

# Classificação de Tumores Cerebrais utilizando uma Rede Neural Convolutacional

Lucas Costa Lima Ferreira<sup>1</sup>, Angela Leite Moreno<sup>2</sup>  
UNIFAL-MG, Alfenas, MG

De acordo com recentes relatórios da OMS, o câncer é a segunda principal causa de morte globalmente. Tumores cerebrais e do sistema nervoso central ocupam a décima segunda posição no ranking de mortalidade por câncer [6], com meningiomas, gliomas e tumores hipofisários sendo os mais prevalentes na população. Para a identificação de tais tumores, diversas técnicas de imagens médicas são empregadas para obter informações sobre tumores, incluindo tipo, forma, tamanho e localização, entre essas técnicas, a Imagem por Ressonância Magnética (MRI) é a mais comumente utilizada. As principais dificuldades no reconhecimento dos tipos de tumores cerebrais estão associadas às irregularidades anatômicas e variações nos layouts nos planos sagital, axial e coronal [1]. Diante desses desafios, o advento do aprendizado profundo (*Deep Learning*) teve um impacto significativo no desenvolvimento de técnicas que possibilitaram a classificação de imagens médicas com alta precisão [3].

Dentre as técnicas de aprendizado profundo utilizadas para a classificação de imagens, as Redes Neurais Convolucionais (Convolutional Neural Networks - CNNs) têm tido destaque. Dentre as camadas da rede de aprendizado profundo, as camadas de convolução possuem filtros que extraem características relevantes da imagem e geralmente são seguidas de camadas de *pooling* que reduzem o tamanho da imagem (geralmente pela metade). Por fim, as camadas densas servem para fazer conexões entre as características extraídas antes da classificação final. Deste modo, este trabalho apresenta os resultados obtidos por uma Rede Neural Convolutacional para o problema de classificação de tumor cerebral.

O conjunto de dados contendo as imagens utilizado foi disponibilizado na plataforma Kaggle [4]. Tal conjunto é organizado em dois diretórios distintos, um deles com imagens a serem usadas durante a fase de treino e o outro para o processo de teste, ambos organizados em outros quatro diretórios: *notumor*, *meningioma*, *pituitary* e *glioma*. A primeira categoria refere-se a tomografias de cérebros sem a presença de tumores, enquanto as demais representam imagens de tumores como adenoma de hipófise, glioma ou meningioma. A Figura 1 apresenta uma imagem de cada classe.




Figura 1: Exemplos de imagens contidas no conjunto de dados. Fonte: adaptado de Nickparvar.

<sup>1</sup>lucascosta.ferreira@sou.unifal-mg.edu.br

<sup>2</sup>angela.moreno@unifal-mg.edu.br

Ao avaliar o modelo proposto no conjunto de teste, a acurácia alcançou um ótimo valor de 95,27%. Esse nível de acurácia se mostra superior à outras redes neurais convolucionais genéricas [2, 5] e também apresenta performance maior do que a *EfficientNet*, modelo pré-treinado de visão computacional [2]. Além da acurácia, foram utilizadas as métricas precisão, sensibilidade e F1-score, conforme pode ser visto na Tabela 1.

Tabela 1: Valores de Precisão, Sensibilidade e F1-Score para cada uma das classes das imagens.

Métricas	Sem tumor	Meningioma	Adenoma de hipófise	Glioma
<b>Precisão</b>	96,66%	91,84%	96,14%	95,82%
<b>Sensibilidade</b>	100,00%	88,24%	99,67%	99,67%
<b>F1-Score</b>	98,30%	89,99%	97,87%	93,70%

É possível observar que o modelo, no geral, obteve uma performance satisfatória. A dificuldade principal da rede está em distinguir meningiomas das demais classes, problema que pode ser o foco de trabalhos futuros.

Concluindo, os resultados obtidos destacam a eficácia do modelo desenvolvido na classificação precisa de imagens de ressonância magnética para identificação de diferentes tipos de tumores cerebrais. As métricas de acurácia, precisão e sensibilidade demonstram consistentemente um alto índice de desempenho, mesmo com uma arquitetura relativamente simples, composta apenas por três camadas de convolução e uma camada densa. A ausência da necessidade de técnicas avançadas de processamento de imagens, como detecção de bordas e outras técnicas, ressalta a praticidade dessa abordagem, tornando-a particularmente interessante na implementação de sistemas médicos escaláveis.

## Referências

- [1] L. Ferariu e E.-D. Neculau. “Fusing Convolutional Neural Networks with Segmentation for Brain Tumor Classification”. Em: **2021 25th International Conference on System Theory, Control and Computing (ICSTCC)**. 2021, pp. 249–254. DOI: 10.1109/ICSTCC52150.2021.9607260.
- [2] D. Filatov e G. N. A. H. Yar. “Brain Tumor Diagnosis and Classification via Pre-trained Convolutional Neural Networks”. Em: **arXiv preprint arXiv:2208.00768** (2022). DOI: 10.48550/arXiv.2208.00768.
- [3] M. A. Mazurowski, M. Buda, A. Saha e M. R. Bashir. “Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI”. Em: **Journal of Magnetic Resonance Imaging** 4 (2019), pp. 939–954. DOI: 10.1002/jmri.26534.
- [4] M. Nickparvar. **Brain Tumor MRI Dataset**. Online. Acessado em 06/11/2024, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>.
- [5] S. Shetty e J. Shetty. “Classification of Brain Tumor using Convolutional Neural Networks”. Em: **International Journal of Engineering and Advanced Technology** 3 (2020), pp. 2841–2845. DOI: 10.35940/ijeat.c5995.029320.
- [6] H. Sung, J. Ferlay, R. L. Siegel, M. Laversanne, I. Soerjomataram, A. Jemal e F. Bray. “Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries”. Em: **CA: A Cancer Journal for Clinicians** 3 (2021), pp. 209–249. DOI: 10.3322/caac.21660.