



III CONGRESSO BRASILEIRO EM BIOCIÊNCIAS APLICADAS À SAÚDE

CLASSIFICAÇÃO DE TUMORES CEREBRAIS POR IMAGEM: SINERGIA ENTRE DEEP LEARNING E MACHINE LEARNING

Lucas Costa Lima Ferreira, Angela Leite Moreno, Ricardo Menezes Salgado

*Universidade Federal de Alfenas, Instituto de Ciências Exatas, Departamento de Ciência da
Computação, Bacharelado em Ciência da Computação*

lucascosta.ferreira@sou.unifal-mg.edu.br

Os tumores cerebrais representam uma condição médica crítica, constituindo aproximadamente 88% das neoplasias malignas do sistema nervoso central. O diagnóstico precoce e preciso desses tumores por meio de imagens de ressonância magnética (RM) são fundamentais para o planejamento terapêutico eficaz. No entanto, este processo permanece desafiador devido à complexidade anatômica e à variabilidade na qualidade das imagens. O presente estudo propõe uma abordagem baseada em inteligência artificial para a classificação automática de tumores cerebrais em quatro categorias: meningioma, glioma, adenoma hipofisário e ausência de tumor. A metodologia empregada baseou-se no uso da *EfficientNetB0*, uma arquitetura de Rede Neural Convolutiva (RNC), com aproximadamente 22 milhões de parâmetros pré-treinados no dataset ImageNet. Este modelo foi submetido a um processo de *fine-tuning* para adaptá-lo ao contexto específico da classificação de tumores cerebrais. O conjunto de dados utilizado, obtido da plataforma Kaggle, compreende 7023 imagens de RM, divididas 80% para treinamento e validação da rede, e 20% para avaliação final do desempenho. Durante a fase de treinamento, diversos tamanhos de lote foram avaliados, sendo o lote de 64 imagens identificado como o mais eficaz no conjunto de validação. Para otimizar o desempenho do modelo e mitigar riscos de *overfitting*, duas técnicas cruciais foram implementadas: *early stopping* e redução da taxa de aprendizado no platô. O *early stopping* foi configurado para interromper o treinamento após cinco épocas consecutivas sem melhoria no erro de validação, prevenindo assim o ajuste excessivo aos dados de treino. Paralelamente, a taxa de aprendizado era reduzida por um fator de 0,1 quando o erro de validação permanecia estagnado por três épocas consecutivas. O processo de otimização foi realizado com o algoritmo Adam, iniciando com uma taxa de aprendizado de 0,0003, que foi subsequentemente reduzida em duas ocasiões distintas durante o treinamento. Após o *early stopping*, uma etapa adicional de *fine-tuning* foi realizada, iniciando com uma taxa de aprendizado ajustada para 0,00001. Uma vez concluído o ajuste fino da rede, esta foi utilizada como extrator de características. Essas características foram então empregadas para treinar três classificadores clássicos de *machine learning*: *Random Forest Classifier*, *Logistic Regression* e *Support Vector Classifier*. A avaliação desses classificadores foi realizada no conjunto de testes composto por 1311 imagens. Os resultados obtidos foram notáveis, com a regressão logística emergindo como o classificador de melhor desempenho. Este modelo alcançou uma acurácia de 99,85% e uma sensibilidade média entre as classes de 99,75%. Tais métricas representam um avanço significativo no campo da classificação de tumores cerebrais. Este estudo se destaca pela utilização de um extenso conjunto de imagens e pela obtenção de uma alta acurácia, resultado da combinação entre uma arquitetura de RNC estado da arte para extração de características e *Machine Learning*. A abordagem proposta não apenas demonstra alta precisão na classificação de tumores cerebrais, mas também oferece potencial para aplicação clínica, auxiliando médicos no diagnóstico rápido e preciso, de modo que o tratamento seja iniciado mais rapidamente e resulte em melhores desfechos para os pacientes.

Palavras-chave: Inteligência Artificial, Rede Neural Convolutiva, Diagnóstico Médico Assistido, Diagnóstico por Imagem.