

Deep Learning Aplicado a Neuroimaging

Jin Uema¹, Lucas M. A. Freitas¹ Mario Olímpio de Menezes¹

¹Faculdade de Computação e Informática– Universidade Presbiteriana Mackenzie
01302-907 – São Paulo – SP – Brazil

31843824@mackenzista.com.br , 41552881@mackenzista.com.br ,
mario.menezes@mackenzie.br

Abstract. *Neuroimaging techniques seek to study the structure of the nervous system through image recognition, thereby recognizing pathologies. In this project, an algorithm was developed using Neural Networks to perform a classification of neurological diseases based on the image recognition focusing on brain cancer. With this application it is possible to help professionals in the health field in a given dataset.*

Resumo. *As técnicas de Neuroimaging buscam estudar a estrutura do sistema nervoso através de reconhecimento de imagem, com isso reconhecendo patologias cerebrais. Neste projeto foi desenvolvido um algoritmo utilizando Redes Neurais para realizar uma classificação de doenças neurológicas com base no reconhecimento de imagens dando foco a câncer cerebral. Com esta aplicação é possível ajudar profissionais na área da saúde em um determinado conjunto de dados.*

1. Introdução

Com o avanço da medicina e da tecnologia, surgiram novos métodos avançados de mapeamento de imagens para a área da saúde. Estes métodos auxiliam os profissionais na área da saúde a diagnosticar possíveis doenças. Contudo a complexidade de realizar a classificação para o reconhecimento de patologias ligadas a doenças neurológicas e neurodegenerativas (como depressão ou *Alzheimer*) aumentaram.

Segundo a ADI (2013) serão cerca de 65.7 milhões de pessoas com doenças neuro cognitivas no mundo em 2030. Para classificar e diagnosticar doenças neurológicas, foram desenvolvidas técnicas de imagem para analisar e investigar casos mais profundos de problemas neurológicos, estas técnicas também são conhecidas pelo nome de *Neuroimaging*. O *Neuroimaging* é amplamente estudado e utilizado no mundo todo e suas técnicas tendem a providenciar um resultado mais rápido e eficaz, contudo existem limitações ao respeito dos diagnósticos, sendo que em sua grande maioria são determinadas por um médico após a análise das imagens.

Por se tratar de um problema de classificação, pode existir erros e discrepâncias com relação a classificações de imagens, o que pode levar a um diagnóstico errado e afetar severamente o tratamento de um paciente, para isto este projeto buscou criar uma rede neural convolucional para realizar a classificação das imagens. Com isso é possível auxiliar os profissionais na área da saúde e psicologia no diagnóstico da doença reduzindo o risco de diagnósticos errados e melhorando a qualidade do serviço prestado através do tempo ganho no processamento dos resultados.

Dentro deste escopo, existem problemas na realização das técnicas, pois há muitos fatores (conhecidos ou não) que interferem no momento da captação das imagens (como ruídos, problemas nos sensores da máquina de captação, etc...) que podem levar a falsos-positivos no momento da análise do diagnóstico, como parte deste processo é manual pode existir erros e discrepâncias que não são notadas (ABDREASEN, 2006).

Neste contexto, a pergunta que será respondida nesta pesquisa é: Qual é a eficácia da implementação de um algoritmo para realizar a classificação de tumores cerebrais, com relação aos métodos tradicionais, utilizando como base, conjuntos de dados de ressonâncias magnéticas?

Assim, pode-se colocar que o objetivo geral deste estudo é a implementação de uma rede neural convolucional para a classificação de uma patologia neurológica com base em imagens médicas. A partir dessa implementação, realizamos um treinamento com os conjuntos de dados disponíveis e classificamos os pacientes.

O estudo buscou atender aos seguintes pontos:

- Implementar um algoritmo de *deep learning*, utilizando redes neurais convolucionais para realizar comparações com técnicas tradicionais de reconhecimento de tumores.
- Empregar ferramentas de visualização de dados, utilizadas na área de Ciência de Dados para a apresentação dos resultados, de forma a facilitar as análises e compreensão dos resultados.
- Desenvolver experimentos com a rede neural implementada utilizando diferentes métodos de validação e classificação de dados (*Cross-Validation*).

Os resultados deste estudo podem contribuir com uma aplicação prática em hospitais, o que pode levar a um ganho operacional no tempo de identificação e diagnóstico da doença. Do ponto de vista técnico-científico, tem-se um desafio técnico do domínio da tecnologia de criação de redes neurais e sua aplicação em modelos de aprendizado de máquina. Com este projeto, pretende-se assim adquirir e gerar mais conhecimento sobre o problema e sobre a aplicação prática de IA na área da saúde.

O Artigo está estruturado da seguinte maneira:

1. Introdução
2. Referencial Teórico
 1. Neuroimaging
 2. Redes Neurais
 3. Aplicações Práticas
3. Metodologia
4. Resultados e Discussão
5. Conclusões
6. Referências

2. Referencial Teórico

2.1. Neuroimaging

Neuroimaging é o estudo do método de investigação do cérebro humano. O mapeamento do cérebro humano já vem sendo estudado e aperfeiçoado a mais de dois séculos com métodos não invasivos ou minimamente invasivos, é possível ser estudado o cérebro humano de pessoas saudáveis e por pessoas com doenças ou ferimentos (Wager e Smith, 2003). Ao longo dos anos, foram desenvolvidas técnicas para a identificação de sintomas, entre essas técnicas são as principais tomografia computadorizada (CT), ressonância magnética transcraniana (MRI), tomografia por emissão de pósitrons (PET), ressonância magnética funcional (fMRI) e eletroencefalograma (EEG), como exemplificados na Figura 1.

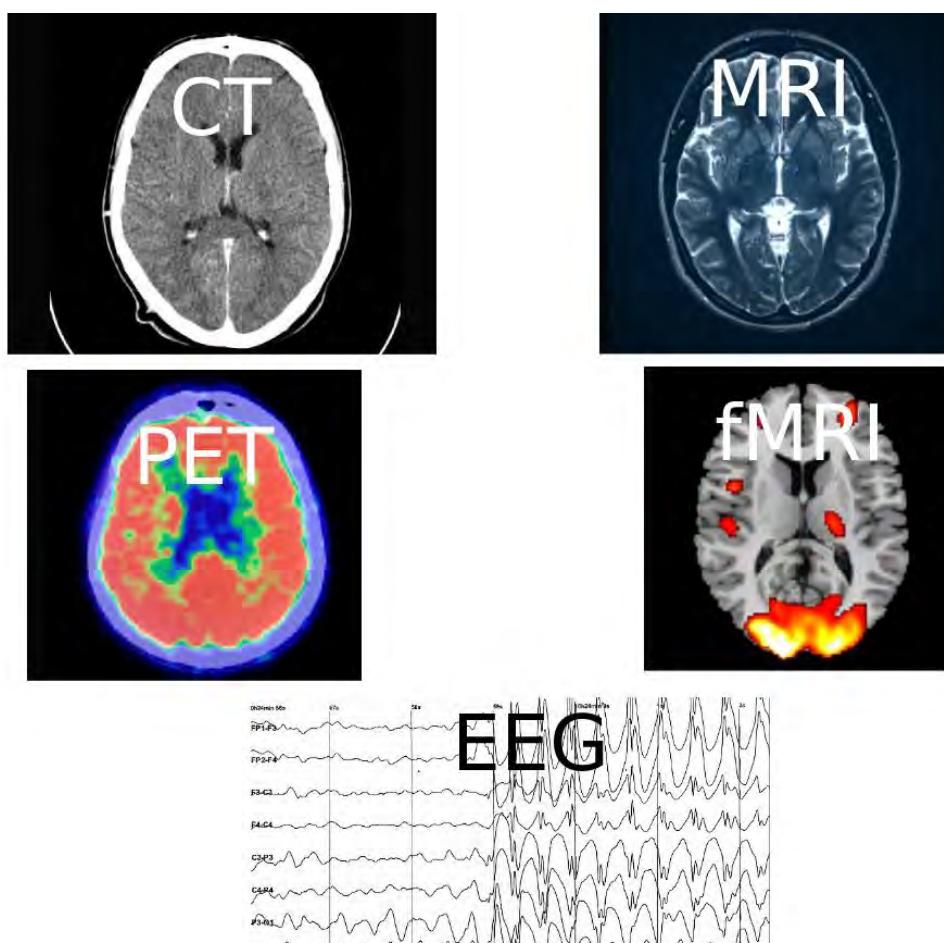


Figura 1. Diferentes técnicas de *neuroimaging* utilizadas atualmente. (Fonte: Brainline)

Quando falamos de *Neuroimaging*, temos que entender qual é a melhor técnica para um determinado problema pois em cada uma temos pontos fortes e limitações. Na interpretação dos dados de neuroimagem deve-se lembrar que não existe um método superior em relação aos demais, já que cada método tem sua finalidade para realizar o monitoramento e as ativações em determinadas regiões do cérebro (KIMBERLEY, 2007).

2.2. Redes Neurais

Na literatura, existe uma grande quantidade de aplicações especializadas para a identificação e resolução de problemas no campo da medicina utilizando como base o *deep learning*, e com o avanço de suas arquiteturas, as redes neurais se tornam mais maduras por causa da sua capacidade de autoaprendizado e generalização em grandes quantidades de dados (BRAGA, 2007). Devido a isso, acabam superando os algoritmos clássicos de aprendizado de máquina (*Machine Learning*) em performance e tempo de execução (CHOLLET, 2018).

Segundo Janiesch (2021), Redes neurais convolucionais (CNN) tem um grande poder computacional em relação ao aprendizado de máquina tradicional, porém são custosas e dependem de um grande volume de dados para gerarem resultados significativos. Com isso, são amplamente utilizadas na literatura para as soluções de problemas relacionados à medicina. As redes neurais convolucionais tem sua capacidade controlada, variando pela profundidade e amplitude, elas fazem suposições fortes e principalmente corretas sobre a natureza das imagens pelas estatísticas e a localização das dependências dos *pixels* (KRIZHEVSKY, 2017).

Com o seu poder de identificar tendências em grandes conjuntos de dados, podemos utilizar as redes neurais convolucionais para identificar padrões e classificar imagens com base no seu processo de extração de características (*features*) e a classificação dos resultados das amostras (Figura 2). Nos últimos anos tivemos um grande desenvolvimento em técnicas de processamento de imagens e de *softwares* de visualização, com estes avanços o uso de CNNs se tornou mais comum para problemas relacionados à computação visual e especialmente em *Neuroimaging* (WANG, 2019).

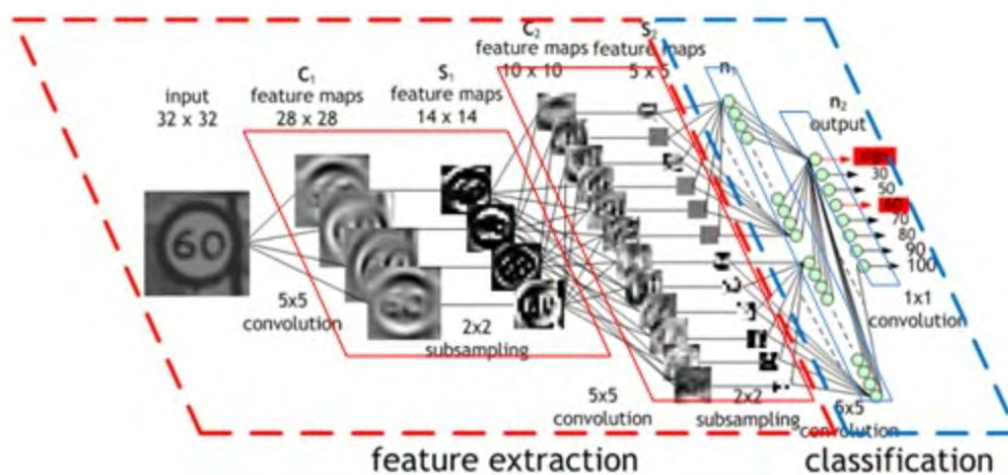


Figura 2. Exemplo de rede neural convolucional (Fonte: Agostinho, 2017)

2.3. Aplicações Práticas

Dentro da medicina, segundo Marques (2018) o uso de técnicas de inteligência artificial é amplamente utilizado para auxiliar diagnósticos médicos com tarefas repetitivas e

previsíveis, pelo fato de problemas de computação visual serem geralmente relacionados à *deep learning* devido a sua alta complexidade e volume de dados. Com isso podemos aplicar redes neurais nos mais diversos tipos de problema de classificação de imagens médicas (LAKHANI, 2017).

Na área de *Neuroimaging*, (MILLETARI, 2017) decidiram aplicar CNNs para análises de regiões profundas do cérebro utilizando técnicas de MRI e Ultrassom. Utilizando uma técnica matemática da transformada de *Hough*, a Rede neural foi capaz de segmentar as regiões em formas geométricas com uma eficiência maior do que outras técnicas de mapeamento (como segmentações baseadas em tamanhos de *voxels* ou semânticas). Com a utilização desta técnica, é possível escalar este tipo de mapeamento para outras regiões do cérebro, visto que a grande limitação encontrada foi a falta de poder do processamento disponível e a quantidade de dados treinados pelo modelo.

Já Sloun (2020) buscaram dar ênfase aos resultados utilizando o Ultrassom, visto que a mesma é uma técnica fundamental para diagnósticos médicos. Por causa de sua portabilidade e custo benefício em comparação com técnicas de diagnóstico mais sofisticadas o ultrassom é mais amplamente utilizado, porém a qualidade da visualização nem sempre é alta, gerando diversos tipos de ruídos no diagnóstico final. O trabalho buscou reconstruir e restaurar imagens implementando redes neurais a partir de técnicas de visão computacional em comparação com o seu resultado original.




Figura 3. (a) Ultrassom original. (b) Ultrassom reconstruído utilizando redes neurais convolucionais (Fonte: Sloun (2020))

Para análise quantitativa de imagens de ressonância magnética do cérebro é feita a segmentação que é a marcação de *pixels* em 2D (*voxels* em 3D), e essa segmentação é feita de maneira manual separando as estruturas fatia por fatia, deixando a segmentação cara, tediosa e imprecisa devido ao erro humano. Para isso Akkus (2017) criaram métodos de segmentação automatizados com alta consistência e precisão próxima ou superior à dos avaliadores visto que a eficiência e eficácia de uma rede neural pode ganhar de um ser humano.

3. Metodologia

Num primeiro momento, foi fundamental aprofundar o mapeamento dos principais problemas na classificação de imagens médicas e classificar suas complexidades. Os dados foram coletados através de bases de acesso público disponíveis no *OpenNeuro*. Após isto, as bases foram separadas em conjuntos de dados dos quais foram incorporadas em um modelo de redes neurais.

Com relação a descrição dos dados que foram utilizados no estudo, foram utilizados arquivos com formato específico para *Neuroimaging* (.nii.gz). Para este tipo de arquivo específico os dados estão estruturados de forma volumétrica, onde existem 3 dimensões de imagem (altura, largura e profundidade). Os dados são ressonâncias magnéticas obtidas por um *scan axial* (Figura 4) de pacientes com tumores na região cerebral (AERTS, 2022). Neste conjunto de dados existem 44 ressonâncias com positivo para tumor cerebral e 21 com negativo. Devido a pouca quantidade de dados disponível para acesso público, foi utilizado técnicas de aumento de dados onde as imagens existentes foram rotacionadas em 6 diferentes ângulos para assim poder gerar um volume maior ao conjunto de treinamento e de teste. Segundo Perez (2017) tais técnicas aumentam a performance de modelos onde o conjunto de dados é limitado. Também foram analisadas as características homogêneas das imagens, dado que as mesmas tiveram a parte frontal do crânio retirada, para evitar o reconhecimento e a reconstrução dos rostos de pacientes que participaram do estudo.




Figura 4. Pedacos scaneados de um crânio em direção axial (Fonte: Aerts (2022))

No que tange ao modelo que foi desenvolvido, foi utilizada a linguagem de programação *Python* para seu desenvolvimento e análise dos resultados após as etapas de treinamento e teste. A biblioteca *Keras* (sub-conjunto da biblioteca *TensorFlow*) foi utilizada no estudo devido as funções de criação e treinamento de redes neurais convolucionais tridimensionais (3DCNN) e por ser utilizada em trabalhos com dados volumétricos existentes na literatura (RAJU, 2021). Com relação a sua estrutura, foram criados 3 filtros (*layers*) de 64, 64, 128 e 256 *pixels*, com um *maxpool* e uma função de normalização (Figura 5), a função de ativação *ReLU* (Retificadora) foi utilizada devido a sua performance em redes neurais profundas. Zunair (2020) utiliza uma estrutura

similar para extrair as características de imagens médicas em dados tridimensionais com uma melhor acurácia. Após isto, foi aplicado um filtro gaussiano com um *kernel* de tamanho 3. Os principais indicadores que foram utilizados para realizar o benchmarking do modelo é uma pontuação de acurácia do modelo com relação a classificação e o seu valor de perda (*loss*).

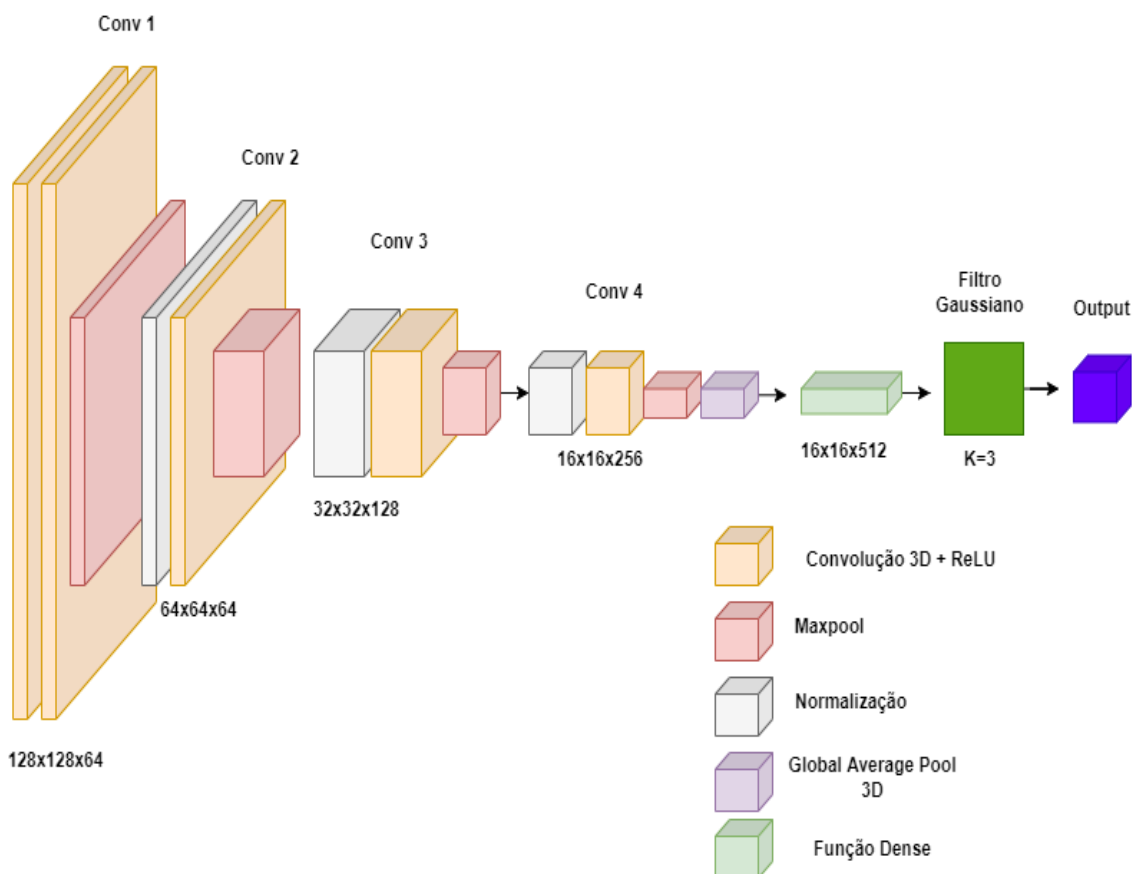


Figura 5. Diagrama do modelo desenvolvido e etapas de processamento dos dados nas camadas (Fonte: Autores).

Após a extração dos dados, foi verificado o score de acurácia e também realizado um método de validação cruzada (*cross-validation*) onde segundo Berrar (2018), realiza a prevenção de problemas relacionados a *overfitting* dos dados e entrega os valores de predição e erro verdadeiros. Com base no que foi apresentado, foi utilizada a validação cruzada *k-fold* onde o conjunto de aprendizado do modelo é particionado em *k* subconjuntos de tamanho igual, no caso do modelo desenvolvido, o número de subconjuntos utilizados foi 10.

4. Resultados e Discussão

Após o treinamento do modelo, o score de acurácia estava alto, porém os valores de validação tiveram um score baixo. Porém nota-se que em dados padronizados, onde as ressonâncias têm a mesma configuração de angulação, a acurácia é maior. O modelo em um momento inicial estava com a acurácia de 0.91 no conjunto de dados de treinamento e 0.67 na validação (Figura 6).




Figura 6. Acurácia e Perda do modelo ao longo das gerações. (Fonte: Autores)

Com base neste resultado inicial, foram exploradas outras formas de otimizar a performance do modelo, através de técnicas de computação visual (como filtros lineares e binarização), porém o ganho de performance não foi significativo.

Tabela 1. Valores de Perda e Acurácia utilizando filtros adicionais.

Técnica	Perda do Modelo - Treino	Perda do Modelo - Teste	Acurácia Treino	Acurácia Teste
Nenhuma	0.74	2.775	91%	67%
Filtro Linear - Passa Baixa	0.72	2.811	91%	64%
Filtro Linear – Passa Alta	0.75	2.682	92%	63%
Binarização	0.80	2.685	90%	59%

Nota-se também que a acurácia de treino do modelo está bem acima da acurácia de validação, o que indica um problema de *overfitting*. Para isso, realizamos a validação cruzada utilizando a técnica de *k-folds* com o número de *folds* igual a 10.

Tabela 2. Valores de Perda e Acurácia ao longo dos *k-folds*.

<i>Folds</i>	Perda do Modelo - Treino	Perda do Modelo - Teste	Acurácia Treino	Acurácia Teste
1	0.95	2.842	88%	62%
2	0.81	1.983	90%	68%
3	0.84	1.672	87%	68%
4	0.83	1.985	91%	71%
5	0.89	2.341	89%	74%

6	0.78	2.791	90%	66%
7	0.90	2.476	92%	70%
8	0.85	2.211	89%	65%
9	0.80	1.787	87%	66%
10	0.93	1.777	88%	69%
Valor Médio	0.847	2.187	89%	68%

Após a validação cruzada, notamos que não houve uma melhora significativa nos resultados da validação cruzada em comparação a solução inicial, por se tratar de um modelo de redes neurais convolucionais tri-dimensionais, pode existir uma falta de dados devido as limitações de tamanho na quantidade de *scans* no conjunto de dados trabalhado. Isto se dá devido à falta de dados disponíveis para acesso público, visto que as leis de proteção de dados (LGPD, GDPR & CCPA) limitam o acesso a informação á nível individual, ficando restrito a instituições de pesquisa. Isto impacta diretamente na escalabilidade do modelo.

5. Conclusões

Com base nos resultados apresentados, podemos afirmar que uma rede neural é capaz de reconhecer pacientes com tumores caso esteja disponível um grande volume de imagens para o seu treinamento. Neste trabalho em específico não se atingiu uma significância estatística para realizar a afirmação sem uma segunda opinião médica e visto que a área médica demanda exatidão para diferentes diagnósticos.

Existe uma dificuldade para encontrar imagens médicas de acesso público em seu formato volumétrico devido as questões de proteção aos dados dos usuários, o que torna o processo de treinamento do modelo burocrático. Também notamos que é possível expandir a abordagem do problema para outros tipos de patologias que necessitam de diagnóstico por análise de imagens neurológicas (Como Alzheimer e Depressão) visto que também existe uma necessidade de reconhecimento precoce destas doenças.

Embora este projeto não tenha realizado outras abordagens, ainda sim é possível realizar classificações entre outras características de patologias neurológicas. Também com os resultados obtidos é possível buscar detentores destes dados para que realizem o treinamento deste modelo de forma interna, assim evitando problemas com as leis de proteção a dados.

Referências

Aerts, H. Marinazzo, D. (2022) “BTC_postop“. OpenNeuro. Dataset
doi:10.18112/openneuro.ds002080.v3.0.0. Disponível em:
<https://www.openneuro.org/datasets/ds002080/versions/3.0.0>.

- Agostinho, I. M., Peres, S. M. (2017) “Redes neurais convolucionais aplicadas à análise de gestos considerando os problemas estudados na área de Estudos dos Gestos“. PETSI-USP. Disponível em: <http://www.each.usp.br/petsi/?p=7325>.
- Akkus, Z. et al. (2017) “Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions” *Journal of Digital Imaging*, v. 4, n. 1, p. 449-459. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5537095/>.
- Alzheimer’s Disease International (2013) “Dementia in the Americas”, <https://www.alzint.org/resource/dementia-in-the-americas/>
- Abdreasen, N. C. et al. (2006) “Image processing for the study of brain structure and function: problems and programs” *The Journal of Neuropsychiatry*, v. 4, n. 2, p. 125-133. Disponível em: <https://doi.org/10.1176/jnp.4.2.125>.
- Berrar, Daniel (2019) “Cross-validation” *Encyclopedia of Bioinformatics and Computational Biology*, v. 1, n. 1, p. 542-545. Disponível em: <https://doi.org/10.1016/B978-0-12-809633-8.20349-X>
- Braga, A de P and Ferreira A. C. P. (2007) “Redes neurais artificiais: Teoria e aplicações”, Ludermir. Rio de Janeiro, Brasil.
- Brainline (2011) “Brain Imaging: What Are the Different Types?”, <https://www.brainline.org/slideshow/brain-imaging-what-are-different-types>
- Chollet, F. (2018) “Deep Learning with Python”, Manning Publications. 2ª edição, p. 360.
- Green, M. A. (2018) “Use of machine learning approaches to compare the contribution of different types of data for predicting an individual’s risk of ill health: an observational study” *The Lancet*, Elsevier, v. 392, p. S40.
- Júnior, R. Fernandes, A. (2018) “Atenuação de artefato metálico em imagem de tomografia computadorizada com uso de Deep learning”, Mestrado em Ciência e Tecnologia em Saúde – PPGCTS, Universidade Estadual da Paraíba, Paraíba, Brasil.
- Krizhevsky, A. Sutskever, I. Hinton, G. E. (2017) “ImageNet classification with deep convolutional neural networks” *Communications of the ACM*, v. 60, n. 6, p. 84-90. Disponível em: <https://dl.acm.org/doi/abs/10.1145/3065386>.
- Kimberley, T. J. Lewis, S. M. (2007) “Understanding Neuroimaging” *Physical Therapy & Rehabilitation Journal*, v. 87, n. 6, p. 670-683. Disponível em: <https://academic.oup.com/ptj/article/87/6/670/2747230>.
- Janiesch, C. Zschech, P. Heinrich, K. (2021) “Machine learning and deep learning” *Electronic Markets*, v. 31, n. 1, p. 685-695. Disponível em: <https://doi.org/10.1007/s12525-021-00475-2>.
- Lahkhani, P. Sundaram, B. (2017) “Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks” *Radiology*, v. 284, n. 2, p. 574-582. Disponível em: <https://pubs.rsna.org/doi/full/10.1148/radiol.2017162326>.
- Liu, F. et al. (2017) “3DCNN-DQN-RNN: A Deep Reinforcement Learning Framework for Semantic Parsing of Large-Scale 3D Point Clouds” *Proceedings of the IEEE*

- International Conference on Computer Vision (ICCV), Beijing, China, v. 1, n. 1, p. 5678-5687.
- Marques, J. S. et al. (2018) “Inteligência Artificial em Radiologia: Do Processamento de Imagem ao Diagnóstico” *Acta Radiológica Portuguesa*, Lisboa, v. 30, n. 2, p. 5-8. Disponível em: <https://revistas.rcaap.pt/actaradiologica/article/view/14999>.
- Milletari, F. et al. (2017) “Hough-CNN: Deep Learning for Segmentation of Deep Brain Regions in MRI and Ultrasound” *Computer Vision and Image Understanding*, Elsevier, v. 164, n. 1, p. 92-102. Disponível em: <https://www.sciencedirect.com/journal/computer-vision-and-image-understanding>.
- Perez, Luis; Wang, Jason. (2017) “The Effectiveness of Data Augmentation in Image Classification using Deep Learning” *Computer Vision and Pattern Recognition*, University of Stanford. Disponível em: <http://vision.stanford.edu/teaching/cs231n/reports/2017/pdfs/300.pdf>
- Raju, Manu; Gopi, Varun P.; Anitha, V. S (2021) “Multi-class Classification of Alzheimer's Disease using 3DCNN Features and Multilayer Perceptron” 2021 Sixth International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET) v. 1, n. 1, p.368-373.
- Sloun, R. J. V. Cohen, R. Eldar, Y. C. (2020) “Deep learning in Ultrasound Imaging” *Proceedings of the IEEE*, v. 108, n. 1, p. 11-29. Disponível em: <https://ieeexplore.ieee.org/document/8808885>.
- Tekerek, A; Bay, O. F. (2019) “Design And Implementation of an artificial intelligence-based web application firewall model. *Neural Network World*” Gazi University, v. 4, n. 29, p. 189-206.
- Wagner, Tor D. Smith, E. E (2003) “Neuroimaging studies of working memory: A meta-analysis. *Cognitive, Affective, & Behavioral Neuroscience*” *Cognitive, Affective, & Behavioral Neuroscience*, v. 3, n. 1, p. 255-274. Disponível em: <https://link.springer.com/article/10.3758/CABN.3.4.255>.
- Wang S. et al. (2019) “Pathology Image Analysis Using Segmentation Deep Learning Algorithms” *The American Journal of Pathology*, v. 189, n. 9, p. 1686-1698. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0002944018311210>.
- Zunair, H. et al. (2020) “Uniformizing Techniques to Process CT scans with 3D CNNs for Tuberculosis Prediction”. *Predictive Intelligence in Medicine*. p. 156-168 Disponível em https://link.springer.com/chapter/10.1007/978-3-030-59354-4_15.