

Análise Comparativa de Arquiteturas de Aprendizado Profundo na Classificação de Tumores Cerebrais

Edriane do Socorro Silva Costa¹, José Jailton Henrique Ferreira Junior¹

¹Faculdade de Computação – Universidade Federal do Pará (UFPA)
Caixa Postal 479, CEP: 66075-110, Castanhal – PA – Brasil

edrianescosta@gmail.com, jjj@ufpa.br

Abstract. *This work presents a comparative analysis of CNN architectures applied to the classification of brain tumors in magnetic resonance images. A generic model and transfer learning-based models were evaluated, using the VGG16 and ResNet101 architectures. The dataset underwent preprocessing and data augmentation steps, and the models were evaluated using metrics such as accuracy, precision, recall, and F1-score. The results demonstrated high performance of the proposed approaches, with emphasis on the ResNet101 architecture. The findings highlight the potential of deep learning as a support tool for computer-aided diagnosis.*

Resumo. *Este trabalho apresenta uma análise comparativa de arquiteturas de CNNs aplicadas à classificação de tumores cerebrais em imagens de ressonância magnética. Foram avaliados um modelo genérico e modelos baseados em transfer learning, utilizando as arquiteturas VGG16 e ResNet101. O conjunto de dados passou por etapas de pré-processamento e aumento de dados, sendo os modelos avaliados por métricas como acurácia, precisão, revocação e F1-score. Os resultados demonstraram elevado desempenho das abordagens propostas, com destaque para a arquitetura ResNet101. Os achados evidenciam o potencial do aprendizado profundo como ferramenta de apoio ao diagnóstico assistido por computador.*

1. Introdução

O câncer constitui uma das principais causas de morbidade e mortalidade em todo o mundo, representando um desafio significativo para os sistemas de saúde. Entre os diferentes tipos de neoplasias, os tumores cerebrais destacam-se pela complexidade do diagnóstico e pelo impacto direto nas funções neurológicas dos pacientes [Nasralla and Pitta 2024]. De acordo com a Organização Mundial da Saúde, os tumores do sistema nervoso central apresentam elevada taxa de mortalidade e exigem diagnóstico precoce e preciso para aumentar as chances de tratamento eficaz [World Health Organization 2023]. Nesse contexto, exames de imagem, como a ressonância magnética (MRI), desempenham papel fundamental na identificação e caracterização dessas lesões.

A análise de imagens de ressonância magnética cerebral, no entanto, demanda alto grau de especialização e está sujeita à variabilidade interpretativa entre profissionais. Diante desse cenário, o Diagnóstico Assistido por Computador (DAC) surge como uma alternativa promissora para apoiar a tomada de decisão clínica, reduzindo a subjetividade

e aumentando a confiabilidade diagnóstica [da Silva 2025]. O avanço das técnicas de inteligência artificial, especialmente do aprendizado profundo, tem impulsionado o desenvolvimento de sistemas capazes de identificar padrões complexos em imagens médicas, tornando o tema altamente relevante tanto do ponto de vista científico quanto clínico [Leite and Gambarato 2022, da Silva 2025, Nasralla and Pitta 2024].

Assim sendo, o objetivo deste trabalho é avaliar o desempenho de diferentes arquiteturas de redes neurais convolucionais na classificação de tumores cerebrais em imagens de ressonância magnética. Especificamente, busca-se comparar uma rede neural convolucional desenvolvida do zero com modelos baseados em *transfer learning*, utilizando as arquiteturas VGG16 e ResNet101, a fim de analisar o impacto da complexidade do modelo e do reaproveitamento de pesos pré-treinados na acurácia e na capacidade de generalização.

Para atingir esse objetivo, foi utilizado um conjunto de dados público contendo imagens de MRI cerebral organizadas em quatro classes distintas. As imagens passaram por etapas de pré-processamento e aumento de dados, sendo posteriormente utilizadas no treinamento e na avaliação dos modelos propostos. O desempenho foi analisado por meio de métricas como acurácia, precisão, revocação, F1-score e matriz de confusão.

Por fim, este trabalho está estruturado da seguinte forma: além desta seção de introdução, o Capítulo de Referencial Teórico apresenta os conceitos fundamentais relacionados ao diagnóstico assistido por computador, aprendizado de máquina, redes neurais convolucionais e técnicas de *transfer learning*. Em seguida, a seção Revisão Bibliográfica, apresenta as explorações a cerca do tema com outros trabalhos. Após isso, a seção de Metodologia descreve detalhadamente os procedimentos adotados para a condução dos experimentos. A seção de Resultados e Discussões apresenta e analisa os resultados obtidos, enquanto a seção de Considerações Finais sintetiza as conclusões do estudo e aponta possibilidades para trabalhos futuros.

2. Referencial Teórico

Esta seção apresenta os principais conceitos teóricos e fundamentos científicos relacionados ao diagnóstico assistido por computador, ao uso de imagens de ressonância magnética cerebral e às técnicas de aprendizado profundo empregadas na classificação de tumores cerebrais, fornecendo o embasamento necessário para o desenvolvimento deste trabalho.

2.1. Diagnóstico Assistido por Computador em MRI Cerebral

O Diagnóstico Assistido por Computador (DAC) tem se consolidado como uma ferramenta essencial no apoio à análise de imagens médicas, empregando técnicas de inteligência artificial para auxiliar na identificação e classificação de padrões patológicos [da Silva 2025]. No contexto das imagens de ressonância magnética cerebral, o DAC contribui para a redução da subjetividade na interpretação visual e para o aumento da precisão diagnóstica, especialmente em aplicações relacionadas à detecção de tumores cerebrais [Leite and Gambarato 2022, da Silva 2025].

A ressonância magnética do cérebro, por sua vez, destaca-se por fornecer imagens com elevado contraste e resolução espacial, possibilitando a análise detalhada das estruturas cerebrais. No entanto, a variabilidade das imagens, a presença de ruídos e a semelhança visual entre diferentes patologias representam desafios para a

análise automática. Nesse cenário, métodos baseados em aprendizado profundo têm se mostrado promissores ao permitir a extração automática de características relevantes, fortalecendo a aplicação do diagnóstico assistido por computador em MRI cerebral [Nasralla and Pitta 2024].

2.2. Aprendizado de Máquina e Aprendizado Profundo aplicados à Análise de Imagens Médicas

O aprendizado de máquina constitui uma área da inteligência artificial voltada ao desenvolvimento de modelos capazes de aprender padrões a partir de dados, sem a necessidade de programação explícita. Dentro desse contexto, o aprendizado profundo destaca-se por empregar arquiteturas baseadas em redes neurais profundas, capazes de modelar relações complexas e não lineares. Essas abordagens têm sido amplamente adotadas em diferentes domínios devido ao aumento da capacidade computacional e à disponibilidade de grandes volumes de dados, consolidando-se como ferramentas centrais em sistemas inteligentes modernos [Gabriel Filho 2023, Arão 2024].

No aprendizado supervisionado, os modelos são treinados a partir de conjuntos de dados rotulados, aprendendo a mapear entradas para saídas conhecidas. Um dos problemas mais comuns nesse paradigma é a classificação multiclasse, na qual o objetivo consiste em atribuir corretamente cada amostra a uma dentre várias classes possíveis. Esse tipo de abordagem é particularmente relevante em aplicações médicas, nas quais diferentes patologias ou condições clínicas devem ser distinguidas de forma automática e confiável [Leite and Gambarato 2022, da Silva 2025].

As aplicações do aprendizado profundo em imagens médicas têm apresentado resultados expressivos, sobretudo em tarefas de classificação, segmentação e detecção de anomalias. Redes neurais convolucionais, em especial, demonstram elevada capacidade de extração automática de características visuais relevantes, reduzindo a dependência de métodos manuais. No contexto das imagens de ressonância magnética cerebral, essas técnicas têm se mostrado promissoras ao lidar com a complexidade visual e a variabilidade dos dados, fortalecendo o uso do diagnóstico assistido por computador como ferramenta de apoio à prática clínica [Nasralla and Pitta 2024, Arão 2024].

2.3. Redes Neurais Convolucionais e Transfer Learning

As Redes Neurais Convolucionais (CNNs) constituem uma das principais abordagens do aprendizado profundo para o processamento e análise de imagens, sendo especialmente eficazes na extração automática de características visuais hierárquicas [Nasralla and Pitta 2024]. Essas redes utilizam operações de convolução para capturar padrões locais, como bordas, texturas e formas, permitindo o aprendizado progressivo de representações cada vez mais abstratas [Leite and Gambarato 2022].


No contexto de imagens médicas, o uso de CNNs desenvolvidas do zero pode apresentar limitações relacionadas à quantidade restrita de dados rotulados disponíveis. Para contornar esse desafio, a técnica de *transfer learning* tem sido amplamente adotada, consistindo no reaproveitamento de modelos previamente treinados em grandes bases de dados, como o ImageNet [Gabriel Filho 2023, da Silva 2025]. Essa abordagem permite que características genéricas aprendidas em outros domínios sejam adaptadas para problemas específicos, reduzindo o tempo de treinamento e melhorando a capacidade de generalização dos modelos.

A combinação entre redes neurais convolucionais e *transfer learning* tem se mostrado particularmente promissora em aplicações de diagnóstico assistido por computador, uma vez que possibilita alto desempenho mesmo em cenários com dados limitados e elevada variabilidade [Arão 2024].

2.4. Arquiteturas de Redes Neurais Utilizadas

As redes neurais convolucionais desenvolvidas do zero baseiam-se nos princípios fundamentais das CNNs introduzidas por LeCun et al., inicialmente propostas para reconhecimento de padrões em imagens [LeCun et al. 1998]. Essa arquitetura é composta por camadas convolucionais intercaladas com camadas de pooling e camadas totalmente conectadas, permitindo a extração hierárquica de características visuais, conforme disposto na Figura 1. No presente trabalho, essa abordagem foi empregada como modelo base, possibilitando avaliar a capacidade de aprendizado direto a partir dos dados, sem o uso de conhecimento prévio oriundo de bases externas.


Figura 1. Arquitetura genérica de uma rede neural convolucional.



Fonte: [Barbosa et al. 2021]

Já a arquitetura do modelo de CNN VGG16, exemplificada na Figura 2 foi proposta por Simonyan e Zisserman [Simonyan and Zisserman 2014] e caracteriza-se por sua profundidade e simplicidade estrutural, utilizando blocos sequenciais de convoluções com filtros de pequeno tamanho. Essa arquitetura tornou-se amplamente utilizada como base para *transfer learning*, devido à sua eficácia na extração de características visuais genéricas. No contexto deste trabalho, a VGG16 foi empregada com pesos pré-treinados, permitindo avaliar os ganhos proporcionados pelo reaproveitamento de conhecimento previamente aprendido.


Figura 2. Visão geral da arquitetura VGG16.



Fonte: [Rohini 2021]

Por sua vez, a arquitetura ResNet101 foi introduzida por He et al. [He et al. 2016] e destaca-se pelo uso de conexões residuais, que permitem o treinamento eficiente de redes extremamente profundas. Essas conexões reduzem problemas como o desaparecimento do gradiente, possibilitando o aprendizado de representações mais complexas. A ResNet101 foi utilizada neste trabalho por sua elevada capacidade de generalização, permitindo investigar o impacto de arquiteturas profundas no desempenho da classificação de tumores cerebrais em imagens de ressonância magnética.

Figura 3. Estrutura simplificada da arquitetura ResNet101 com conexões residuais.



Fonte: [Kalshetty and Parveen 2023]

2.5. Classes de Tumores Cerebrais Consideradas

A classe Glioma refere-se a tumores originados das células gliais do sistema nervoso central, sendo considerados os tumores cerebrais primários mais comuns. Os gliomas podem variar em grau de malignidade e apresentam crescimento infiltrativo, o que dificulta sua delimitação precisa em exames de imagem. Em imagens de ressonância magnética, esses tumores frequentemente apresentam heterogeneidade de intensidade e bordas pouco definidas, tornando sua classificação automática um desafio relevante [Louis et al. 2021].

A classe Meningioma corresponde a tumores que se desenvolvem a partir das meninges, as membranas que envolvem o cérebro e a medula espinhal. Em geral, são tumores de crescimento lento e, na maioria dos casos, benignos. Em exames de MRI, os meningiomas tendem a apresentar margens bem definidas e contraste relativamente homogêneo, características que auxiliam tanto o diagnóstico clínico quanto a análise automatizada [Whitfield and Bruneau 2020].

A classe Hipófise refere-se a tumor hipofisário, engloba neoplasias que se originam na hipófise, glândula responsável pela regulação hormonal do organismo. Esses tumores podem provocar alterações hormonais significativas e sintomas neurológicos dependendo de seu tamanho e localização. Em imagens de ressonância magnética, os tumores hipofisários apresentam características específicas relacionadas à região selar, exigindo atenção especial na distinção entre tecidos normais e anormais [Melmed 2017].

Por fim, a classe Sem tumor representa imagens de ressonância magnética que não apresentam evidências de lesões tumorais. Essa classe é fundamental para o treinamento de modelos de classificação, pois permite distinguir padrões anatômicos normais daqueles associados a patologias. A correta identificação dessa classe contribui para a redução de falsos positivos e para o aumento da confiabilidade dos sistemas de diagnóstico assistido por computador [Nasralla and Pitta 2024].

2.6. Avaliação de Modelos de Classificação

A avaliação de modelos de classificação baseia-se na comparação entre os rótulos previstos pelo modelo e os rótulos reais das amostras, sendo a matriz de confusão uma das principais ferramentas para essa análise. A matriz de confusão organiza os resultados em termos de verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN), permitindo uma análise do comportamento do classificador em cada classe [Powers 2011].

A partir da matriz de confusão, diversas métricas podem ser derivadas. A *acurácia* mede a proporção total de classificações corretas e é definida como:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

A *precisão* (também denominada *valor preditivo positivo*) indica a proporção de predições positivas corretas:

$$Precisão = \frac{TP}{TP + FP} \quad (2)$$

Já a *revocação*, também conhecida como *sensibilidade* ou *taxa de verdadeiros positivos*, mede a capacidade do modelo em identificar corretamente as amostras positivas:

$$Revocação = \frac{TP}{TP + FN} \quad (3)$$

O *F1-score* consiste na média harmônica entre precisão e revocação, sendo particularmente útil quando se busca um equilíbrio entre essas métricas:

$$F1 - score = 2 \cdot \frac{Precisão \cdot Revocação}{Precisão + Revocação} \quad (4)$$

3. Revisão Bibliográfica

Um estudo recente desenvolvido por Wong et al. (2025) explorou um sistema de classificação de tumores cerebrais baseado em ressonância magnética utilizando a arquitetura pré-treinada VGG16 com *transfer learning*. No trabalho, os autores utilizaram um grande conjunto de dados com mais de 17 mil imagens distribuídas entre as classes glioma, meningioma, pituitary e no tumor, aplicando técnicas de aumento de dados e ajuste fino (*fine-tuning*) para melhorar a capacidade de extração de características. Os resultados alcançaram uma acurácia global de 99,24%, indicando alto potencial do modelo para auxiliar no diagnóstico clínico automatizado [Wong et al. 2025].

Por outro lado, Kathuria et al. (2025) apresentaram um estudo focado no desempenho da arquitetura ResNet101 em comparação com outras redes profundas para classificação de tumores cerebrais. Utilizando *transfer learning* e treinamento sobre conjuntos públicos de MRI, o trabalho demonstrou que o modelo ResNet101 obteve uma acurácia extremamente elevada (99,94%), superando diversas outras arquiteturas avaliadas. O estudo ressalta a grandeza das conexões residuais profundas e a efetividade do

ResNet101 em lidar com dados visuais complexos como os de ressonância magnética [Kathuria et al. 2025].

Além das abordagens com *transfer learning*, Alemayehu (2025) propôs uma CNN genérica leve para classificação de quatro classes de tumores cerebrais com base em MRI, utilizando técnicas de pré-processamento, normalização, aumento de dados e validação cruzada em cinco dobras para evitar sobreajuste. Esse modelo alcançou uma acurácia de 98,78%, destacando que redes convolucionais personalizadas, mesmo com menor complexidade computacional, podem atingir desempenho competitivo em tarefas de diagnóstico assistido por computador [Alemayehu 2025].

Comparando os três estudos, observa-se que tanto modelos baseados em *transfer learning* (VGG16 e ResNet101) quanto arquiteturas CNN genéricas podem alcançar resultados elevados em classificação de tumores cerebrais. No entanto, a literatura tende a favorecer arquiteturas profundas com ajuste fino quando há grandes volumes de dados disponíveis. O presente trabalho engloba essas três vertentes ao comparar diretamente uma CNN desenvolvida do zero com modelos VGG16 e ResNet101, proporcionando uma análise mais abrangente e direta do impacto da complexidade arquitetural e das estratégias de *transfer learning* no desempenho de classificação multiclases em MRI cerebral.

A fim de sintetizar as principais características dos trabalhos analisados, a Tabela 1 apresenta uma comparação entre os estudos quanto aos seus objetivos, lacunas identificadas, bases de dados utilizadas e tipos de arquiteturas empregadas.

Tabela 1. Comparação dos trabalhos relacionados na literatura

Autor (Ano)	Objetivo do Trabalho	Lacuna Identificada	Banco de Dados Utilizado	Tipo de Arquitetura
Wong et al. (2025)	Classificar tumores cerebrais em MRI com VGG16 via transfer learning.	Demanda por modelos robustos para apoio ao diagnóstico em grandes bases.	>17 mil imagens de MRI (glioma, meningioma, pituitary, no tumor).	VGG16 pré-treinada (transfer learning + fine-tuning).
Kathuria et al. (2025)	Comparar ResNet101 a outras redes profundas na classificação em MRI.	Avaliar ganhos de conexões residuais em desempenho e generalização.	Conjuntos públicos de MRI cerebral.	ResNet101 pré-treinada (transfer learning).
Alemayehu (2025)	Propor CNN leve para classificação multiclases de tumores em MRI.	Reduzir custo computacional mantendo desempenho competitivo.	Dataset público de MRI cerebral (4 classes).	CNN do zero (arquitetura leve personalizada).

Embora os estudos analisados evidenciem o elevado potencial de arquiteturas profundas e modelos pré-treinados, especialmente em cenários com grandes bases de dados, observa-se que o *trade-off* entre desempenho, complexidade computacional e capacidade de generalização ainda constitui um ponto relevante de investigação. Assim, ao comparar diretamente uma CNN desenvolvida do zero com modelos VGG16 e ResNet101, o presente trabalho busca aprofundar a compreensão sobre esse equilíbrio, contribuindo para a identificação de soluções adequadas a diferentes contextos computacionais e clínicos.

4. Metodologia

Esta seção descreve o processo metodológico adotado para o desenvolvimento do sistema de classificação de tumores cerebrais a partir de imagens de ressonância magnética, abrangendo desde a preparação dos dados até a avaliação dos modelos propostos.


4.1. Base de Dados

O conjunto de dados utilizado neste trabalho foi o *Brain Tumor MRI Dataset*, disponibilizado publicamente na plataforma *Kaggle*. A escolha desse banco de dados deve-se ao fato de ele ser amplamente empregado em pesquisas na área de diagnóstico assistido por computador, além de conter imagens de ressonância magnética (MRI) do cérebro humano devidamente rotuladas por especialistas. Ademais, o conjunto de dados atende aos requisitos éticos, uma vez que as imagens são anonimizadas, preservando a identidade dos pacientes conforme as diretrizes dos comitês de ética.

O dataset é composto por quatro classes distintas, rotuladas como: *glioma*, *meningioma*, *pituitary tumor* e *no tumor*, onde neste trabalho serão atribuídas as classes em língua portuguesa, sendo, portanto, tomadas como: glioma, meningioma, hipófise e não tumor. As imagens estão organizadas em diretórios correspondentes a cada classe, o que possibilita a associação direta entre cada imagem e seu respectivo rótulo. O conjunto de dados encontra-se previamente dividido em duas partições principais: um conjunto de *treinamento* e um conjunto de *teste*, garantindo uma separação explícita entre os dados utilizados para o aprendizado dos modelos e aqueles destinados à avaliação final.

A Figura 4 apresenta exemplos representativos das imagens pertencentes a cada uma das classes. Observa-se uma expressiva variabilidade visual entre as categorias, tanto no que se refere à presença e à localização dos tumores quanto às características de contraste, formato e intensidade das imagens, o que evidencia a complexidade do problema de classificação.

Figura 4. Exemplos de imagens das diferentes classes do conjunto de dados.



Em relação à distribuição das classes, o conjunto de dados não é perfeitamente balanceado. No conjunto de treinamento, a classe *não tumor* apresenta o maior número de amostras, totalizando 1.595 imagens, seguida pelas classes *hipófise* e *glioma*, com 1.457 e 1.339 imagens, respectivamente. A classe *meningioma* possui o menor número de amostras, com 1.321 imagens. No conjunto de teste, observa-se uma distribuição

proporcionalmente semelhante, com 405 imagens para a classe *não tumor*, 300 imagens para as classes *hipófise* e *glioma*, e 306 imagens para a classe *meningioma*.

4.2. Pré-processamento das Imagens

Antes do treinamento dos modelos, as imagens do conjunto de dados passaram por uma etapa de pré-processamento com o objetivo de padronizar a entrada da rede neural e facilitar o processo de aprendizado. Inicialmente, todas as imagens foram redimensionadas para o tamanho 150×150 pixels, garantindo uniformidade dimensional e reduzindo o custo computacional durante o treinamento.

Em seguida, os valores de intensidade dos pixels foram normalizados para o intervalo $[0, 1]$ por meio da divisão por 255. Essa normalização contribuiu para a estabilidade numérica do treinamento e favoreceu uma convergência mais eficiente dos algoritmos de otimização.

As imagens foram convertidas para o formato RGB, como forma de assegurar a compatibilidade com as arquiteturas de redes neurais convolucionais utilizados neste trabalho. Ressalta-se que, nesta etapa, não foram aplicadas transformações geométricas ou artificiais adicionais, de modo que o pré-processamento se limitou à padronização e normalização dos dados.

4.3. Aumento de Dados (*Data Augmentation*)


Com o objetivo de aumentar a variabilidade do conjunto de treinamento e reduzir o risco de sobreajuste (*overfitting*), foram aplicadas técnicas de aumento de dados (*data augmentation*) durante o processo de treinamento dos modelos.

O aumento de dados foi realizado por meio de transformações geométricas e fotométricas aplicadas de forma aleatória às imagens do conjunto de treinamento. Entre as transformações utilizadas destacam-se rotações de pequeno ângulo, variações controladas de brilho, deslocamentos horizontais e verticais, além de operações de cisalhamento e espelhamento horizontal.

Ressalta-se que as técnicas de *data augmentation* foram aplicadas exclusivamente ao conjunto de treinamento. Os conjuntos de validação e teste foram mantidos inalterados, sendo submetidos apenas às etapas de redimensionamento e normalização, garantindo assim uma avaliação justa e imparcial do desempenho dos modelos.

A Figura 5 apresenta exemplos de imagens geradas a partir do processo de aumento de dados, ilustrando as principais transformações aplicadas ao conjunto de treinamento.

Figura 5. Exemplos de imagens geradas pelo processo de aumento de dados.



4.4. Divisão dos Dados

Do conjunto de treinamento original, 15% das imagens foram reservadas para validação, permitindo o monitoramento do desempenho dos modelos durante o treinamento. O conjunto de teste permaneceu completamente separado, sendo utilizado apenas para a avaliação final.

4.5. Arquiteturas dos Modelos

Para a realização dos experimentos, foram selecionadas três arquiteturas distintas de redes neurais convolucionais, com o objetivo de avaliar diferentes estratégias de aprendizado aplicadas ao problema de classificação de tumores cerebrais em imagens de ressonância magnética.

O primeiro modelo consiste em uma rede neural convolucional desenvolvida do zero, utilizada como linha de base (*baseline*). A adoção dessa arquitetura permitiu avaliar a capacidade de aprendizado de características diretamente a partir dos dados disponíveis, sem o uso de conhecimento prévio. Esse modelo serviu como referência para compreender os ganhos obtidos com a utilização de arquiteturas mais profundas e pré-treinadas, além de possibilitar uma análise do desempenho de soluções mais simples para o problema em estudo.

O segundo modelo emprega a arquitetura VGG16 pré-treinada no conjunto de dados *ImageNet*, utilizando a técnica de *transfer learning*. A escolha da VGG16 deve-se à sua ampla utilização na literatura e à sua comprovada eficácia na extração de características visuais relevantes.

O terceiro modelo baseia-se na arquitetura ResNet101, também pré-treinada no *ImageNet*. Essa arquitetura foi selecionada por sua maior profundidade e por empregar mecanismos que facilitam o treinamento de redes mais complexas. A inclusão da ResNet101 permitiu avaliar o impacto da profundidade da rede no desempenho da classificação.

A comparação entre essas três abordagens foi optada por possibilitar uma análise abrangente dos benefícios e limitações de cada estratégia, considerando aspectos como capacidade de generalização, complexidade do modelo e desempenho preditivo. Dessa forma, busca-se identificar a arquitetura mais adequada para o problema de classificação de tumores cerebrais, bem como compreender o *trade-off* entre simplicidade e desempenho.

4.6. Configuração de Treinamento

4.6.1. CNN Desenvolvida do Zero

A CNN proposta foi composta por quatro blocos convolucionais sequenciais. Cada bloco contém uma camada convolucional seguida de uma função de ativação ReLU (*Rectified Linear Unit*) e uma camada de *max pooling*. Os tamanhos dos filtros convolucionais foram definidos como 3×3 , padrão amplamente adotado na literatura por capturar características espaciais locais de forma eficiente. O número de filtros aumentou progressivamente ao longo da rede (32, 64, 128 e 256 filtros), permitindo a extração hierárquica de características de baixo a alto nível.

Após os blocos convolucionais, a rede inclui uma camada de *flatten*, seguida por duas camadas densas totalmente conectadas. A primeira camada densa utiliza a função de ativação ReLU, enquanto a camada de saída emprega a função *softmax*, adequada para problemas de classificação multiclasse. O modelo foi treinado integralmente, sem congelamento de camadas, uma vez que seus pesos foram inicializados aleatoriamente.

4.6.2. Modelos com Transfer Learning

Nos modelos baseados em *transfer learning*, as arquiteturas VGG16 e ResNet101 foram utilizadas como extratoras de características. Em ambos os casos, as camadas convolucionais pré-treinadas foram inicialmente congeladas, preservando os pesos aprendidos no ImageNet. Sobre essas arquiteturas base foram adicionadas camadas personalizadas compostas por uma camada de *global average pooling*, seguida por camadas densas com ativação ReLU e uma camada final com ativação *softmax*.

Durante o treinamento, apenas as camadas adicionadas foram atualizadas, caracterizando um processo de ajuste fino parcial (*fine-tuning*). Essa estratégia visou reduzir o risco de sobreajuste, além de diminuir o custo computacional, ao mesmo tempo em que permitiu a adaptação dos modelos ao domínio específico de imagens de ressonância magnética cerebral.

4.6.3. Parâmetros de Treinamento e Validação

Todos os modelos foram treinados utilizando o otimizador Adam, selecionado por sua eficiência e rápida convergência. A função de perda adotada foi a *categorical cross-entropy*, apropriada para tarefas de classificação multiclasse. A métrica de acurácia foi empregada para monitorar o desempenho durante o treinamento e a validação.

A CNN desenvolvida do zero foi treinada por 30 épocas, utilizando a taxa de aprendizagem padrão do otimizador Adam. Já os modelos VGG16 e ResNet101 foram treinados por 20 épocas, com uma taxa de aprendizagem reduzida de 1×10^{-4} , permitindo ajustes mais suaves nos pesos das camadas treináveis.

Observa-se, no entanto, que embora os modelos baseados em *transfer learning* tenham sido configurados para treinamento por 20 épocas, os históricos de treinamento apresentam um número ligeiramente inferior de épocas registradas. Esse comportamento está associado ao processo de treinamento com geradores de dados, no qual o número efetivo de épocas pode variar em função do total de amostras, do tamanho do lote e da convergência antecipada das métricas. Ressalta-se que tal comportamento é esperado em modelos pré-treinados, os quais tendem a convergir mais rapidamente devido ao reaproveitamento de pesos previamente aprendidos.

O conjunto de dados foi dividido em subconjuntos de treinamento e validação, possibilitando o acompanhamento da capacidade de generalização dos modelos. Não foi empregada a técnica de *early stopping*; a avaliação do desempenho foi realizada exclusivamente por meio da análise das curvas de perda e acurácia ao longo das épocas.

4.7. Avaliação dos Modelos

A avaliação foi conduzida utilizando o conjunto de teste, por meio de métricas como acurácia, precisão, revocação e *F1-score*. Além disso, foram geradas matrizes de confusão e relatórios de classificação para análise do desempenho de cada modelo.

Também, durante o treinamento, foram gerados gráficos de acurácia e perda ao longo das épocas, permitindo a análise da convergência dos modelos.


5. Resultados e Discussões

Nesta seção são apresentados os resultados obtidos a partir da avaliação dos modelos propostos, eles são organizados por arquitetura, permitindo uma análise individual do desempenho de cada modelo, seguida de uma comparação geral entre as abordagens avaliadas.

5.1. Resultados da Rede Neural Convolutacional Desenvolvida do Zero

A Figura 6 apresenta a evolução da função de perda e da acurácia ao longo do treinamento. Observa-se uma redução consistente da perda no conjunto de treinamento, acompanhada de um aumento progressivo da acurácia, indicando que o modelo foi capaz de aprender padrões discriminativos relevantes a partir dos dados. No conjunto de validação, a perda apresenta pequenas oscilações após as primeiras épocas, enquanto a acurácia se mantém elevada e relativamente estável, sugerindo boa capacidade de generalização e ausência de sobreajuste severo.

Figura 6. Evolução da perda e da acurácia durante o treinamento.



A avaliação final no conjunto de teste resultou em uma acurácia de **97,56%** e perda de **0,15**, evidenciando o bom desempenho do modelo mesmo sem o uso de arquiteturas pré-treinadas. Esses resultados demonstram que a rede desenvolvida do zero foi capaz de extrair características relevantes das imagens de MRI para a tarefa de classificação multiclasse.

A Tabela 2 apresenta as métricas de precisão, revocação e *F1-score* obtidas para cada classe. Observa-se desempenho consistente entre as classes, com valores de *F1-score* superiores a 0,95 em todas elas. As classes *meningioma* e *glioma* apresentaram os

melhores resultados, indicando maior facilidade do modelo em identificar essas categorias.

Tabela 2. Métricas de desempenho da rede neural convolucional.

Classe	Precisão	Revocação	F1-score	Suporte
Hipófise	1.00	0.96	0.98	300
Não tumor	0.96	0.94	0.95	306
Meningioma	0.97	0.99	0.98	405
Glioma	0.98	1.00	0.99	300
Acurácia	0.98			
Média Macro	0.98	0.97	0.98	—
Média Ponderada	0.98	0.98	0.98	—

A matriz de confusão apresentada na Figura 7 permite uma análise mais detalhada dos erros de classificação. Nota-se que a maioria das previsões está concentrada na diagonal principal, indicando elevado número de classificações corretas. Os principais erros ocorrem entre as classes *hipófise* e *nãoo tumor*, bem como entre *não tumor* e *meningioma*, o que pode ser atribuído a semelhanças visuais sutis entre essas categorias em determinadas imagens.




Figura 7. Matriz de confusão da rede neural convolucional.


De forma geral, os resultados indicam que a rede neural convolucional desenvolvida do zero apresentou desempenho elevado e consistente, servindo como uma linha de base para comparação com os modelos baseados em *transfer learning*. Apesar de sua menor complexidade em relação às arquiteturas pré-treinadas, o modelo demonstrou boa capacidade de generalização, evidenciando a eficácia do pré-processamento e das estratégias de treinamento adotadas.

5.2. Resultados do Modelo VGG16

A Figura 8 apresenta a evolução da função de perda e da acurácia ao longo do treinamento. Observa-se uma rápida convergência do modelo, com redução acentuada da perda nas

primeiras épocas e estabilização em valores baixos. A acurácia no conjunto de validação atinge valores elevados ainda nas fases iniciais do treinamento, indicando que o uso de pesos pré-treinados contribuiu para um aprendizado mais eficiente e estável quando comparado ao modelo desenvolvido do zero.

Figura 8. Evolução da perda e da acurácia durante o treinamento do modelo VGG16.



A avaliação final no conjunto de teste resultou em uma acurácia de **97,79%** e perda de **0,07**, evidenciando um desempenho ligeiramente superior ao do modelo desenvolvido do zero. O menor valor da função de perda indica maior confiança nas predições realizadas pelo modelo VGG16.

A Tabela 3 apresenta as métricas de precisão, revocação e *F1-score* obtidas para cada classe. Observa-se desempenho elevado e consistente entre as classes, com valores de *F1-score* próximos ou superiores a 0,97. As classes *meningioma* e *glioma* apresentaram revocação máxima, indicando excelente capacidade do modelo em identificar corretamente essas categorias.


Tabela 3. Métricas de desempenho do modelo VGG16 no conjunto de teste.

Classe	Precisão	Revocação	F1-score	Suporte
Hipófise	1.00	0.94	0.97	300
Não tumor	0.97	0.97	0.97	306
Meningioma	0.97	1.00	0.99	405
Glioma	0.97	1.00	0.99	300
Acurácia	0.98			
Média Macro	0.98	0.98	0.98	—
Média Ponderada	0.98	0.98	0.98	—

A matriz de confusão apresentada na Figura 9 evidencia que a maior parte das amostras foi corretamente classificada, com poucos erros fora da diagonal principal.

De modo geral, o modelo VGG16 apresentou desempenho superior e mais estável em relação à rede desenvolvida do zero, beneficiando-se do uso de pesos pré-treinados.

Figura 9. Matriz de confusão do modelo VGG16 no conjunto de teste.




Esses resultados indicam que a técnica de *transfer learning* é eficaz para o problema de classificação de tumores cerebrais, permitindo obter alto desempenho mesmo com um número limitado de imagens, além de reduzir o tempo necessário para convergência do treinamento.

5.3. Resultados do Modelo ResNet101

A Figura 10 apresenta a evolução da função de perda e da acurácia ao longo do treinamento. Observa-se uma rápida convergência do modelo, com redução significativa da perda nas primeiras épocas e estabilização em valores baixos ao longo do treinamento. A acurácia no conjunto de treinamento atinge valores próximos de 100%, enquanto a acurácia de validação apresenta crescimento consistente, mantendo-se elevada, o que indica bom ajuste do modelo aos dados e ausência de sobreajuste acentuado.

Figura 10. Evolução da perda e da acurácia durante o treinamento do modelo ResNet101.



A avaliação final no conjunto de teste resultou em uma acurácia de **98,47%** e perda de **0,06**, configurando o melhor desempenho entre os modelos avaliados. O baixo valor da função de perda indica elevada confiança nas predições realizadas pela rede, refletindo a capacidade da ResNet101 em capturar padrões discriminativos complexos presentes nas imagens de MRI.


A Tabela 4 apresenta as métricas de precisão, revocação e *F1-score* obtidas para cada classe. Observa-se desempenho elevado e equilibrado entre as categorias, com valores de *F1-score* iguais ou superiores a 0,97 em todas as classes. As classes *hipófise* e *meningioma* apresentaram revocação máxima, indicando que todas as amostras dessas classes foram corretamente identificadas pelo modelo.

Tabela 4. Métricas de desempenho do modelo ResNet101 no conjunto de teste.

Classe	Precisão	Revocação	F1-score	Suporte
Hipófise	0.97	1.00	0.99	300
Não tumor	0.99	0.94	0.97	306
Meningioma	0.99	1.00	0.99	405
Glioma	0.98	0.99	0.99	300
Acurácia	0.98			
Média Macro	0.98	0.98	0.98	—
Média Ponderada	0.98	0.98	0.98	—

A matriz de confusão apresentada na Figura 11 evidencia excelente desempenho do modelo, com a maioria absoluta das amostras corretamente classificadas. Nota-se ausência de erros para a classe *hipófise* e número reduzido de confusões nas demais classes, concentradas principalmente na classe *não tumor*.

Figura 11. Matriz de confusão do modelo ResNet101 no conjunto de teste.



Assim, de maneira geral, o modelo ResNet101 apresentou o melhor desempenho entre as arquiteturas avaliadas, beneficiando-se de sua maior profundidade e da utilização de conexões residuais, que facilitam o treinamento de redes profundas.

5.4. Análise Comparativa entre os Modelos

De modo geral, os três modelos apresentaram desempenho elevado, com valores de acurácia superiores a 97%, indicando que todas as arquiteturas foram capazes de aprender padrões discriminativos relevantes para a classificação de tumores cerebrais em imagens de ressonância magnética. Entretanto, diferenças sutis podem ser observadas quando se analisa o impacto da complexidade dos modelos e do uso de *transfer learning*.

A rede neural convolucional desenvolvida do zero apresentou resultados consistentes e desempenho competitivo, demonstrando que, mesmo sem o uso de pesos pré-treinados, é possível obter bons resultados quando se utilizam estratégias adequadas de pré-processamento e aumento de dados. Contudo, esse modelo apresentou maior sensibilidade a variações durante o treinamento e desempenho ligeiramente inferior em comparação com as arquiteturas baseadas em *transfer learning*.

O modelo VGG16 apresentou ganhos em termos de estabilidade e convergência mais rápida, evidenciando os benefícios do reaproveitamento de pesos treinados em grandes bases de dados. Além disso, o modelo mostrou desempenho mais equilibrado entre as classes, com redução de erros de classificação em relação à rede desenvolvida do zero, especialmente para categorias visualmente semelhantes.

O melhor desempenho foi obtido pelo modelo ResNet101, que apresentou a maior acurácia e os menores valores de perda no conjunto de teste. A maior profundidade da arquitetura, aliada ao uso de conexões residuais, contribuiu para uma melhor capacidade de representação e aprendizado de padrões mais complexos. Apesar do maior custo computacional, os resultados indicam que essa arquitetura oferece o melhor compromisso entre desempenho e capacidade de generalização para o problema proposto.

Em síntese, os resultados evidenciam que o uso de *transfer learning*, especialmente com arquiteturas profundas como a ResNet101, proporciona ganhos significativos de desempenho na classificação de tumores cerebrais. Ainda assim, a rede desenvolvida do zero mostrou-se uma alternativa viável, sobretudo em cenários com restrições computacionais ou quando o uso de modelos pré-treinados não é possível.

6. Considerações Finais

Este trabalho apresentou o desenvolvimento e a avaliação de um sistema de classificação de tumores cerebrais a partir de imagens de ressonância magnética, utilizando técnicas de aprendizado profundo baseadas em redes neurais convolucionais. Foram analisadas diferentes arquiteturas, incluindo um modelo desenvolvido do zero e modelos baseados em *transfer learning*, permitindo uma análise comparativa do impacto da complexidade arquitetural e do reaproveitamento de pesos pré-treinados no desempenho da classificação.

Os resultados obtidos demonstraram que todas as abordagens avaliadas apresentaram desempenho elevado, com destaque para os modelos baseados em *transfer learning*, especialmente a arquitetura ResNet101, que obteve os melhores resultados em termos de acurácia e estabilidade. Esses achados evidenciam o potencial das técnicas de aprendizado profundo para a extração automática de características relevantes em imagens de ressonância magnética cerebral, contribuindo para a identificação de padrões associados a diferentes tipos de tumores.

Ressalta-se, entretanto, que os sistemas propostos têm como objetivo auxiliar o

diagnóstico médico, não substituindo, em hipótese alguma, a atuação da equipe de profissionais de saúde. O diagnóstico definitivo de tumores cerebrais deve ser estabelecido a partir da análise conjunta de exames complementares, histórico clínico e avaliação especializada. Dessa forma, destaca-se a importância do acompanhamento de médicos radiologistas, neurologistas e demais profissionais capacitados para a correta interpretação dos resultados e para a definição do plano terapêutico mais adequado ao paciente.

6.1. Limitações e Dificuldades

Entre as principais limitações deste trabalho, destaca-se a utilização de um conjunto de dados público, o qual, embora amplamente empregado na literatura, pode não representar toda a variabilidade encontrada em ambientes clínicos reais. Além disso, o desbalanceamento entre as classes e a ausência de informações clínicas adicionais podem influenciar o desempenho dos modelos. Outra limitação refere-se à dependência de recursos computacionais para o treinamento de arquiteturas profundas, o que pode restringir a replicação dos experimentos em ambientes com menor capacidade de processamento.

6.2. Trabalhos Futuros

Como trabalhos futuros, sugere-se a ampliação do estudo por meio da utilização de bases de dados maiores e provenientes de diferentes instituições, visando aumentar a generalização dos modelos. Também é possível investigar a inclusão de informações clínicas complementares e a aplicação de técnicas de interpretabilidade, como mapas de ativação, para tornar as decisões dos modelos mais transparentes. Além disso, a avaliação dos sistemas em cenários com dados balanceados podem contribuir para o aprimoramento contínuo das soluções propostas.

Referências

- Alemayehu, N. (2025). Light weight cnn for classification of brain tumors from mri images. *arXiv preprint arXiv:2504.21188*.
- Arão, C. (2024). Por trás da inteligência artificial: uma análise das bases epistemológicas do aprendizado de máquina. *Transformação*, 47:e02400163.
- Barbosa, G., Bezerra, G., Medeiros, D., Andreoni, M., and Menezes, D. (2021). *Segurança em Redes 5G: Oportunidades e Desafios em Detecção de Anomalias e Predição de Tráfego Baseadas em Aprendizado de Máquina*, pages 145–189.
- da Silva, I. C. (2025). Diagnóstico assistido por computador na análise do exame de papanicolaou: Revisão sistemática. *Revista Pleiade*, 19(46):119–122.
- Gabriel Filho, O. (2023). *Inteligência artificial e aprendizagem de máquina: aspectos teóricos e aplicações*. Editora Blucher.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 770–778.
- Kalshetty, R. and Parveen, A. (2023). Abnormal event detection model using an improved resnet101 in context aware surveillance system. *Cognitive Computation and Systems*, 5:n/a–n/a.

- Kathuria, A., Gupta, D., and Uppal, M. (2025). Sustainable approaches in medical imaging: Enhanced mri-based brain tumor classification using transfer learning for urban health applications. *International Journal of Sustainable Building Technology and Urban Development*, 16(3):355–372.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- Leite, A. B. G. G. and Gambarato, V. T. S. (2022). Inteligência artificial aplicada ao processamento de imagem diagnóstica. *Tekhne e Logos*, 13(3):104–115.
- Louis, D. N., Perry, A., Wesseling, P., et al. (2021). The 2021 who classification of tumors of the central nervous system. *Acta Neuropathologica*, 142(2):229–281.
- Melmed, S. (2017). Pituitary tumors. *Endocrinology and Metabolism Clinics of North America*, 46(2):333–352.
- Nasralla, F. W. and Pitta, B. C. (2024). Inteligência artificial no diagnóstico de nódulos tireoidianos.
- Powers, D. M. W. (2011). Evaluation: From precision, recall and f-measure to roc, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1):37–63.
- Rohini, G. (2021). Everything you need to know about vgg16.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Whitfield, P. C. and Bruneau, M. (2020). Meningioma: a review of epidemiology, pathology, diagnosis, treatment, and future directions. *Expert Review of Neurotherapeutics*, 20(9):885–900.
- Wong, Y., Su, E. L. M., Yeong, C. F., Holderbaum, W., and Yang, C. (2025). Brain tumor classification using mri images and deep learning techniques. *PloS one*, 20(5):e0322624.
- World Health Organization (2023). Cancer. <https://www.who.int/news-room/fact-sheets/detail/cancer>.