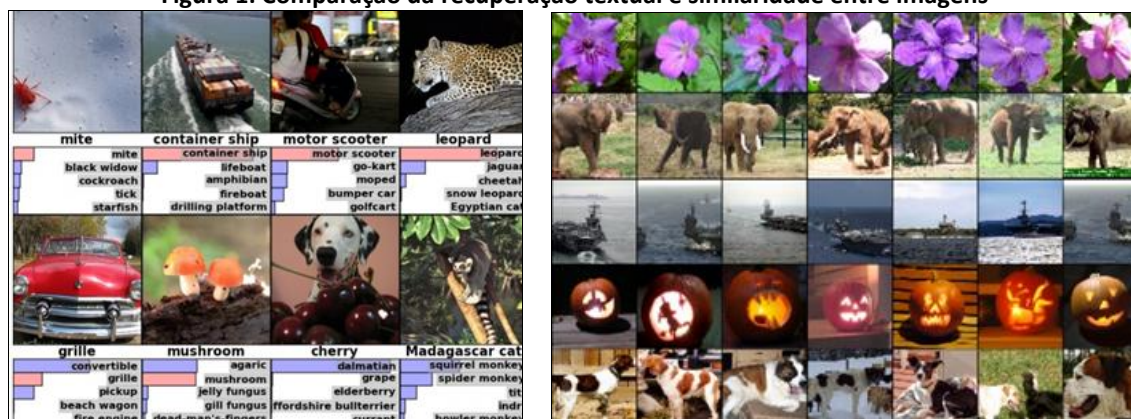
As possibilidades de recuperação da imagem por conteúdo ocorrem por diversas maneiras, como recuperação pela cor, semelhança entre formas e até mesmo pela temperatura. Entre algumas iniciativas de destaque está o estudo da semântica do uso da cor, onde as sensações induzidas pela cor incluem calor, concordância ou contraste, harmonia, excitação, depressão, angústia, entre outros (CORRIDONI; DEL BIMBO; PALA, 1999).

A busca por similaridade é outra maneira de recuperação pelo conteúdo. O reconhecimento de imagens similares em uma base de imagens a partir de uma consulta é denominado como *Content Based Image Retrieval (CBIR)*, e as informações são obtidas a partir da análise de cada *pixel*, sem considerar os índices de textos associados ou anotações externas (WEI; LI; WILSON, 2006). Em suma, cada atributo adiciona uma dimensão ao espaço e cada ponto é determinado pelos dados indexados de cada imagem, a busca por pontos (ou imagens) mais próximos a um específico é denominado como busca por similaridade.

As formas de recuperação da informação podem tornar um sistema de aprendizado que toma decisões baseado em experiências acumuladas por meio da solução bem-sucedida de problemas anteriores, como já mencionado anteriormente nos tópicos sobre *Machine Learning e Deep Learning*.

O grupo de pesquisadores Krizhevsky, Sutskever e Hinton (2012) no artigo *ImageNet classification with deep convolutional neural networks* apresenta vetores e algoritmos calculados para que um sistema consiga recuperar por similaridade, como se verifica na Figura 01, a qual ilustra as dificuldades que as buscas textuais apresentam. Sendo que a retratação da busca, na primeira parte da figura, representa a precisão da recuperação do texto em relação aos resultados de busca para cada imagem, e a segunda parte, os autores demonstram a similaridade dos resultados são mais aperfeiçoados ao que foi procurado.

Figura 1: Comparação da recuperação textual e similaridade entre imagens



Fonte: Krizhevsky, Sutskever e Hinton (2012, p. 8).

A recuperação por similaridade apresentada por Krizhevsky, Sutskever e Hinton (2012) também é utilizada pelos motores de busca como *Google* e *Bing*, por exemplo. O *Google* também contém a indexação por conteúdo e a recuperação por similaridade em seus próprios produtos, como o *Google Photos*.

O *Google Photos* permite aos seus usuários realizarem um *backup* de suas fotos de vários dispositivos em um único local, enquanto também coletam imagens das mesmas pessoas ou objetos em grupos organizados. A partir de uma aprendizagem automática, a ferramenta seleciona as melhores fotos, que estão focadas ou bem compostas.

Esse procedimento de aprendizagem também consegue reconhecer pessoas, animais e coisas, para que possam realizar uma categorização, e assim, o usuário recuperar o conteúdo almejado. A categorização é baseada na recuperação por similaridade, bem como, a identificação de pessoas, pelo reconhecimento de faces. Recentemente, o *Google* tem investido não somente na recuperação por imagens, mas também em desenhos, o que amplia mais a capacidade de aprendizagem e de recuperação.

Assim, frente ao cenário brevemente apresentado, reconhece-se que as técnicas *Deep Learning* têm promovido impactos significativos nas ações de descrição e recuperação de imagens na *Web* e, neste sentido, se intentou verificar o quanto e como esta programação tem sido discutida e analisada na CI, com o intuito de refletir, neste momento, quais seriam as possíveis tendências e os principais desafios desta aproximação.

3 Procedimentos metodológicos

A pesquisa se caracteriza como exploratória, com base na revisão integrativa de artigos de periódicos indexados nas bases de dados especializadas no campo da CI. A revisão integrativa, geralmente é utilizada na área de saúde, permitindo pesquisar, sistematizar e operacionalizar dados provenientes de estudos metodologicamente diversificados (literatura teórica, empírica, experimental), dando destaque aos principais resultados alcançados nas mesmas, permitindo assim, ao final da análise, sinalizar prospecções e ações relacionadas ao assunto. A revisão integrativa se propõe a integrar os trabalhos já desenvolvidos sobre um tema procurando oferecer subsídios para compreensão de um fenômeno particular.

A revisão integrativa da literatura consiste na construção de uma análise ampla da literatura, contribuindo para discussões sobre métodos e resultados de pesquisas, assim como reflexões sobre a realização de futuros estudos. [...] Este método também permite a combinação de dados de literatura teórica e empírica. Assim, o revisor pode elaborar uma revisão integrativa com diferentes finalidades, ou seja, ela pode ser direcionada para a definição de

conceitos, a revisão de teorias ou a análise metodológica dos estudos incluídos de um tópico particular. (MENDES; SILVEIRA; GALVÃO, 2008).

No contexto desta pesquisa, o fenômeno em análise direciona-se para identificação e análise das técnicas *Deep Learning utilizadas* nas metodologias de descrição, indexação e recuperação de imagens, discutindo a viabilidade e os potenciais impactos desta relação nos estudos e nas práticas do campo. São seis as principais etapas desta revisão integrativa, tal como indica Ganong (1987), 1ª Etapa: Elaboração da pergunta norteadora; 2ª Etapa: Busca ou amostragem na literatura; 3ª Etapa: Coleta de dados; 4ª Etapa: Análise crítica dos estudos incluídos; 5ª Etapa: Discussão dos resultados; 6ª Etapa: Apresentação da revisão integrativa. (GANONG, 1987). Outros autores também sugerem etapas similares, mas com algumas outras especificações, são eles: (BEYEA; NICOLL, 1998; BROOME, 2000; COOPER, 1984; WHITTEMORE; KNAFL, 2005).

4 Resultados e discussões

Como ponto de partida para atender a 1ª etapa metodológica, descrita anteriormente, formulou-se o questionamento sobre como a CI tem se voltado às técnicas de *Deep Learning* para aferir da mais valia destas quando aplicadas à representação, descrição e recuperação de imagens na *Web*?

Para atender a 2ª e a 3ª etapa da metodológica, foram desenvolvidas pesquisas bibliográficas. As bases de dados utilizadas para este levantamento foram às indicadas por Lucas, Pinto e Lara (2013), a saber: *Information Science and Technology Abstracts (ISTA)*; *Library Literature Information Science - Full texts (LLIS)*, *Library Information Science Abstracts (LISA)*. Além destas bases também foi analisada a *Base de dados Brasileira de Periódicos em Ciência da Informação (BRAPCI)*. Foram ainda verificadas as referências disponíveis a partir de bases de dados acessíveis pelo Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Complementarmente foi analisado o site de busca da *Information Society for Knowledge Organization (ISKO)* que indexa tanto o *Knowledge Organization Journal* como os *Proceedings* dos eventos ISKO. O recorte de busca se restringiu aos últimos 5 anos (2013-2017) uma vez que a temática é emergente, e os levantamentos foram feitos entre março e abril de 2017.

As expressões de busca, inicialmente elencadas, foram: *Deep learning*; *Deep learning and Information Science*; *Deep learning AND knowledge organization*; *Deep learning AND image*; *Deep learning AND image AND Information science*; *Deep learning AND Knowledge organization*, demonstradas no Quadro 1. As buscas foram efetuadas em todos os campos de título, palavras-chave e resumo, quando estes foram disponibilizados nas bases pesquisadas.

Quadro 1: Protocolo de levantamento bibliográfico.

Expressões de busca	<i>Deep learning¹ ; Deep learning AND Information Science; Deep learning AND knowledge organization; Deep learning AND image; Deep learning AND image AND Information science; Deep learning AND image AND knowledge organization.</i>
Bases de dados consultadas	<i>Information Science and Technology Abstracts (ISTA); Library Literature Information Science - Full texts (LLIS); Library Information Science Abstracts (LISA); Base de dados de Periódicos em Ciência da Informação (BRAPCI); Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); Journal e Proceedings ISKO.</i>

Fonte: Elaborado pelos autores.

As principais bases indexadas pelo Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, que contemplam publicações da área de CI, e que foram consultadas simultaneamente foram: Programa de Publicações Digitais da Propg (UNESP); Repositório Científico de Acesso Aberto de Portugal (RCAAP); Scielo.org; Repositório Institucional do Museu Paraense Emílio Goeldi; DOAB: *Directory of Open Access Books*; Instituto Brasileiro de Informação em Ciência e Tecnologia (IBICT); Repositório Institucional Di; Fundação Oswaldo Cruz (FIOCRUZ) e Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior.

No Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, a estratégia de busca *Deep Learning* recuperou 7.408 artigos. Os assuntos relacionados ao tema e que foram sugestionados pelo sistema foram: *Computer Science* (1.880); *Learning* (896); *Deep learning* (612); *Algorithms* (473); *Neural Networks* (444); *Machine Learning* (403); *Statistics* (335); *Engineering* (326); *Classification* (320); *Artificial Neural Networks* (311); *Artificial Intelligence* (281); *Training* (194); *Feature extraction* (172); *Computing and processing* (158); *Images* (152); *An* (145); *Signal processing and analysis* (131); *Convolutional Neural Network* (101), e; *Convolutional Neural Networks* (100).

Constata-se que não há indicação automática direta de relação com os termos que selecionamos para a estratégia de busca de nossa pesquisa: *Information Science* e *Knowledge Organization*. Ao analisar a relação mais próxima entre os assuntos que sugerimos em nossa estratégia, identificamos que, dentre as 320 referências relacionadas a *Classification*, 29 foram dedicadas ao assunto *Image Processing* e 23 a *Image Classification*. Analisando pontualmente

¹ Uma observação torna-se necessária: estudos sobre comportamento de busca (*Information Literacy*), têm sido indexados com o termo *Deep Learning* no campo da Ciência da Informação. Tais trabalhos não foram considerados nos resultados da revisão proposta por este estudo uma vez que os mesmos não abordam o conceito de *Deep Learning* no âmbito considerado na presente investigação, na medida em que diz respeito ao aprendizado artificial e automático das máquinas. Para tal constatação cabe frisar que foram feitas as leituras de títulos, resumos e palavras-chave dos trabalhos recuperados.

cada uma destas referências, somente um artigo foi publicado em periódicos da CI (refª. CS.1 da tabela 1).

Tabela 1. Trabalhos recuperados

Estratégia de busca	Quantidade de itens		Itens relevantes			
	recuperados	relevantes	Refª.	Autoria (ano)	Título	Publicação
Portal de Periódicos da CAPES						
<i>Deep Learning</i>	7428	1	CS.1	Zhang, C.; Zhu, G.; Huang, Q.; Tian, Q. (2017)	Image classification by search with explicitly and implicitly semantic representations.	<i>Information Sciences Journal</i>
<i>Deep Learning and Information Science</i>	249	2	CS.2	Shao, L.; Cai, Z.; Liu, L.; Lu, K. (2017)	Performance evaluation of deep feature learning for RGB-D image/video classification.	<i>Information Sciences Journal</i>
			CS.3	Yang, X; Liu, W; Tao, D.; Cheng, J. (2017)	Canonical correlation analysis networks for two-view image recognition.	<i>Information Sciences Journal</i>
<i>Deep Learning and Knowledge Organization</i>	16	1	CS.4	Jensen, S.; Liu, X.; Yu, Y.; Milojevic, S. (2016)	Generation of topic evolution trees from heterogeneous bibliographic networks	<i>Journal of Informetrics</i>
LLIS [base de dados indisponível no momento da recolha]						
LISA						
<i>Deep Learning</i>	20	0	-			
ISTA						
<i>Deep Learning</i>	15	3	IA.1	Ebesu, T.; Fang, Y. (2017)	Neural Semantic Personalized Ranking for item coldstart recommendation.	<i>Information Retrieval Journal</i>
			IA.2	Matsuo, Y. (2015)	The future of artificial intelligence and the emerging potentials of data sharing.	<i>Journal of Information Processing & Management</i>
			IA.3	Matsubara, H (2016)	Game informatics: Beyond computer shogi.	<i>Journal of Information Processing & Management</i>
BRAPCI						
<i>Deep Learning</i>	0	-				
Journal e Proceedings ISKO						
<i>Deep Learning</i>	0	-				

Fonte: Elaborado pelos autores

Ao avançarmos nas buscas no Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior constatamos que a partir da estratégia *Deep Learning and Information Science* foram identificados 249 (sendo que os termos foram buscados isoladamente pelo sistema). Destes 249, foi sugerido pelo sistema o assunto relacionado *Information Science* que recuperou 20 artigos, sendo que destes, oito foram

publicados em periódicos do campo, no entanto, em apenas dois o conceito *Deep Learning* é abordado pela perspectiva computacional que adotamos neste artigo. (ref^{as}. CS.2 e CS.3 da tabela 1).

Ainda no Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, a partir da estratégia *Deep Learning and Knowledge Organization* foram recuperados 16 artigos, sendo que somente um em revista da área de CI, (ref^a. CS.4 da Tabela 1). Já com a expressão *Deep Learning and Knowledge Organization and image*, obtivemos zero de retorno.

No contexto específico da CI foram pesquisadas as bases internacionais ISTA e LISA disponíveis via Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior. A Base LLIS não estava com conteúdo disponível no momento desta pesquisa. Diante da especificidade destas bases, foram buscadas referências sem cruzar os termos de busca com o descritor *Information Science*, uma vez que os conteúdos das bases selecionadas já estão inseridos especificamente no campo.

Na base de dados LISA, a busca por *Deep Learning* resultou em 20 ocorrências, sendo que nenhum corresponde totalmente aos critérios estabelecidos para a revisão. Na base de dados ISTA, foram recuperados 15 artigos, com a estratégia *Deep Learning*, sendo que destes, três atendem os requisitos da revisão do artigo (referências: IA.1, IA.2 e IA.3 da Tabela 1,). Refira-se que os artigos com as referências: IA.2 e IA.3 se encontram em língua japonesa.

Na base de dados BRAPCI, a partir do uso da estratégia de busca *Deep Learning* não foi recuperado nenhum documento. Diante desta constatação, não foi dada continuidade em buscas com as demais estratégias pois as mesmas contemplavam o descritor *Deep Learning*.

Na base de busca do *Journal e Proceedings ISKO*, a partir do uso da estratégia de busca *Deep Learning* no campo título (único campo disponível para busca aberta), não houve retorno de trabalhos relacionados ao assunto. Diante desta constatação também não foi dada continuidade em buscas com as demais estratégias pelos motivos já apresentados.

Tendo em conta que dos sete artigos recuperados, dois encontram-se escritos em japonês (referências IA.2 e IA.3), a análise do texto integral foi efetuada apenas aos restantes cinco artigos. Todavia, pela análise aos resumos dos dois artigos referidos foi possível verificar que apenas um aborda a arquitetura DL aplicada à classificação e reconhecimento automático de imagens. Nos artigos restantes (referências CS.1, CS.2, CS.3, CS.4 e IA.1) apenas em três, os artigos referenciados com CS.1, CS.2, CS.3, é abordado as técnicas DL aplicadas à classificação de imagens.

No intuito de atender a 4^a etapa (análise crítica), a 5^a etapa (discussão das análises) e 6^a (apresentação da revisão) da revisão integrativa, daremos seguimento a análise, discussão e

apresentação dos conteúdos dos trabalhos identificados, contextualizando-os em caráter conclusivo, no campo da CI.

O artigo *Image classification by search with explicitly and implicitly semantic representation* (CS.1), tem como assuntos a representação explícita e implícita (de imagens) a classificação de imagens e a modelação semântica. Seu objetivo principal foi propor um novo método para classificação de imagens (*Explicitly and Implicitly Semantic Representations - EISR*), explorando a combinação de informação recolhida de um conjunto de imagens previamente treinado (representação explícita) e de descrições textuais, associadas a imagens similares, retiradas da *Web* (representação implícita). Demonstrar a utilidade do método EISR testando-o e comparando-o com outros métodos de classificação de imagens. Para tanto, metodologicamente, desenvolveu estudo experimental comparativo para avaliação da eficiência do método EISR relativamente a três dezenas de outros métodos/algoritmos, nas bases de imagens: *Scene-15*; *MIT-Indoor*; *UIUC-Sports*; e *PASCAL VOC 2007*. Como principais resultados foi possível concluir que o método EISR apresentou um aumento da precisão na anotação e classificação de imagens diminuindo, em parte, a discrepância semântica entre a informação visual e o entendimento humano, assim como aumentando o poder discriminativo das representações finais de cada imagem devido à recolha de informação de diferentes fontes.

O trabalho *Performance evaluation of deep feature learning for RGB-D image/video classification* (CS.2), versa sobre os assuntos de Redes Neurais Profundas, Dados/informação RGB-D, aprendizagem de características visuais e avaliação de desempenho. Teve como objetivos investigar como as técnicas de *Deep Learning* podem ser utilizadas para extrair e combinar características de dados RGB-D (combinação de informação de luminosidade e de profundidade de campo), uma vez que nenhuma abordagem consegue lidar com todos os cenários de forma eficiente. Também foi objetivo do trabalho analisar o desempenho de modelos *Deep Learning* na classificação de imagem/vídeo em bases de dados RGB-D e ainda apresentar sugestões de melhoria dos referidos modelos em termos de ajustes dos seus parâmetros. O método utilizado foi o estudo experimental extensivo para comparação de 4 modelos de aprendizagem profunda (*Deep Belief Networks (DBNs)*; *Stacked Denoising Auto-Encoders (SDAE)*; *Convolutional Neural Networks (CNNs)*; *Long Short-Term Memory Neural Networks (LSTM)*) em três bases de imagens e dois de vídeo (*2D&3D object*; *RGB-D object*; *NYU Depth v1 indoor scene segmentation*; *Sheffield Kinect Gesture*; *MSRDailyActivity3D*). Os principais resultados indicam que os métodos de combinação RGB-D que usam CNNs com numerosos conjuntos de treino superaram sempre os outros métodos analisados (DBNs, SDAE e LSTM). O modelo LSTM apresenta vantagens relativamente aos SDAE e DBNs em tarefas de

classificação de vídeo RGB-D devido à sua capacidade em aprender por experiência. Quanto maior é a complexidade das bases de dados mais numerosos deverão ser os exemplos para treino de forma a não diminuir a precisão da classificação. Os resultados de concatenação e combinação RGB-D (SVM) são melhores que os de outros métodos.

A pesquisa *Canonical correlation analysis networks for two-view image recognition* (CS.3) tem como assuntos centrais a análise de correlação canônica, a aprendizagem profunda e as Redes Neurais Convulsionais. Seu principal objetivo foi propor um novo método para classificação de imagens (*Canonical Correlation Analysis Network - CCANet*), onde as imagens são representadas numa visão dupla de características por forma a aumentar a precisão do processo. A partir disto objetivou também demonstrar a vantagem da dupla representação do método CCANet na classificação de imagens. Como recurso metodológico, desenvolveu um estudo experimental extensivo para verificar e comparar a eficácia do método CCANet, relativamente aos métodos PCANet e RandNet, na classificação de objetos, de rostos e de caracteres manuscritos, usando, respetivamente, as bases de dados *ETH-80*, *Yale-B* e *USPS*. Os resultados indicaram que o método CCANet alcançou maior precisão de reconhecimento de objetos, rostos e caracteres manuscritos que outros métodos representativos do uso de técnicas *Deep Learning*, como PCANet e RandNet.

Já a publicação *Generation of topic evolution trees from heterogeneous bibliographic networks* (CS.4) tratou de assuntos relacionados a evolução de temas científicos (ao longo do tempo), a Rede Bibliográfica Heterogênea e o caminho entre dois nós (de uma rede) ligados indiretamente e a visualização (de caminhos evolutivos de temas). Seus objetivos foram examinar a questão da extração de informação de grafos heterogêneos de diferentes domínios científicos para o mapeamento da evolução de temas científicos em forma de diagrama de árvore (*Topic Evolution Tree - TET*) e ainda propor um modelo TET que, baseando-se no mesmo conjunto de pesquisas, apresente em uma visualização gráfica, diferentes caminhos evolutivos dos temas de acordo com a especificidade de diferentes pesquisadores. Ao final objetivou demonstrar a utilidade do método TET proposto, aplicando-o em duas bases de diferentes áreas científicas (biomedicina e ciência da computação). Desenvolveu para tanto, um estudo empírico sobre um método de extração de informação em Redes Bibliográficas Heterogêneas (RBHs) para geração de TETs aplicado a dois repositórios de artigos científicos: *National Center for Biotechnology Information's PubMed Central Repository* (PMC) e *Association for Computing Machinery digital library* (ACM). Os principais resultados indicaram que o mapeamento entre nós não ligados diretamente (*meta-paths*) em RBHs, pode ser usado para identificar os elementos da rede que mais contribuíram para um tema em especial. Os diagramas TET gerados pelo modelo proposto, nas bases PMC

e ACM, apresentam um bom resumo dos tópicos que contribuíram para a evolução do tema inicial. A introdução de *meta-paths* restritos a uma RHB, usada no método TET proposto, permite restringir a visualização da evolução de um determinado tema ao contexto específico do interesse do pesquisador, aumentando a relevância da informação obtida comparativamente com a mesma sem tais restrições.

O estudo *Neural Semantic Personalized Ranking for item coldstart recommendation* (IA.1) tratou de assuntos relacionados a sistemas de recomendação, rede neuronal profunda, respostas/reações implícitas de utilizadores e algoritmo de aprendizagem *Pairwise*. Seu principal objetivo foi propor um novo modelo probabilístico (*Neural Semantic Personalized Ranking* - NSPR) para caracterizar as preferências dos utilizadores por determinados itens com base nas respostas/reações implícitas destes, unindo as potencialidades das redes neuronais profundas com algoritmos de aprendizagem *Parwise*. Foi ainda objetivo do trabalho, demonstrar a utilidade do modelo NSPR testando-o e comparando-o com outros sistemas de recomendação. Configurou-se como estudo experimental extensivo para verificar e comparar a eficácia do modelo NSPR relativamente aos quatro sistemas de recomendação mais recentes: *SVDFeature*; *Collective matrix factorization*; *Collaborative topic regression*; e *Collaborative deep learning*, usando para o efeito duas bases de dados públicas cuja finalidade é salvar e partilhar preferências pessoais: *CiteULike* (citações de artigos científicos) e *Yahoo! Movies* (sinopses de filmes). Como resultado foi constatado que o NSPR funde as capacidades de um modelo probabilístico de fatores latentes com as de uma rede neural de aprendizagem profunda, combinando características representativas extraídas do conteúdo do item e das respostas/reações implícitas dos utilizadores, produzindo inferências robustas que permitem que o modelo generalize de forma eficaz. O modelo NSPR demonstrou versatilidade ao integrar várias funções probabilísticas *Pairwise* assim como duas variantes baseadas em funções Logística e *Probit* e ainda o modelo NSPR demonstrou um desempenho significativamente melhor que os quatro sistemas de recomendação considerados como o estado-da-arte.

Verifica-se, atendendo às descrições acima apresentadas, que o tema dos artigos com as referências CS.4 e IA.1 afastam-se do âmbito do presente trabalho na medida em que não abordam o tratamento de imagens. E, no caso do trabalho CS.4, o afastamento é ainda maior uma vez que o texto discorre sobre o uso do Latent Dirichlet Allocation (LDA), para identificar tópicos emergentes em textos científicos mostrando o quanto os meta-caminhos de uma rede bibliográfica heterogênea podem ser usados para identificar os elementos de rede que contribuíram para um tópico.

5 Considerações finais

A CI possui larga trajetória no desenvolvimento de metodologias voltadas a representação e descrição de imagens. Estas metodologias têm se sofisticado na medida em que os processos de tratamento documental e sua representação passam a ser desenvolvidos em ambientes virtuais. O avanço propiciado pela interoperabilidade entre os sistemas de informação em rede também tem demandado novos esforços de integração metodológica para descrição da informação. Somado a isto, inclui-se nos últimos dez anos, a participação efetiva de usuários da informação, como autores e descritores de conteúdos na Web. Toda esta complexidade tem sido refletida nos métodos de representação e descrição de imagens desenvolvidos e aplicados nas práticas da CI. Neste cenário o propósito deste estudo, foi o de verificar, a partir de revisão integrativa da literatura nacional e internacional, se as técnicas de representação e descrição artificiais e automatizadas, propiciadas a partir do uso da estrutura das lógicas convolucionais, têm sido consideradas neste processo complexo de representação, recuperação, acesso e uso da informação pela CI. Para isto, apresentamos e analisamos pesquisas básicas que conceituam o *Deep Learning*, sendo estes estudos os produzidos por Arel; Rose; Karnowski (2010); Ávila (2013); Bezerra (2016); Calsaverini (2016); Carvalho (2015); Ceci (2015); Corridoni; Del Bimbo; Pala (1999); Dehaven (2017); Deng; Yu, (2014); Fergus (2016); Jost (2016); Krizhevsky, Sutskever e Hinton (2012); Lopes (2016); Mitchell (2006); Shao *et al.*, (2017); Valenzuela (2017); Vitorino (2016); Wei; Li; Wilson (2006) e Yang *et al.*(2017) e que deram ênfase na interface DL com as ações de descrição e recuperação de imagens na Web.

Ainda, foram identificados e recuperados os principais estudos voltados à representação descritiva e temática de imagens na Web recorrendo a técnicas associadas ao *Deep Learning*, no âmbito da CI, num cenário nacional e internacional, sendo estes: “*Image classification by search with explicitly and implicitly semantic representations*”; “*Performance evaluation of deep feature learning for RGB-D image/video classification*”; “*Canonical correlation analysis networks for two-view image recognition*”.

Quanto à estrutura das publicações sobre o tema, foi possível identificar os jornais que mais se dedicaram ao assunto, que são o *Information Sciences Journal* seguido do *Journal of Information Processing & Management*, *Journal of infometrics* e *Information Retrieval Journal*. Destaca-se que as publicações também são recentes e concentram-se mais entre os anos de 2015 e 2017. Não foram identificadas até o momento do levantamento bibliográfico, pesquisas

brasileiras ou portuguesas sobre a relação entre os assuntos DL e CI. Quanto aos resultados das pesquisas analisadas, foi possível identificar, no âmbito metodológico, que os recursos utilizados foram o estudo exploratório comparativo, o estudo experimental comparativo e o estudo empírico.

Foi possível categorizar e analisar os conteúdos dos artigos identificados, sistematizando potenciais categorias temáticas já investigadas, sendo elas: a) o aumento da precisão na anotação e classificação de imagens; b) o auxílio no controle da discrepância semântica entre a informação visual e o entendimento humano; c) a extração e combinação automática de diversa informação imagética; d) a capacidade de prover ao sistema uma aprendizagem semântica a partir de suas experiências. Além disso, num âmbito mais afastado do da descrição e recuperação de imagens, foi possível constatar a possibilidade de melhorar significativamente as capacidades predicativas de sistemas de recomendação.

Visando finalizar as discussões relacionando os potenciais desdobramentos sobre o tema na CI, podemos concluir que ainda é restrita a produção científica sobre o assunto no campo. Embora as iniciativas identificadas sejam relevantes, entendemos que ainda se faz necessário maior investimento em pesquisas sobre o assunto, uma vez que o impacto nas ações de recuperação de imagens na Web, via ML e DL, podem refletir diretamente sobre as práticas de representação e organização da informação imagética tal como temos desenvolvido. Um investimento que deverá ser acompanhado de uma reflexão que vá além dos aspectos técnicos uma vez que, tal como refere Hjørland, este tipo de técnicas computacionais podem ser vistas como tentativas de modelar artificialmente a formação de conceitos de acordo com uma visão empirista do mundo (2009, p. 1523) que, não sendo equilibrada com outras abordagens, poderá implicar uma perspectiva reducionista.

Evidentemente não se visualiza qualquer substituição da aplicação das metodologias de descrição e representação de imagens já desenvolvidas e aplicadas pela CI, pela descrição automática de imagens. Reconhecemos, no entanto, que ao avançarmos no aprimoramento das técnicas e metodologias de tratamento de imagens pela CI, para o ambiente Web, tenhamos que atentar para este recurso de descrição automática, considerando-o, em suas diferentes perspectivas, como parte integrante dos processos que estão sendo validados. Neste sentido, como continuidade deste trabalho, tem-se como propósito avançar na análise das estruturas metodológicas de representação imagéticas desenvolvidas pela CI, identificando as possibilidades de incorporação dos elementos de descrição automática de imagens, para ampliar e qualificar o resultado do processo de sua recuperação.

6 Referências

- ANGUS, E.; THELWALL, M.; STUART, D. General patterns of tag usage among university groups in Flickr. **Online Information Review**, v. 32, n. 1, 2008.
- AREL, I.; ROSE, D. C.; KARNOWSKI, T. P. Deep Machine Learning - A New Frontier in Artificial Intelligence Research. **IEEE Computational Intelligence Magazine**, v. 5, n. 4, p. 13–18, 2010.
- ÁVILA, S. E. F. DE. **Extended bag-of-words formalism for image Classification**. Belo Horizonte: Universitté Pierre et Marie Curie/Universidade Federal de Minas Gerais, 2013. Tese de doutorado. Disponível em: <http://www.bibliotecadigital.ufmg.br/dspace/handle/1843/ESSA-9ACJ4K>
- BEYEA, S.; NICOLL, L. H. Writing an integrative review. **AORN journal**, v. 67, n. 4, p. 877–80, April 1998.
- BEZERRA, E. Introdução à Aprendizagem Profunda. In: OGASAWARA, E.; VIEIRA, V. (Eds.). **Tópicos em Gerenciamento de Dados e Informações**. Porto Alegre: Sociedade Brasileira de Computação, 2016. p. 57–86.
- BROOME, M. E. Integrative literature reviews for the development of concepts. In: RODGERS, B. L.; KNAFL, K. A. (Eds.). **Concept development in nursing: foundations, techniques and applications**. Philadelphia, PA: W.B. Saunders, 2000. p. 231–250.
- CALSAVERINI, R. S. Aprendizado profundo: Princípios e uso. **Tecnologia de Crédito**, v. 13, n. 94, p. 6–15, março 2016. Disponível em: https://ecitydoc.com/download/aprendizado-profundo-principios-e-uso_pdf
- CARVALHO, M. C. **Transfer schemes for deep learning in image classification**. Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, 2015. Disponível em: www.ic.unicamp.br/~sandra/pdf/msc-2015-micael-carvalho.pdf
- CECI, F. **Um modelo baseado em casos e ontologia para apoio à tarefa intensiva em conhecimento de classificação com foco na análise de sentimentos**. Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-graduação em Engenharia e Gestão do Conhecimento, Florianópolis, 2015. Disponível em: <https://repositorio.ufsc.br/handle/123456789/158856>
- CHOI, Y.; RASMUSSEN, E. M. Searching for images: he analysis of users’ queries for image retrieval in American history. **Journal of the American Society for Information Science and Technology**, v. 54, p. 498-511, February 2003.
- COOPER, H. M. **The integrative research review: a systematic approach**. Beverly Hills, CA: Sage Publications, 1984.
- CORDEIRO, R. I. N. O delineamento de uma pesquisa em imagens e audiovisuais na Ciência da Informação: o “tagueamento” como quarta dimensão. **Informação & Informação**, Londrina, v. 23, n. 1, p. 6-30, mar. 2018. Disponível em: <http://www.uel.br/revistas/uel/index.php/informacao/article/view/32581> Acesso em: 30 mar. 2018.

CORRIDONI, J. M.; DEL BIMBO, A.; PALA, P. Image retrieval by color semantics. **Multimedia Systems**, v. 7, n. 3, p. 175–183, May 1999. Disponível em: <https://dl.acm.org/citation.cfm?id=314286.314287>

DEHAVEN, V. R. **Machine learning**: Future capabilities and their implications. Tucson: University of Arizona, 2017. Disponível em: <https://arizona.openrepository.com/handle/10150/320027>

DENG, L.; YU, D. Deep Learning: Methods and applications. **Foundations and Trends in Signal Processing**, v. 7, n. 3–4, p. 197–387, 2014.

EBESU, T.; FANG, Y. Neural Semantic Personalized Ranking for item cold-start recommendation. **Information Retrieval Journal**, v. 20, p. 109-131, April 2017.

FERGUS, R. **Deep Learning Summer School**: Convolutional Neural Networks and Computer Vision. New York: VideoLectures.NET, 2016. Disponível em: http://videolectures.net/deeplearning2016_fergus_neural_networks/ Acesso em: 8 abr. 2017

GALDO, A. M. R.; VIERA, A. F. G.; RODRIGUES, R. N. S. Classificação social da informação na web: tecnologia, informação e gente. **DataGramZero**, Rio de Janeiro, v. 10, n. 6, p. A03, 2009. Disponível em: <http://www.brapci.inf.br/v/a/8337>

GANONG, L. H. Integrative reviews of nursing research. **Research in Nursing & Health**, v. 10, n. 1, p. 1–11, February 1987. Disponível em: <https://www.ncbi.nlm.nih.gov/pubmed/3644366>

GRACIOSO, L. S. Parâmetros teóricos para elaboração de instrumentos pragmáticos de representação e organização da informação na web: considerações preliminares sobre uma possível proposta metodológica. **InCID: Revista de Ciência da Informação e Documentação**, v. 1, n. 1, p. 138-158, 2010. Disponível em: <http://www.brapci.inf.br/v/a/9503>.

GRACIOSO, L. S.. Organização social de fotografias na Web: fundamentos, métodos e orientações. In: SOUZA; FUJITA; GRACIOSO. (Org.). **A Imagem em Ciência da informação**: reflexões teóricas, experiências práticas. Marília, SP: Cultura Acadêmica, 2014, v. 1, p. 207-207.

GUEDES, R. M.; MOURA, M. A.; DIAS, E. J. W. Indexação social e pensamento dialógico: reflexões teóricas; indización social y pensamiento dialógico: reflexiones teóricas. **Informação & Informação**, Londrina, v. 16, n. 3, p. 40-59, 2011.10.5433/1981-8920.2011v16n3p40. DOI:10.5433/1981-8920.2011v16n3p40 Disponível em: <http://www.brapci.inf.br/v/a/12613>

HJØRLAND, B. Concept theory. **Journal of the American Society for Information Science and Technology**, v. 60, n. 8, p. 1519–1536, August 2009.

HOSCH, W. L. Machine learning: artificial intelligence. In: *Encyclopaedia Britannica*. Disponível em: <https://www.britannica.com/technology/machine-learning> Acesso em: 2 abr. 2017.

JENSEN, S. *et al.* Generation of topic evolution trees from heterogeneous bibliographic networks. **Journal of Informetrics**, v. 10, n. 2, p. 606–621, 2016.

JOST, I. **Aplicação de Deep Learning em dados refinados para mineração de opiniões**. São Leopoldo: Universidade do Vale do Rio dos Sinos, 2016. Disponível em: <http://www.repositorio.jesuita.org.br/handle/UNISINOS/3841?locale-attribute=en>

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with Deep Convolutional Neural Networks. **Advances in Neural Information Processing Systems**. Stateline: NIPS, p.

1097–1105, 2012. Disponível em: <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>

LOPES, A. T. **Facial expression recognition using deep learning**: Convolutional neural network. Vitória: Universidade Federal do Espírito Santo, 2016. Disponível em: <http://repositorio.ufes.br/handle/10/4301>

LUCAS, E. DE O.; PINTO, A. L.; LARA, M. L. G. DE. Periódicos de Ciência da Informação nas bases de dados internacionais. **DataGramZero**, Rio de Janeiro, v. 14, n. 1, 2013.

MATUSIAK, K. K. Towards user-centered indexing in digital image collections. **OCLC Systems & Services**, v. 22, n. 4, 2006.

MEJIAS, U. A. Tag literacy. 2005. Disponível em: <http://blog.ulisesmejias.com/2005/04/26/tag-literacy/>

MENDES, K. D. S.; SILVEIRA, R. C. DE C. P.; GALVÃO, C. M. Revisão integrativa: método de pesquisa para a incorporação de evidências na saúde e na enfermagem. **Texto & Contexto Enfermagem**, v. 17, n. 4, p. 758–764, 2008. Disponível em: www.scielo.br/pdf/tce/v17n4/18.pdf

MITCHELL, T. M. The discipline of Machine Learning. Pittsburgh: [s.n.]. Disponível em: <http://www-cgi.cs.cmu.edu/~tom/pubs/MachineLearningTR.pdf>

PLANGPRASOPCHOK, A; LERMAN, K. Constructing folksonomies from user-specified relations on Flickr In: INTERNATIONAL WORLD WIDE WEB CONFERENCE, 18., New York, 2009. **Proceedings** New York: ACM Press. 2009.

REBELO, L. D. T. **Avaliação automática do resultado estético do tratamento conservador do cancro da mama**. Porto: Universidade do Porto, 2008. Disponível em: <https://repositorio-aberto.up.pt/bitstream/10216/60215/2/Texto%20integral.pdf>

SHAO, L. *et al.* Performance evaluation of deep feature learning for RGB-D image/video classification. **Information Sciences**, v. 385–386, p. 266–283, 2017.

SIGURBJÖRNSSON, B.; VAN ZWOL, R. Flickr tag recommendation based on collective knowledge. In: INTERNATIONAL CONFERENCE ON WORLD WIDE WEB, 17., 2016. **Proceedings**. New York: ACM Press, 2017.

SOUSA, L. M. A. E.; FUJITA, M. S. L.; GRACIOSO, L. S. (Org.). **A Imagem em Ciência da informação**: reflexões teóricas, experiências práticas. Marília, SP: Cultura acadêmica, 2014. v. 1. 232p.

STREHL, L. C. As folksonomias entre os conceitos e os pontos de acesso: as funções de descritores, citações e marcadores nos sistemas de recuperação da informação. **Perspectivas em Ciência da Informação**, Belo Horizonte, v. 16, n. 2, p. 101-114, 2011. Disponível em: <http://www.brapci.inf.br/v/a/10263>

TARTAROTTI, R. C. D. E.; DAL'EVEDOVE, P. R.; FUJITA, M. N. S. L. Política de indexação em ambiente colaborativo das folksonomias: uma reflexão preliminar. **Encontro Nacional de Pesquisa em Ciência da Informação**, v. 17, 2016. Disponível em: <http://www.brapci.inf.br/index.php/article/view/0000021876/4aa140c1127a1cab0701add352546d8>

TRANT, J. Exploring the potential for social tagging and folksonomy in art museums: proof of concept. **New Review of Hypermedia and Multimedia**, v. 12, n. 1, 2006.

VALENZUELA, M. L. **Machine learning, optimization, and anti-training with sacrificial data**. Tucson: University of Arizona, 2017. Disponível em: <https://arizona.openrepository.com/handle/10150/605111>

VIGNOLI, R. G.; ALMEIDA, P. O. P.; CATARINO, M. E. Folksonomias como ferramenta da organização e representação da informação. **Revista Digital de Biblioteconomia & Ciência da Informação**, Campinas, v. 12, n. 2, p. 120-135, 2014. Disponível em: <http://www.brapci.inf.br/v/a/14547> Acesso em: 2 abril 2018.

VITORINO, P. R. R. **Detecção de pornografia infantil em imagens através de técnicas de aprendizado profundo**. Brasília: Universidade de Brasília, 2016. Disponível em: <http://repositorio.unb.br/handle/10482/22757?locale=fr>

WALDRON, M. **10 Machine learning terms explained in simple English**. Disponível em: <http://www.datasciencecentral.com/profiles/blogs/10-machine-learning-terms-explained-in-simple-english> Acesso em: 2 abr. 2017.

WEI, C.-H.; LI, C.-T.; WILSON, R. A Content-Based Approach to Medical Image Database Retrieval. In: **Database modeling for industrial data management: Emerging technologies and applications**. [s.l.] IGI Global, 2006. p. 258–292.

WHITTEMORE, R.; KNAFL, K. The integrative review: updated methodology. **Journal of Advanced Nursing**, v. 52, n. 5, p. 546–53, December 2005.

YANG, X. et al. Canonical correlation analysis networks for two-view image recognition. **Information Sciences**, v. 385–386, p. 338–352, 2017.

ZHANG, C. *et al.* Image classification by search with explicitly and implicitly semantic representations. **Information Sciences**, v. 376, p. 125–135

Recebido/Recibido/Received: 2017-09-14

Aceitado/Aceptado/Accepted: 2018-04-19