

Classificação de Tumor Cerebral utilizando *Deep Learning*

Ederson N. F. G. Júnior¹, Guilherme S. M. C. Paes¹, Pedro Silva¹

¹Departamento de Computação – Universidade Federal de Ouro Preto (UFOP)
35400-000 – Ouro Preto – MG – Brazil

{ederson.junior, guilherme.paes}@aluno.ufop.edu.br, silvap@ufop.edu.br

Abstract. *Classification of brain tumors is a crucial challenge in the field of medicine and aided by computer science. This study seeks to improve the identification of brain tumors through the use of Convolutional Neural Networks (CNN), specifically the EfficientNetB0 architecture. Using magnetic resonance images, a identification is conducted with an accuracy of 99,33%.*

Resumo. *A classificação de tumores cerebrais é um desafio crucial no campo da medicina e que pode ser auxiliada pela computação. Este estudo busca aprimorar a identificação de tumores cerebrais por meio do uso de Convolutional Neural Network (CNN), especificamente a arquitetura EfficientNetB0. Utilizando imagens de ressonância magnética, realizou-se a identificação com uma acurácia de 99,33%.*

1. Introdução

A detecção eficiente de tumores cerebrais é uma preocupação na área da saúde, exigindo abordagens avançadas para aprimorar a precisão e rapidez no processo do diagnóstico. A complexidade e diversidade dessas formações demandam soluções inovadoras, especialmente diante das limitações encontradas nos métodos tradicionais [Mohan and Subashini 2017].

A investigação sobre a classificação de tumores cerebrais, utilizando técnicas de aprendizado de máquina, encontra-se fundamentada em uma série de estudos e avanços significativos na interseção da medicina e da computação [Litjens et al. 2017]. A aplicação de técnicas como redes neurais convolucionais (*Convolutional Neural Networks* – CNN) busca identificar padrões em imagens médicas de tal forma a encontrar características que caracterizem um tumor, por exemplo [Pereira et al. 2019].

A importância da precisão na detecção de patologias, especialmente em casos de tumores cerebrais, tem sido um ponto central em estudos que exploram a aplicação de técnicas de CNN em radiologia [Litjens et al. 2017]. O principal objetivo é auxiliar médicos na detecção de doenças de forma precisa e de forma antecipada. As fontes desses dados podem ser variadas, como por exemplo, imagens de raio-x [Luz et al. 2023].

Há trabalhos que utilizam de imagens de radiografia para realizar a classificação entre doenças, como por exemplo, o trabalho proposto em [Ullah et al. 2023]. Os autores criaram uma nova arquitetura chamada *TumorDetNet*, na qual o autor faz o uso de 134 camadas em toda sua estrutura. Tais camadas são divididas em Camadas Convolucionais, normalizações, *dropout*, *pooling*, no qual ocorre a utilização de filtros 1x1 e 3x3, além da utilização de ativações *ReLU*, fazendo com que para essa base de dados o autor tenha 99,83% de acurácia nos resultados.

Outro exemplo é o trabalho desenvolvido em [Öksüz et al. 2022], o qual usou uma fusão de características de *Deep Learning* e abordagens convencionais para detectar tumores cerebrais. Combinou-se o modelo VGG-19 com o histograma de gradiente de orientação e *Local Binary Patterns* para a extração de características, de forma a identificar padrões e aumentar a precisão da abordagem.

Nesse contexto, esta pesquisa se propõe a explorar as potencialidades das redes neurais na classificação de tumores cerebrais. O principal objetivo é avaliar se a EfficientNetB0 [Tan and Le 2019], pode ser adaptada para a identificação de tumores cerebrais.

2. Metodologia

Neste estudo, foi utilizada como base a arquitetura a EfficientNetB0, a qual pode ser vista na Figura 1. A arquitetura EfficientNetB0 faz parte de uma família de arquiteturas que foram obtidas otimizando o tamanho e os blocos de *MBConv* (base da arquitetura) para atingir um equilíbrio entre desempenho e eficiência computacional. Essa arquitetura foi selecionada devido à sua alta acurácia em tarefas semelhantes e à sua capacidade de extrair padrões de imagens médicas complexas [Luz et al. 2023].

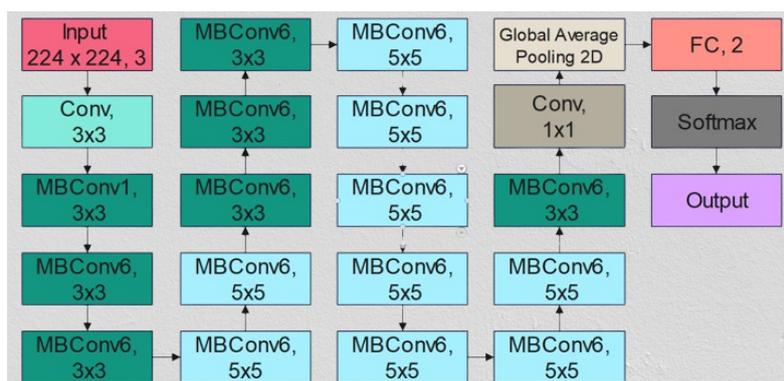


Figura 1. Arquitetura EfficientNetB0.

A metodologia deste trabalho pode ser dividida em duas principais etapas: pré-processamento dos dados e treinamento do modelo. No passo de pré-processamento foi feita a normalização dos dados para o intervalo de 0 a 1 dividindo os valores dos pixels das imagens por 255. As imagens também foram redimensionadas para 224×224 .

Tendo por base a arquitetura EfficientNetB0, adicionou-se duas camadas densas com ativação *ReLU* e 256 e 128 neurônios, respectivamente. Após isso, adicionou-se uma camada de *dropout* com 30% dos neurônios, e, por fim, mais duas camadas densas, ambas com ativação *ReLU* e 32 neurônios. A última camada do modelo é uma camada densa com dois neurônios e ativação *softmax*.

Ademais, utilizou-se a função de perda *Sparse Categorical Crossentropy* e o protocolo de redução de *learning rate* seguindo a estratégia de *Exponential Decay* com decaimento após uma taxa fixa de épocas e a um valor fixo. O otimizador dos pesos usado foi o Adam. Além disso, o modelo foi avaliado usando a métrica de acurácia, a qual pode ser definida como o total de acertos do modelo, dividido pelo total de amostras.

3. Experimentos

O modelo foi treinado por 70 épocas, com o *learning rate* inicial de 10^{-3} e decaimento a cada 27 épocas a uma taxa de 0,9. Para a execução dos algoritmos, foi utilizado uma máquina com 128Gb de RAM, uma RTX 3090 e o processador AMD Ryzen Threadripper 3960x. A linguagem utilizada foi o Python com o *framework* TensorFlow e o *Scikit-Learn*.

3.1. Base de dados - *Brain Tumor Detection MRI*

O conjunto de dados neste trabalho é “*Brain Tumor Detection MRI*”¹. O conjunto de dados contém imagens contendo tumores cerebrais ou não, no qual existem 3000 imagens com 1500 imagens sem tumor e 1500 com tumor. A Figura 2 apresenta exemplos da base de dados. A divisão de dados entre treinamento, validação e teste foi feita usando a razão de 72%, 8% e 20% respectivamente.

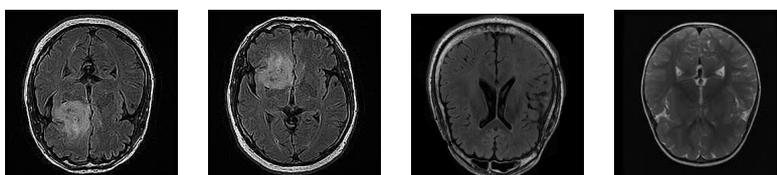


Figura 2. Exemplo da base de dados. As duas primeiras imagens são exemplos de tumor cerebral e as duas últimas, sem tumor.

3.2. Resultados

Na Tabela 1 são apresentados os resultados obtidos pelo trabalho proposto em relação a literatura. Apesar da redução da acurácia em relação ao trabalho visto em [Ullah et al. 2023], o presente trabalho apresenta resultados com uma diferença inferior a 1,2%, com um modelo utilizando um menor número de parâmetros (em torno de 20 milhões) em relação ao trabalho comparado, no qual o mesmo teve um alto número de parâmetros (em torno de 26 milhões), fazendo com que assim o presente trabalho esteja utilizando uma arquitetura menos custosa e com isso, o presente trabalho conseguiu uma acurácia de 99,33% com um desvio padrão de 0,0037 para 10 execuções desse modelo com sementes diferentes.

Trabalho	Acurácia (%)
[Ullah et al. 2023]	99,83
Trabalho Proposto	99,33 ± 0,0037

Tabela 1. Resultados para classificação binária de tumor e não tumor.

A Figura 3 apresenta a matriz de confusão do modelo treinado. É possível observar que a classificação de existência ou não de tumor foi quase perfeita, errando apenas quatro classificações de 600 imagens avaliadas.

¹Disponível em: <https://www.kaggle.com/datasets/abhranta/brain-tumor-detection-mri>. Acessado em 25 de janeiro de 2024

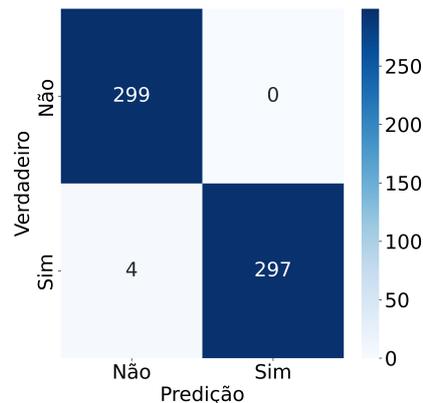


Figura 3. Matriz de confusão do modelo treinado.

4. Conclusão

Ao final deste estudo, explorou-se as capacidades da adaptação do modelo a Efficient-NetB0, na identificação de tumores cerebrais a partir de imagens de ressonância magnética. A acurácia de aproximadamente 99,33% na identificação de tumores cerebrais obtida, corrobora com a importância de técnicas de aprendizado de máquina na área médica e, mais especificamente, na identificação de tumores cerebrais. O cruzamento entre tecnologia e medicina abre novos horizontes, com potencial para impactar positivamente a saúde e o bem-estar de pacientes ao redor do mundo.

Referências

- Litjens, G., Ciompi, F., Ghahfoorian, M., Bulten, W., Miesnerberger, K., Gonçalves, A., Zuidhof, G., and Sánchez, C. I. (2017). Deep learning in radiology: An overview of the concepts and a survey of the state of the art. *Journal of Magnetic Resonance Imaging*, 46(3):872–879.
- Luz, E., Silva, P., Silva, R., Silva, L., Moreira, G., and Menotti, D. (2023). Towards an effective and efficient deep learning model for covid-19 patterns detection in x-ray images. 2020. [arXiv preprint arXiv:2004.05717](https://arxiv.org/abs/2004.05717).
- Mohan, G. and Subashini, M. (2017). Análise de imagem médica baseada em ressonância magnética: pesquisa sobre a classificação do grau do tumor cerebral. *MRI based medical image analysis: Survey on brain tumor grade classification*.
- Pereira, M. F. S., Leite, C. A., Oliveira, L. S., de M. Lima, A. A., Anelli, R., and Martins, A. F. M. (2019). A survey on deep learning in medical image analysis. *Journal of Health Informatics*, 11(3):120–136.
- Tan, M. and Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, pages 6105–6114. PMLR.
- Ullah, N., Javed, A., Alhazmi, A., Hasnain, S. M., Tahir, A., and Ashraf, R. (2023). Tumordetnet: A unified deep learning model for brain tumor detection and classification. *Plos one*, 18(9):e0291200.
- Öksüz, C., Urhan, O., and Güllü, M. K. (2022). Brain tumor classification using the fused features extracted from expanded tumor region. *Biomedical Signal Processing and Control*, 72:103356.