

Experimento da utilização de Deep Learning para auxílio na detecção de Tumor Cerebral

Natália Caroline de Oliveira Rodrigues¹

¹Departamento de Ciência da Computação – DECOM
Universidade Federal de Ouro Preto (UFOP)
Ouro Preto, MG – Brasil

natalia.cor@aluno.ufop.edu.br

Abstract. *The article proposes an educational experiment to demonstrate the potential of deep learning models in the detection and classification of brain tumors. Using neural networks such as EfficientNetB1, VGG-19, and VGG-16, the study compares their efficacy in analyzing magnetic resonance images to identify tumors. The results show that the EfficientNet-B1 model achieved better performance, highlighting the importance of deep learning in medicine. The experiment stands out for integrating practical applications in an educational setting, contributing to the advancement of knowledge and medical practice*

Resumo. *O artigo demonstra o potencial de redes neurais, como EfficientNet-B1, VGG-19 e VGG-16, na detecção e classificação de tumores cerebrais através de imagens de ressonância magnética. Destaca-se que o EfficientNet-B1 superou os demais, ressaltando a relevância do aprendizado profundo na medicina e sua aplicabilidade em contextos educacionais para enriquecer o conhecimento e práticas médicas.*

1. Introdução

O tumor é caracterizado pelo crescimento descontrolado das células em uma dada região do corpo. Os tumores cerebrais se destacam por sua raridade e alta letalidade, conforme destacado em [Işın et al. 2016]. A detecção precoce e a classificação precisa desses tumores são vitais para o prognóstico e tratamento eficaz dos pacientes, o que motiva intensa pesquisa nessa área [Ahmad et al. 2017], [Sengupta et al. 2018].

Novos métodos de mapeamento de imagens vão surgindo de acordo com o avanço da medicina. Auxiliando o dia a dia de profissionais da saúde [Uema and Silva 2022]. Segundo estudos de [Koerich et al. 2024] O *deep learning* imita o processo de aprendizado do cérebro humano usando redes neurais complexas e grandes conjuntos de dados, destaca-se na medicina principalmente pela sua capacidade de identificar padrões e interpretar imagens, além de criar prognósticos e terapias personalizadas. Uma das suas aplicações médicas em estudo é na segmentação de tumores cerebrais a partir de imagens de ressonância magnética, visando aprimorar e acelerar as decisões clínicas dos profissionais de saúde.

De acordo com os estudos de [Talebi et al. 2024] o uso de aprendizado profundo, uma técnica avançada que permite aos algoritmos aprender com dados e responder a novas informações com base em padrões previamente identificados, está crescendo rapidamente em várias áreas médicas, como o estudo do coração, imagens de diagnóstico, saúde ocular,

problemas de pele e análise de tecidos doentes. Esses algoritmos têm a capacidade de se aprimorar com a prática, o que os torna cada vez mais eficazes na interpretação de novos casos.

2. Objetivo

Este artigo tem como objetivo propor um experimento aplicável em sala de aula para turmas do curso de Sistemas de Informação do Ensino Superior, visando explorar e demonstrar o potencial dos modelos de aprendizado profundo na detecção e classificação de tumores cerebrais. A metodologia precisa apresentada neste estudo busca não apenas enriquecer o aprendizado dos estudantes, mas também ressaltar a importância e a viabilidade dos modelos de inteligência artificial na medicina. Especificamente, o experimento focará na classificação de até três classes de tumores cerebrais, fornecendo uma abordagem prática e didática para integrar conceitos teóricos com aplicações práticas em um ambiente educacional.

3. Metodologia

Este estudo aplica modelos de aprendizado profundo (*EfficientNetB1*, *VGG-19*, *VGG-16*) com estudantes de graduação em *Sistemas de Informação* para a detecção e classificação de tumores cerebrais usando imagens de ressonância magnética. Os modelos serão avaliados por precisão, *recall* e outras métricas relevantes, buscando identificar o mais eficiente. Discussões sobre as implicações clínicas dos resultados e sugestões de melhorias para a aplicação de aprendizado profundo na medicina serão realizadas, com o objetivo de contribuir para avanços significativos na área.

No ambiente educacional, a metodologia incluirá sessões práticas em sala de aula, onde os estudantes participarão ativamente do processo de desenvolvimento e treinamento dos modelos usando *CNN*, *ANN*, e *Transfer Learning* através do *Google Colab* com o auxílio das bibliotecas *Tensorflow* e *Keras*. A experiência prática se concentrará na aplicação de técnicas de *Data Augmentation*, preparação de dados, e análise de resultados. Serão discutidos os conceitos teóricos por trás das redes neurais utilizadas, com ênfase na importância da *Global Average Pooling2D* e *Dropout* para a eficiência do modelo e na interpretação da camada *Dense* para a classificação dos tumores. O trabalho prático será complementado com a análise comparativa dos modelos *EfficientNetB1*, *VGG-19* e *VGG-16*, enfatizando a adaptação para imagens de ressonância magnética de 224×224 pixels em *RGB* e a utilização estratégica das diversas camadas de convolução e a camada *Soft-Max* para a classificação efetiva dos dados de imagem. Este enfoque prático visa não só reforçar o aprendizado teórico dos alunos, mas também prepará-los para aplicar esses conhecimentos em cenários reais, potencializando seu entendimento sobre as aplicações do aprendizado profundo na medicina.

4. Base de dados

Devido ao baixo número de dados fornecido pelo *kaggle*, aplicamos *Data Augmentation* para aumentar a diversidade do conjunto. As imagens foram redimensionadas e convertidas em matrizes com *numpy*, em seguida, foram realizadas operações como inversão, zoom, preenchimento e corte para aumentar os dados. Posteriormente, dividimos o conjunto em treinamento e teste.

Tabela 1. Principais resultados

MÉTRICAS	LOSS	ACURÁCIA
EFFICIENTNET B1	0,157	0,938
VGG16	0,426	0,848
VGG19	0,680	0,715

5. Resultados

De acordo com o trabalho desenvolvido, o código foi reproduzido no Google Colab utilizando diferentes extratores de características, como os modelos *EfficientNet-B1*, *VGG-16* e *VGG-19*. Esses modelos foram treinados e, posteriormente, comparados em termos de acurácia e perda, especificando qual seria o melhor com relação a essas métricas. Foram apresentadas as pastas que continham as imagens destinadas ao teste, ao treino e as imagens gerais. Posteriormente, ocorreu a entrada dos dados. Do conjunto de dados (*Dataset*), 80% foram utilizados para treino e 20% para teste.

No geral, o modelo *EfficientNet-B1* superou os outros dois modelos em termos de acurácia e perda, enquanto o *VGG-19* teve o desempenho mais fraco. O *VGG-16* apresentou uma acurácia relativamente alta, mas sua perda foi maior do que a do *EfficientNet-B1*. A análise também sugere que o modelo *VGG-19* pode ter sofrido de *overfitting*, pois sua acurácia ficou abaixo de 80%. Para futuros estudos, pretende-se melhorar os resultados do modelo *VGG-19*, buscando obter uma acurácia e perda mais favoráveis.

Os resultados destacam a importância de selecionar um modelo de aprendizado profundo robusto e bem-sucedido para aplicações médicas e para o aprendizado de alunos de graduação, como a classificação de tumores cerebrais. O *EfficientNet-B1* mostra-se promissor nesse sentido, mas pesquisas contínuas e refinamento dos modelos são necessários para garantir sua eficácia e confiabilidade na prática clínica.

6. Considerações Finais

Os experimentos conduzidos destacam a importância do uso de modelos de *Deep Learning* na detecção de tumores cerebrais. Pretendemos aprimorar os resultados obtidos, considerando o uso de arquiteturas mais avançadas e uma abordagem mais abrangente na revisão da literatura. A contribuição deste estudo está na proposição de um experimento aplicável em sala de aula, demonstrando o potencial dos modelos computacionais na área médica e no aprendizado dos alunos.

As principais limitações do estudo incluem o tamanho limitado do conjunto de dados disponível, que pode afetar a generalização dos resultados, e a falta de diversidade nas amostras de imagens de ressonância magnética, o que pode influenciar na representatividade dos modelos treinados. Além disso, a utilização de arquiteturas de redes neurais pré-treinadas pode introduzir viés nos resultados e limitar a capacidade de adaptação do modelo a diferentes conjuntos de dados. Essas limitações devem ser consideradas ao interpretar e aplicar os resultados deste estudo.

7. References

Referências

- Ahmad, J., Muhammad, K., Lee, M. Y., and Baik, S. W. (2017). Endoscopic image classification and retrieval using clustered convolutional features. *Journal of medical systems*, 41(12):1–12.
- Işın, A., Direkoğlu, C., and Şah, M. (2016). Review of mri-based brain tumor image segmentation using deep learning methods. *Procedia Computer Science*, 102:317–324.
- Koerich, A. H., de Campos Lana, G., Damin, S. D. A., and Hedel, M. A. (2024). Deep learning na segmentação de tumores cerebrais em ressonância magnética: uma revisão de literatura. *Cuadernos de Educación y Desarrollo*, 16(2 Edição Especial).
- Sengupta, N., McNabb, C. B., Kasabov, N., and Russell, B. R. (2018). Integrating space, time, and orientation in spiking neural networks: A case study on multimodal brain data modeling. *IEEE Transactions on neural Networks and Learning systems*, 29(11):5249–5263.
- Talebi, S., Gai, S., Sossin, A., Zhu, V., Tong, E., and Mofrad, M. R. (2024). Deep learning for perfusion cerebral blood flow (cbf) and volume (cbv) predictions and diagnostics. *Annals of Biomedical Engineering*, pages 1–8.
- Uema, J. and Silva, L. M. A. F. d. (2022). Deep learning aplicado a neuroimaging.