



ANÁLISE DO DEEP LEARNING EM CUIDADOS DE SAÚDE
DEEP LEARNING ANALYSIS IN HEALTH CARE
ANÁLISIS DEL DEEP LEARNING EN ATENCIÓN MÉDICA

Flávio Vaz Machado¹, Lízety Guimarães Emmerick², Roberto Carlos Lyra da Silva³, Luiza Cerqueira Reis da Costa⁴,
Fernanda Rodrigues da Silva⁵, Alexandre Fernando Coutinho da Silva⁶, Elizangela Aparecida da Silva de Laffitte Alves⁷,
Ilda Cecília Moreira da Silva⁸

RESUMO

Objetivo: analisar a aplicabilidade e os benefícios do *Deep Learning* na área de cuidados de saúde. **Método:** trata-se de um estudo descritivo, tipo análise reflexiva, com consulta a artigos entre os anos de 2014 a 2019, publicados em inglês e revisado por pares, no Portal de Periódicos da CAPES, com a equação de busca ("*Deep Learning*" AND ("*Health Care*" OR *Health-care* OR *Healthcare*)). Apresentaram-se os resultados em forma de figura seguida da análise descritiva. **Resultados:** revela-se que 15 artigos descrevem a aplicabilidade do *Deep Learning* na área de cuidados de saúde. Analisou-se, por este artigo, o emprego do *Deep Learning* em diferentes áreas referentes aos cuidados de saúde, destacando os benefícios encontrados pelos autores dos selecionados por meio da revisão de literatura. **Conclusão:** sugere-se o emprego do *Deep Learning* na área de cuidados de saúde diante dos benefícios identificados nos artigos selecionados como: a previsão dos estágios das doenças; a identificação precisa de mutações patológicas e o suporte aos médicos e aos enfermeiros em suas atividades diárias. **Descritores:** Benefícios; *Deep Learning*; Cuidados de Saúde; Doenças; Médicos; Enfermeiros.

ABSTRACT

Objective: to analyze the applicability and benefits of *Deep Learning* in health care. **Method:** this is a descriptive study, reflective analysis, with articles from 2014 to 2019, published in English and peer-reviewed, in the CAPES Journal Portal, with the search equation ("*Deep Learning*" AND ("*Health Care*" OR *Health-care* OR *Healthcare*)). The results were presented in figure form followed by descriptive analysis. **Results:** it is revealed that 15 articles describe the applicability of *Deep Learning* in the health care area. This article analyzed the use of *Deep Learning* in different areas related to health care, highlighting the benefits found by the authors of those selected through the literature review. **Conclusion:** it is suggested the use of *Deep Learning* in health care in view of the benefits identified in the articles selected as: the prediction of disease stages; precise identification of pathological mutations and support to doctors and nurses in their daily activities. **Descriptors:** Benefits; *Deep Learning*; Health Care; Diseases; Physicians; Nurses.

RESUMEN

Objetivo: analizar la aplicabilidad y los beneficios del *Deep Learning* en la atención médica. **Método:** se trata de un estudio descriptivo, tipo análisis reflexivo, con artículos de 2014 a 2019, publicados en inglés y revisados por pares, en el Portal de la revista CAPES, con la ecuación de búsqueda ("*Deep Learning*" Y ("*Health Care*" O *Health-care* O *Healthcare*)). Los resultados se presentaron en forma de figura seguida de un análisis descriptivo. **Resultados:** se revela que 15 artículos describen la aplicabilidad del *Deep Learning* en el área de la atención médica. Este artículo analizó el uso del *Deep Learning* en diferentes áreas relacionadas con la atención de la salud, destacando los beneficios encontrados por los autores de los seleccionados a través de la revisión de la literatura. **Conclusión:** se sugiere el uso de *Deep Learning* en la atención de la salud en vista de los beneficios identificados en los artículos seleccionados como: la predicción de las etapas de la enfermedad; identificación precisa de mutaciones patológicas y apoyo a médicos y enfermeros en sus actividades diarias. **Descriptores:** Beneficios; *Deep Learning*; Cuidados de la Salud; Enfermedades; Médicos; Enfermeros.

^{1,2,3,4} Universidade Federal do Estado do Rio de Janeiro/UNIRIO. Rio de Janeiro (RJ), Brasil.  ORCID: <https://orcid.org/0000-0001-8950-7139>  ORCID: <https://orcid.org/0000-0001-7657-982X>  ORCID: <https://orcid.org/0000-0001-9416-9525>  ORCID: <https://orcid.org/0000-0001-6184-6892> ^{5,7,8} Centro Universitário de Volta Redonda/UNIFOA. Volta Redonda (RJ), Brasil.  ORCID: <http://lattes.cnpq.br/8776057131845323>  ORCID: <http://lattes.cnpq.br/0159410766739987>  ORCID: <http://lattes.cnpq.br/6406160619040292> ⁶ Centro Universitário de Barra Mansa/UBM. Barra Mansa (RJ). Brasil.  ORCID: <https://orcid.org/0000-0002-0172-812X>

Como citar este artigo

Machado FV, Emmerick LG, Silva RCL, Costa LC, Silva FR, Silva AFC, et al. Análise do *deep learning* em cuidados de saúde. Rev enferm UFPE on line. 2019;13:e242121 DOI: <https://doi.org/10.5205/1981-8963.2019.242121>

INTRODUÇÃO

Sabe-se que muitos cientistas têm tentado criar, nas últimas décadas, um programa que, aparentemente, pense e processe dados como os seres humanos por meio da observação do comportamento. Começou-se a partir desta ideia, a analisar como os neurônios transmitem informações elétricas entre si por meio da liberação de neurotransmissores no espaço conhecido como fenda sináptica, tentando replicar esse formato de transmissões para os computadores, o que deu origem ao termo *Deep Learning* (DL).¹

Representam-se, pelo DL, em outras palavras, as etapas que o computador realiza para tentar descobrir determinadas coisas. Trata-se de uma tecnologia inspirada no funcionamento do cérebro humano onde as redes neuronais artificiais analisam grandes conjuntos de dados para descobrir automaticamente padrões subjacentes, sem intervenção humana.²

Informa-se que o DL é um subgrupo do *Machine Learning* (ML) que, por sua vez, é uma vertente da Inteligência Artificial (IA). Tem-se aplicado o DL, assim como o Big Data (BD), a Internet das Coisas (IoT) e a própria (ML), na área da saúde com frequência. Pode-se afirmar, por isso, que ele faz parte da saúde eletrônica (*e-Health*) que, segundo a Organização Mundial da Saúde,³ é o uso de tecnologias de comunicação e informação em prol da saúde. Afirma-se, também, pela Organização Mundial de Saúde,⁴ que as soluções de *e-Health* foram criadas para facilitar a vida de seus usuários.

Deriva-se o termo "profundo", por sua vez, das numerosas camadas ocultas na estrutura da Rede Neural Artificial (RNA). Modelam-se, pelo algoritmo de RNA, a funcionalidade de um cérebro biológico e suas respectivas células nervosas.⁵ Compõe-se uma célula nervosa de axônio (saída), dendritos (entrada), um nó (soma), núcleo (função de ativação) e sinapses (pesos).⁶ Atua-se a função de ativação no neurônio artificial como o núcleo de um neurônio biológico, enquanto os sinais de entrada e seus respectivos pesos modelam os dendritos e as sinapses, respectivamente.

Pontua-se que os métodos do DL são ferramentas poderosas que complementam o tradicional ML e permitem que os computadores aprendam com os dados para que possam criar maneiras de produzir aplicativos mais inteligentes. Acrescenta-se que essas abordagens já foram usadas em diversas aplicações, especialmente para a visão computacional e o processamento de linguagem natural. Ilustram-se, por todos os resultados disponíveis na literatura, as capacidades de DL para a análise de dados de cuidados de saúde também.⁷

Explica-se, conforme descrito anteriormente, que o DP é um subgrupo do ML, por isso, para

compreender melhor a ideia do DL, é importante saber que o objetivo do ML. Objetiva-se, pelo ML, permitir que um sistema aprenda com o passado ou presente e use esse conhecimento para fazer previsões ou decisões relativas a eventos futuros desconhecidos e seu foco geral é a representação dos dados de entrada e a generalização dos padrões aprendidos para uso em futuros dados não vistos.⁸

Infere-se que, provavelmente, o *software* do ML em cuidados de saúde mais conhecido é o *Watson Health* (WH) da *International Business Machines* (IBM). Alimenta-se o WH com tudo que já foi escrito em qualquer idioma e a qualquer momento relacionado a diagnósticos de cânceres e seus respectivos tratamentos. Continua-se, ainda, o WH, a ingerir todos os novos dados à medida que são publicados. Recomendar-se-á, pelo WH, quando apresentado a um paciente específico com câncer, o teste de tratamento com maior probabilidade de curar o câncer desse paciente individual, considerando seu genoma, histórico, imagem e patologia, juntamente com todas as informações conhecidas sobre o tratamento desse câncer, pois, quanto mais informações o WH tiver sobre o paciente, mais preciso será. Tem-se, basicamente, a visão da IBM para a IA que ela apoiará a tomada de decisão do médico, em vez de substituí-la, fazendo aquilo que ela faz de melhor: gerenciar, lidar com grandes quantidades de dados e apresentar apenas as informações relevantes ao médico.⁹

Detalha-se, conforme descrito na introdução o ML e o DL, que o tema central deste artigo são vertentes da IA, que é definida pela ciência como o estudo de agentes inteligentes, que são dispositivos que percebem seu ambiente e tomam ações para maximizar sua chance de sucesso em algum objetivo.¹⁰

Relata-se que existem muitos exemplos de IA em nossas vidas, e o *Siri*, da *Apple*, é um desses exemplos; outro é o *Alexa*, da *Amazon*. Usa-se a tecnologia de processamento de linguagem natural, uma forma de inteligência artificial, para traduzir idiomas no Google Tradutor. Investiram-se, 30 bilhões de dólares, aproximadamente, em IA, em 2017, e em pesquisa e desenvolvimento por empresas como *Google* e *Microsoft*.¹¹

Esclarece-se que a IA já existe há algum tempo. Cunhou-se o termo por John McCarthy em uma palestra no *Dartmouth College*, em 1956,¹² no entanto, levou algum tempo para a tecnologia alcançar a promessa da IA e as esperanças dos especialistas em ciência da computação. Previu-se, pela Lei de *Moore*, definida em 1965 pelo cofundador da *Intel*, Gordon E. Moore, que o número de transistores em circuitos integrados dobraria aproximadamente a cada dois anos.

OBJETIVO

- Analisar a aplicabilidade e os benefícios do *Deep Learning* na área de cuidados de saúde.

MÉTODO

Trata-se de um estudo descritivo, tipo análise reflexiva, com pesquisa no Portal de Periódico da CAPES (PPC).¹³

Seguiram-se as seguintes etapas: 1) formulação do problema; 2) determinação dos critérios de inclusão e exclusão dos estudos segundo os critérios da amostragem; 3) avaliação dos dados; 4) análise das informações e 5) análise e interpretação dos resultados e apresentação da revisão.

Esleu-se a questão norteadora “Quais benefícios podem ser obtidos por meio da aplicabilidade do *Deep Learning* em cuidados de saúde?”.

Utilizaram-se, para a busca, os descritores em Ciências da Saúde (DeCS) e o *Medical Subject Headings* (MeSH) com a seguinte equação de busca: (“*Deep Learning*” AND (“*Health Care*” OR *Health-care* OR *Healthcare*)), resultando em 421 artigos revisados por pares e publicados de janeiro de 2014 a janeiro de 2019.

Utilizaram-se os seguintes critérios para a seleção e exclusão: artigos em inglês que descreviam o uso do DL em cuidados de saúde; artigos publicados nos últimos 5 anos; artigos revisados por pares; artigos que apresentassem os descritores da busca apenas no título, utilizando, como operadores *booleanos*, AND e OR; limitação dos resultados por meio do uso de aspas e hífen.

Utilizou-se, como auxílio para a seleção e exclusão dos artigos, ferramentas de filtro do PPC e obteve-se, por sua vez, 30 artigos para leitura na íntegra.

Detalha-se, dos resultados provenientes desta busca, que 15 artigos descrevem a aplicabilidade do DL na área de cuidados de saúde.

RESULTADOS

Descrevem-se na figura 1 os artigos incluídos nesse estudo, bem como as especificações concernentes ao título/autores, campo de aplicação, ano e aos principais benefícios destacados

CÓDIGO ESTUDO	DO	TÍTULO/AUTORES	CAMPO DE APLICAÇÃO	ANO	BENEFÍCIOS DESTACADOS
E1		Introduction to the special issue on deep learning for biomedical and healthcare applications. Tong, Medsker, Cheng, Jafari, Wang ¹⁵	Biomedicina	2016	Exemplos importantes incluem o uso de Deep Learning para a classificação de imagens e descoberta de drogas.
E2		Predicting healthcare trajectories from medical records: A deep learning approach. Pham, Tran, Phung, Venkatesh ¹⁶	Medicina Preditiva	2017	O Deep Learning lê registros médicos, memoriza trajetórias das doenças e dos processos de atendimento, estima os estados atuais das doenças e prevê riscos futuros, além de abrir uma nova abordagem baseada em princípios para a medicina preditiva.
E3		Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. Song, Zhao, Luo, Dou ¹⁷	Imagiologia Médica	2017	O Deep Learning provou ser um método popular e poderoso em muitas áreas de diagnóstico por imagem médica.
E4		A deep inference learning framework for healthcare. Dai, Wang ¹⁸	Assistência Médica	2018	Este trabalho demonstra a eficácia do processo de ciclo fechado e ilustra a perspectiva promissora de Deep Learning em saúde.
E5		Socialized healthcare service recommendation using Deep Learning. Yuan, Li, Guan, Han, Khattak ¹⁹	Serviços de Saúde	2018	O modelo baseado em Deep Learning pode alcançar altos desempenhos mesmo para usuários iniciantes e com um número limitado de conhecimentos.
E6		Deep Learning versus Professional Healthcare Equipment: A Fine-Grained Breathing Rate Monitoring Model. Liu, Dai, Gong, Guo, Liu, Wang, et al. ²⁰	M-Health (saúde móvel)	2018	Os resultados mostram uma boa precisão do monitoramento da taxa de respiração. Propõe-se, assim, o Deep Filter, um algoritmo de monitoramento de taxa de respiração de baixa granularidade baseado em Deep Learning, que funciona no smartphone.
E7		Applying Deep Learning in Medical Images: The Case of Bone Age Estimation. Lee, Kim ²¹	Imagiologia Médica (Raios-X)	2018	A rede neural baseada em Deep Learning pode ser usada para estimar a idade de um sujeito a partir de imagens de raio-x de mão, o que elimina a necessidade de buscas tediosas de atlas em ambientes clínicos e deve melhorar o tempo e custo do processo de estimativa.
E8		Benchmarking deep learning models on large healthcare datasets. Purushotham, Meng, Che, Liu ¹	UTI	2018	Os resultados mostram que o modelo Deep Learning supera consistentemente todas as outras abordagens, especialmente quando os dados da série temporal clínica "bruta" são usados como recursos de entrada para os modelos.
E9		Voice Pathology Detection Using Deep Learning on Mobile Healthcare Framework. Alhussein, Muhammad ²²	Telemedicina	2018	O resultado obtido, baseado no Deep Learning, é promissor porque supera alguns dos resultados anteriores relatados na literatura onde se utilizou outra abordagem.
E10		Deep learning for healthcare: review, opportunities and challenges. Miotto, Wang, Wang, Jiang, Dudley ⁷	Medicina	2018	O Deep Learning pode abrir o caminho para a próxima geração de sistemas preditivos de saúde que podem incluir muitos milhões a bilhões de registros de pacientes.
E11		Human Action Monitoring for Healthcare Based on Deep Learning. Gao, Xiang, Xiong, Huang, Lee, Alrifai, et al. ²³	Cuidados em Saúde	2018	O método baseado em Deep Learning para o reconhecimento de ação humana mostrou uma diferença significativa em relação aos métodos tradicionais. Esse método é eficaz e discriminativo para o reconhecimento de ações humanas.
E12		A guide to deep learning in healthcare. Esteva, Robicquet, Ramsundar, Kuleshov, Depristo, Chou, et al. ²⁴	Imagiologia Médica	2019	Em um futuro próximo, os modelos que integram modalidades externas e fontes adicionais de dados biológicos, imagens médicas e outros fenótipos intermediários também podem se beneficiar pelo Deep Learning.
E13		Improving Accuracy of Lung Nodule Classification Using Deep Learning with Focal Loss. Tran, Nghiem, Nguyen, Luong, Burie ²⁵	Tomografia Computadorizada	2019	Os experimentos mostraram que o método de Deep Learning com perda focal é um classificador de alta qualidade, com uma precisão de 97,2%, sensibilidade de 96,0% e especificidade de 97,3%.
E14		Recent Deep Learning Techniques, Challenges and Its Applications for Medical Healthcare System: a review. Pandey, Janghel ²⁶	Assistência Médica	2019	Os resultados apresentam algumas das aplicações mais fundamentais e recentes no sistema de saúde médico e também identificaram alguns dos desafios e oportunidades das técnicas de Deep Learning.
E15		Automatic Tissue Image Segmentation Based on Image Processing and Deep Learning. Kong, Li, Luo, Xu ²⁷	Imagiologia Multimodal	2019	Abordagens relacionadas ao Deep Learning reduziram bastante o tempo de processamento em comparação com a segmentação manual e semiautomática, além de serem de grande importância para melhorar a velocidade e precisão à medida que mais e mais amostras estão sendo aprendidas.

Figura 2. Artigos pesquisados na revisão. Rio de Janeiro (RJ), Brasil, 2019.

DISCUSSÃO

Analisou-se, por este artigo, o emprego do DL em diferentes áreas referentes aos cuidados de saúde. Propôs-se, no primeiro estudo, (E1) trazer artigos sobre desenvolvimento teórico e modelo juntamente com aplicações inovadoras do DL. Mostrou-se, neste estudo, a eficácia do DL no que tange ao seu uso para classificação de imagens e descoberta de drogas. Destaca-se, por meio deste estudo, a contribuição do DL para a imagenologia e para a indústria farmacêutica, pois descobrir novas drogas, representa a esperança de descobrir a cura para muitas doenças.¹⁵ Destaca-se a importância de pesquisar outros setores nos quais possam empregar o DL como citado no estudo E1.

Mostrou-se, no segundo estudo (E2), a eficácia do DL para a modelagem da progressão da doença, recomendação de intervenção e previsão de risco futuro. Identificou-se, por meio deste estudo, que o DL abre uma nova abordagem baseada em princípios para a medicina preditiva, destacando-se, por sua vez, que a medicina preditiva pode ser definida como a capacidade de se fazer previsões quanto à possibilidade de uma pessoa desenvolver alguma doença.¹⁶

Analisou-se, no terceiro estudo (E3), os dois tipos de redes neurais profundas, conhecidas como rede neural de convolução (CNN) e rede neural profunda (DNN). Observou-se a popularidade e o poder do DL em muitas áreas de diagnóstico por imagem médica.¹⁷

Apresentou-se, no quarto estudo (E4), uma estrutura de inferências do DL para os cuidados de saúde. Demonstrou-se, a perspectiva promissora do DL na área de cuidados de saúde devido a eficácia do processo de ciclo fechado.¹⁸

Demonstrou-se, no quinto estudo (E5), um novo modelo de recomendação de serviço de saúde socializado baseado em DL. Destacou-se, a importância do DL, no que tange à facilidade de uso deste método, pois pode-se alcançar altos desempenhos, mesmo quando utilizado por usuários iniciantes e com um número limitado de conhecimentos.¹⁹

Introduziu-se, no sexto estudo (E6), o modelo DL como uma técnica de monitoramento da taxa respiratória de alta resolução aos smartphones para o monitoramento diário da qualidade do sono das pessoas. Nota-se, por meio dos resultados deste estudo, uma boa precisão do monitoramento da taxa de respiração.²⁰

Apresentou-se, no sétimo estudo (E7), uma maneira de aplicar a técnica de DL à análise de imagens médicas usando a estimativa da idade óssea como exemplo. Identificou-se a alta precisão do DL, ao possibilitar-se estimar idade de um sujeito, a partir de imagens de raio-x de mão, o que elimina a necessidade de buscas tediosas de atlas em ambientes clínicos e deve melhorar o tempo e custo do processo de estimativa.²¹

Demonstrou-se, no oitavo estudo (E8), os resultados de benchmarking (avaliação comparativa) para várias tarefas de predição clínica e utilizar o conjunto de dados disponível publicamente no Centro de Informação Médica para Cuidados Intensivos. Mostrou-se, desta forma, que o DL supera consistentemente todas as outras abordagens, especialmente quando os dados da série temporal clínica "bruta" são usados como recursos de entrada para os modelos.¹

Utilizou-se, no nono estudo (E9), uma técnica de aprendizado de transferência para usar os modelos robustos existentes da Redes Neurais Convolucionais. Constatou-se, por meio dos resultados obtidos neste estudo, que o DL é uma abordagem promissora porque supera alguns dos resultados anteriores relatados na literatura onde se utilizou outros tipos de abordagem.²²

Discutiram-se, no décimo estudo (E10), as aplicações recentes e futuras da Deep Learning em Medicina, destacando os aspectos-chave para impactar significativamente os cuidados de saúde. O Deep Learning pode abrir o caminho para a próxima geração de sistemas preditivos de saúde que podem incluir muitos milhões a bilhões de registros de pacientes.⁷

Apresentou-se, no décimo primeiro estudo (E11), uma classe de rede neural artificial do tipo feed-forward para monitorar remotamente a ação humana para a saúde inteligente, que é a primeira tentativa de integrar a rede convolucional 3D. Notou-se uma diferença significativa em relação aos métodos tradicionais, no que tange ao reconhecimento de voz humana.²³

Implementou-se, no décimo segundo estudo (E12), técnicas de Deep Learning para cuidados de saúde, centrando a discussão sobre Deep Learning em visão computacional, processamento de linguagem natural e métodos generalizados. Mostrou-se, neste estudo, que os benefícios do DL, podem alcançar os modelos que integram modalidades externas e fontes adicionais de dados biológicos, imagens médicas e outros fenótipos intermediários.²⁴

Relatou-se, no décimo terceiro estudo (E13), um novo método de Deep Learning para melhorar a acurácia da classificação dos nódulos pulmonares na tomografia computadorizada (TC). (E13) Destacou-se, neste estudo, a alta qualidade do método DL, mesmo com perda focal.²⁵

Descreveu-se, no décimo quarto estudo (E14), todas as técnicas de Deep Learning e sua análise experimental com vantagens e desvantagens. Apresentaram-se, por meio dos resultados, algumas das aplicações mais fundamentais e recentes no sistema de saúde médico e também identificaram alguns dos desafios e oportunidades das técnicas de Deep Learning.²⁶

Usou-se métodos de pré-processamento, como a denoisação wavelet, para extrair os contornos precisos de diferentes tecidos, como crânio,

líquido cefalorraquidiano (LCR), substância cinzenta (GM) e substância branca (WM), em cinco conjuntos de imagens de cabeça de RM. Identificou-se, assim como no (E6), uma boa precisão no modelo DL, destacando-se, ainda, a redução do tempo de processamento em comparação com a segmentação manual e semiautomática.²⁷

CONCLUSÃO

Conclui-se que sistemas de DL podem ser efetivamente usados para melhorar a precisão e aumentar a eficiência em cuidados de saúde. Pode-se o DL ajudar os profissionais de saúde com aquelas tarefas nas quais os mesmos tenham certa dificuldade, pois a proposta do “aprendizado profundo”, forma na qual o DL pode ser traduzido, busca aprender com as dificuldades humanas por meio da identificação de erros em determinadas etapas, procurando sempre corrigi-los e evitá-los em etapas posteriores.

Pontua-se a necessidade de abordar mais temas que estabeleçam uma relação entre cuidados de saúde e Big Data, a Internet das Coisas e a própria *Machine Learning*, considerando que DL é um subgrupo do *Machine Learning*, que por sua vez, é uma vertente da IA.

Busca-se, com este estudo incentivar profissionais da área da saúde a implementarem o *Deep Learning* em cuidados de saúde e divulgarem seus respectivos resultados obtidos por meio desta implementação e citar os principais desafios que podem surgir ao longo do caminho.

Entende-se que a análise destes benefícios pode colaborar para pesquisas futuras e identificação de outros que não foram identificados neste estudo. Identifica-se a necessidade de mais publicações nacionais, devido a diferença significativa entre o número de artigos nacionais e internacionais, pois maior parte da literatura baseada na temática deste estudo concentra-se em publicações fora do Brasil e no idioma inglês, baseando-se nos resultados apresentados neste artigo.

REFERÊNCIAS

1. Purushotham S, Meng C, Che Z, Liu Y. Benchmarking deep learning models on large healthcare datasets. *J Biomed Inform.* 2018 July;83:112-34. DOI: <https://doi.org/10.1016/j.jbi.2018.04.007>
2. Bini SA. Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *J Arthroplasty.* 2018 Aug;33(8):2358-61. DOI: <https://doi.org/10.1016/j.arth.2018.02.067>
3. World Health Organization. Resolutions and Decisions WHA58.28 eHealth [Internet]. Geneva: WHO;2005 [cited 2018 Dec 15]. Available from:

https://apps.who.int/iris/bitstream/handle/10665/20378/WHA58_28-en.pdf?sessionid=29FCA109F3711C9A1CDAFC2DC48254EE?sequence=1

4. Organização Mundial da Saúde. Chamada da OMS para tecnologias inovadoras em saúde para situação de recursos limitados [Internet]. Brasília: PAHO;2013 [cited 2018 Aug 10]. Available from: https://www.paho.org/bra/index.php?option=com_content&view=article&id=3175:chamada-da-oms-para-tecnologias-inovadoras-em-saude-para-situacao-de-recursos-limitados&Itemid=838
5. Goodfellow Y, Bengio A. Courville, Deep Learning. Cambridge MIT Press; 2016.
6. Squire L, Berg D, Bloom FE, Lac SD, Ghosh A, Spitzer NC. Fundamental Neuroscience. California: Academic Press; 2012.
7. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. *Brief Bioinform.* 2018 Nov;19(6):1236-46. DOI: [10.1093/bib/bbx044](https://doi.org/10.1093/bib/bbx044)
8. Landset S, Khoshgoftaar TM, Richter AN, Hasanin T. A survey of open source tools for machine learning with big data in the Hadoop ecosystem. *J Big Data.* 2015 Nov;2:24. DOI: [http://dx.doi.org/10.1186/s40537-015-0032-1](https://dx.doi.org/10.1186/s40537-015-0032-1)
9. Liu C, Liu X, Wu F, Xie M, Feng Y, Hu C. Can Watson for Oncology replace oncologists: A comparative study between Watson for Oncology and our multidisciplinary tumor board (Preprint). *J Med Internet Res.* 2018 Sept;20(9):e11087. DOI: [http://dx.doi.org/10.2196/11087](https://dx.doi.org/10.2196/11087)
10. Poole DL, Mackworth A, Goebel RG. Computational Intelligence and Knowledge [Internet]. New York: Oxford University Press; 1998 [cited 2018 Aug 10]. Available from: <https://www.cs.ubc.ca/~poole/ci/ch1.pdf>
11. Bughin J, Hazan E, Ramaswamy S, Chui M, Allas T, Dahlstrom P, et al. Artificial Intelligence: the next digital frontier? Chicago: McKinsey & Global Institute;2017 [cited 2019 June 15];
12. Available from: <https://www.mckinsey.com/~/media/McKinsey/Industries/Advanced%20Electronics/Our%20Insights/How%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/MGI-Artificial-Intelligence-Discussion-paper.ashx>
13. Widmayer CE. John Sloan Dickey: a Chronicle of His Presidency of Dartmouth College. Hanover: Dartmouth College; 1991.
14. Martins CA, Braile DM. Análise cientométrica dos periódicos em Ciências da Saúde e áreas correlatas disponíveis no Portal de Periódicos da Capes. *PCI.* 2009 Dec;14(3):75-93. DOI: [http://dx.doi.org/10.1590/s1413-99362009000300006](https://dx.doi.org/10.1590/s1413-99362009000300006).
15. Moher D, Liberati A, Tetzlaff J, Altman DG, The PRISMA Group. Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The

PRISMA Statement. PLoS Med. 2009;6(7):e1000097. DOI: [10.1371/journal.pmed1000097](https://doi.org/10.1371/journal.pmed1000097)

16. Tong C, Medsker L, Cheng L, Jafari A, Wang X. Introduction to the special issue on deep learning for biomedical and healthcare applications. Neural Comput Appl. 2018 Sept;30(7):2015-6. DOI: [http://dx.doi.org/10.1007/s00521-018-3694-8](https://dx.doi.org/10.1007/s00521-018-3694-8)

17. Pham T, Tran T, Phung D, Venkatesh S. Predicting healthcare trajectories from medical records: A deep learning approach. J Biomed Inform. 2017 May;69:218-29. DOI: [10.1016/j.jbi.2017.04.001](https://doi.org/10.1016/j.jbi.2017.04.001)

18. Song Q, Zhao L, Luo X, Dou X. Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. J Healthc Eng. 2017 Mar/Aug;1-7. DOI: [http://dx.doi.org/10.1155/2017/8314740](https://dx.doi.org/10.1155/2017/8314740)

19. Dai Y, Wang G. A deep inference learning framework for healthcare. Pattern Recognition Letters. 2018 Feb. DOI: [http://dx.doi.org/10.1016/j.patrec.2018.02.009](https://dx.doi.org/10.1016/j.patrec.2018.02.009)

20. Yuan W, Li C, Guan D, Han G, Khattak AM. Socialized healthcare service recommendation using deep learning. Neural Comput Appl. 2018 Mar;30(7):2071-82. DOI: [http://dx.doi.org/10.1007/s00521-018-3394-4](https://dx.doi.org/10.1007/s00521-018-3394-4)

21. Liu B, Dai X, Gong H, Guo Z, Liu N, Wang X, *et al.* Deep Learning versus Professional Healthcare Equipment: A Fine-Grained Breathing Rate Monitoring Model. J Sports Med. 2018 July/Nov;1-9. DOI: [http://dx.doi.org/10.1155/2018/5214067](https://dx.doi.org/10.1155/2018/5214067)

22. Lee JH, Kim KG. Applying Deep Learning in Medical Images: The Case of Bone Age Estimation. Healthc Inform Res. 2018 Jan;24(1):86. DOI: [10.4258/hir.2018.24.1.86](https://doi.org/10.4258/hir.2018.24.1.86)

23. Alhussein M, Muhammad G. Voice Pathology Detection Using Deep Learning on Mobile Healthcare Framework. IEEE Access. 2018 July;6:41034-41. DOI: [http://dx.doi.org/10.1109/access.2018.2856238](https://dx.doi.org/10.1109/access.2018.2856238)

24. Gao Y, Xiang X, Xiong N, Huang B, Lee HJ, Alrifai R, *et al.* Human Action Monitoring for Healthcare Based on Deep Learning. IEEE Access. 2018 Nov;6:1. DOI: [http://dx.doi.org/10.1109/access.2018.2869790](https://dx.doi.org/10.1109/access.2018.2869790)

25. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, Depristo M, Chou K, *et al.* A guide to deep learning in healthcare. Nature Med. 2019 Jan;25(1):24(6). DOI: [http://dx.doi.org/10.1038/s41591-018-0316-z](https://dx.doi.org/10.1038/s41591-018-0316-z)

26. Tran GS, Nghiem TP, Nguyen VT, Luong CM, Burie J-C. Improving Accuracy of Lung Nodule Classification Using Deep Learning with Focal Loss. J Healthc Eng. 2019 Feb 4;2019:1-9. DOI: [http://dx.doi.org/10.1155/2019/5156416](https://dx.doi.org/10.1155/2019/5156416)

27. Pandey SK, Janghel RR. Recent Deep Learning Techniques, Challenges and Its Applications for Medical Healthcare System: a review. Neural

Processing Letters. 2019 Jan;01-29. DOI: [http://dx.doi.org/10.1007/s11063-018-09976-2](https://dx.doi.org/10.1007/s11063-018-09976-2)

28. Kong Z, Li T, Luo J, Xu S. Automatic Tissue Image Segmentation Based on Image Processing and Deep Learning. J Healthc Eng. 2019 Jan;1-10. DOI: <https://doi.org/10.1155/2019/2912458>

29. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, *et al.* Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. JAMA [Internet]. American Medical Association (AMA);2016 Dec 13;316(22):2402. Available from: [http://dx.doi.org/10.1001/jama.2016.17216](https://dx.doi.org/10.1001/jama.2016.17216)

30. Lipton ZC, Kale DC, Elkan C., *et al.* Learning to diagnose with LSTM recurrent neural networks. In: International Conference on Learning Representations, San Diego, CA, USA, 2015, 1-18. DOI: <http://arxiv.org/abs/1511.03677>

Submissão: 01/08/2019

Aceito: 07/08/2019

Publicado: 07/08/2019

Correspondência

Flávio Vaz Machado

E-mail: fvaz649@gmail.com

 Esta obra é licenciada sob Atribuição CC BY 4.0 [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by/4.0/) sendo permitida a reprodução parcial ou total desde que mencionada a fonte.