

COMPARAÇÃO ENTRE DIFERENTES CONFIGURAÇÕES DE REDES NEURAIS CONVOLUCIONAIS PARA DETECÇÃO E CLASSIFICAÇÃO DE TUMORES CEREBRAIS ATRAVÉS DE IMAGENS DE RESSONÂNCIA MAGNÉTICA DO CRÂNIO

Edgar de Oliveira Cabral Filho¹; Cassiana Fagundes da Silva²

¹ Faculdade de Tecnologia Senac São José dos Pinhais. (edgar.filho@docente.pr.senac.br).

² Faculdade de Tecnologia Senac São José dos Pinhais. (cassiana.silva@docente.pr.senac.br).

Resumo: O avanço da inteligência artificial, especialmente no campo do aprendizado profundo, tem possibilitado importantes aplicações na área da saúde, com destaque para o uso de redes neurais convolucionais na análise e classificação de imagens médicas. No contexto do diagnóstico de tumores cerebrais, a utilização de imagens de ressonância magnética aliada a técnicas de visão computacional representa uma alternativa promissora para o apoio à tomada de decisão clínica. O presente trabalho teve como objetivo analisar e comparar o desempenho de diferentes arquiteturas de redes neurais convolucionais, bem como distintas configurações de hiperparâmetros, na tarefa de classificação de tumores cerebrais a partir de imagens de ressonância magnética, avaliando o impacto dessas escolhas na acurácia e na capacidade de generalização dos modelos selecionados. A metodologia adotada baseou-se na utilização de bases de dados públicas contendo imagens de ressonância magnética do crânio, totalizando aproximadamente 6.300 imagens, distribuídas entre as classes glioma, meningioma, tumor de pituitária e ausência de tumor, as quais foram subdivididas em conjuntos de treinamento, validação e teste. As imagens passaram por etapas de pré-processamento que incluíram redimensionamento para dimensões padronizadas, normalização dos valores de pixels para o intervalo [0,1] e codificação dos rótulos. Foram implementadas três arquiteturas de redes neurais convolucionais: LeNet-5, AlexNet e ResNet, utilizando as bibliotecas TensorFlow e Keras. O treinamento foi conduzido por meio da técnica de validação cruzada *K-Fold* com cinco partições, empregando o otimizador Adam, função de perda *sparse categorical crossentropy*, taxa de aprendizado padrão e número fixo de épocas por *fold*. As métricas utilizadas para avaliação do desempenho foram acurácia, precisão, *recall*, *F1-score* e matriz de confusão. Arquiteturas mais profundas, como VGGNet e Xception, não puderam ser treinadas em razão de limitações computacionais, caracterizadas principalmente por insuficiência de memória. Os resultados obtidos evidenciaram diferenças significativas de desempenho entre as arquiteturas avaliadas. O modelo LeNet-5 apresentou o melhor desempenho global, alcançando aproximadamente 93% de acurácia, demonstrando boa capacidade de generalização mesmo com uma arquitetura menos complexa. A ResNet obteve acurácia em torno de 90%, contudo apresentou indícios de sobreajuste, observados pela discrepância entre desempenho em treinamento e testes de classificação. Por outro lado, a AlexNet apresentou desempenho insatisfatório, com acurácia inferior a 30%, mostrando dificuldades relevantes na classificação multiclasse, especialmente na identificação dos diferentes tipos de tumores. A análise comparativa, apoiada por matrizes de confusão e relatórios de classificação, indicou que arquiteturas mais simples, quando corretamente configuradas e treinadas com um volume adequado de dados, podem superar modelos mais complexos em ambientes com restrições de

recursos computacionais. Conclui-se que a escolha da arquitetura e da configuração dos hiperparâmetros exerce influência direta no desempenho de redes neurais convolucionais aplicadas à classificação de tumores cerebrais. O estudo evidencia a viabilidade do uso de CNNs para análise de imagens médicas, ao mesmo tempo em que ressalta a importância de recursos computacionais adequados, da apresentação sistematizada dos resultados e de abordagens metodológicas rigorosas para garantir a validade científica dos achados.

Palavras-chave: Aprendizado Profundo; Redes Neurais Convolucionais; Tumores Cerebrais; Ressonância Magnética; Classificação de Imagens.