

# MODELO DE REDE NEURAL CONVOLUCIONAL PARA CLASSIFICAÇÃO E PREDIÇÃO DE TUMOR CEREBRAL COM BASE EM IMAGEM DE RESSONÂNCIA MAGNÉTICA

Gabriel Moraes de Oliveira (Universidade Federal de Ciências da Saúde de Porto Alegre, UFCSPA - Porto Alegre-RS- Brasil) E-mail: [gabriel.moraes@ufcspa.edu.br](mailto:gabriel.moraes@ufcspa.edu.br)

Elisangela Gisele do Carmo (Universidade Estadual Paulista, UNESP- Rio Claro-SP-Brasil) E-mail: [elisangela.gisele@unesp.br](mailto:elisangela.gisele@unesp.br)

**Resumo:** O diagnóstico preciso de tumores cerebrais é crucial na medicina, necessitando de imagens de Ressonância Magnética de alta qualidade para identificar corretamente o tipo e a localização do tumor, fator essencial para um tratamento eficaz. O objetivo deste estudo visa desenvolver uma rede neural convolucional para prever tipos de tumores cerebrais, aplicando técnicas de visão computacional e inteligência artificial. O método utiliza imagens de Ressonância Magnética, aplicando uma abordagem experimental com uma rede neural convolucional de cinco camadas no *Google Colab*, com o auxílio das bibliotecas *Keras* e *TensorFlow*. A rede neural convolucional demonstrou melhorias significativas na precisão da previsão dos tipos de tumores cerebrais, classificando efetivamente as imagens e identificando características distintas dos tumores. A aplicação de redes neurais convolucionais na análise de imagens de tumores cerebrais é promissora, contribuindo para o avanço da inteligência artificial na medicina e melhorando a precisão do diagnóstico e tratamento de tumores cerebrais.

**Palavras-chave:** Visão Computacional, Rede Neural Convolucional, Deep Learning, Ressonância Magnética.

## CONVOLUTIONAL NEURAL NETWORK MODEL FOR CLASSIFICATION AND PREDICTION OF BRAIN TUMOR BASED ON MAGNETIC RESONANCE IMAGING

**Abstract:** Accurate diagnosis of brain tumors is crucial in medicine, requiring high-quality magnetic resonance imaging to correctly identify the type and location of the tumor, which are essential factors for effective treatment. The aim of this study is to develop a convolutional neural network to predict types of brain tumors, applying computer vision techniques and artificial intelligence. The method uses Magnetic Resonance Imaging, and the study applied an experimental approach with a five-layer convolutional neural network on Google Colab, aided by the Keras and TensorFlow libraries. The convolutional neural network demonstrated significant improvements in the precision of predicting types of brain tumors, effectively classifying images and identifying distinctive characteristics of the tumors. The application of convolutional neural networks in the analysis of brain tumor images is promising, contributing to the advancement of artificial intelligence in medicine and improving the accuracy of diagnosis and treatment of brain tumors.

**Keywords:** Computer Vision, Convolutional Neural Network, Deep Learning, Magnetic Resonance Imaging.

### 1. Introdução

Há anos a medicina se beneficia dos exames por imagem para apoio ao diagnóstico, facilitando o tratamento e a cura de determinadas patologias, que eram dificilmente tratadas adequadamente sem este recurso disponível. Especialmente, no que diz respeito aos tumores cerebrais, este recurso é altamente significativo no campo da saúde, já que de acordo com dados do Instituto Nacional de Câncer (2022) ocorreram 310 mil casos registrados no mundo, sendo que no Brasil houveram no ano de 2020, um total de 9.355 óbitos por esta patologia.

Devido ao fato de que este tipo de tumor é heterogêneo, a identificação precisa do tipo e localização representa um desafio, sendo a melhor forma de não ocorrer o avanço e obter a cura mais rapidamente. Desta forma, as imagens de Ressonância Magnética (RM) além de serem utilizadas para o diagnóstico, necessitam apresentar imagens mais

claras possíveis. Assim, nos últimos anos ocorreu o avanço dos sistemas inteligentes, que possibilitou a utilização de modelos de inteligência artificial para auxiliar no processo de análise, classificação e predição de patologias através do processamento de dados médicos. Dentro disso, uma das áreas de maior avanço é a de visão computacional para tratar de imagens médicas.

A visão computacional é uma família de algoritmos para análise de imagens, com distinção de duas classes principais: algoritmos baseados em redes neurais convolucionais utilizando o *Deep learning* (DL) e os que aplicam métodos clássicos (GAO et al., 2018). Dentre estas duas classes, as redes neurais convolucionais, de acordo com Baur et al. (2022), são mais apropriadas para as imagens de RM, pois conseguem aprimorar as mesmas com melhor definição e nitidez que as de método clássico.

Bernal et al. (2019) complementam que as redes neurais convolucionais, nos últimos anos estão entre os métodos mais utilizados pelo fato de que com uma maior nitidez proporcionada e a geração de imagens mais claras e precisas. Os mesmos autores destacam que o método consegue pré-processar os dados, identificar a segmentação de lesões tumorais cerebrais, das estruturas subcorticais e classificar os mesmos, mostrando-se uma ferramenta muito útil no manejo do diagnóstico.

Desta forma, o presente estudo apresenta um modelo de rede neural convolucional para classificação e predição de tumor cerebral com base em imagem de RM. O artigo se estrutura em partes: primeiro apresenta-se a fundamentação teórica, seguida dos estudos relacionados com essa temática que apresentaram a aplicação da metodologia nas imagens de RM relacionadas a tumores. Após, se apresenta o experimento, assim como os resultados obtidos, a discussão dos mesmos e a conclusão.

## 2. Fundamentação Teórica

### 2.1. Tumores cerebrais e Ressonância Magnética

Os tumores cerebrais são definidos como um grupo heterogêneo de neoplasias com formações intracranianas, constituindo diversos tipos de fases e localização em sua evolução. Os tumores podem se instalar em todos os locais do cérebro, sendo que há uma determinada incidência de faixa etária para que ocorram (MICKEVICIUS et al., 2015).

Observa-se que em crianças os tumores cerebrais mais frequentes são os denominados astrocitomas do cerebelo e tronco cerebral, meduloblastomas e ependimomas, já em adultos, os astrocitomas e glioblastomas de hemisférios cerebrais, metástases, meningiomas, schwannomas e adenomas da hipófise são os mais prevalentes nesta faixa etária (UNICAMP, s/d). Sendo que, os schwannoma são os tumores cerebrais mais importantes e os glioblastomas os mais agressivos e com maior incidência, com 50% de ocorrência em comparação com os demais tumores (AMERICAN ASSOCIATION OF NEUROLOGICAL SURGEONS, 2023).

A classificação histológica dos tumores cerebrais do Sistema Nervoso Central (SNC) apresenta mais de 100 subtipos, com indicação do tipo de tumor a ser desenvolvido de acordo com as células a partir das quais o mesmo é formado (MICKEVICIUS et al., 2015). Com relação a classificação dos tumores cerebrais, a mesma apresenta base no tecido de origem do tumor, a saber: 1) Tumores neuroectodérmicos (glia e neurônios); 2) Tumores mesodérmicos; 3) Tumores metastáticos (UNICAMP, s/d).

As causas para o desenvolvimento de um tumor cerebral são descritas não apenas pelos fatores externos, como estilo de vida, mas também podem ser derivados de condições congênitas (MCNEILL, 2016). As principais causas são o envelhecimento; a exposição frequente a radiação (raios-x e gama); substâncias tóxicas nocivas; distúrbios do SNC;

lesões cerebrais traumáticas graves; habitar em grandes cidades com muita poluição do ar; histórico viral (SOCIEDADE BRASILEIRA DE CIRURGIA ONCOLÓGICA, 2023).

Para o padrão de referência de diagnóstico de tumores a avaliação patológica ainda é realizada. Entretanto, com o advento dos métodos de neuroimagem, tornou-se possível identificar quaisquer patologias nos estágios iniciais de seu desenvolvimento, facilitando seu manejo clínico. E este avanço dos métodos de diagnóstico realizados por imagem, tem como principal exame, para tal finalidade, a RM que passou a ser um meio mais confiáveis para a detecção de diversos tipos de tumores, além de verificar seu grau de avanço. A RM analisa o grau do tumor em benigno ou maligno, fornecendo informações mais detalhadas e fidedignas que a Tomografia Computadorizada (TC) (BAHADURE et al., 2017).

O método de RM permite a detecção do tumor nos seus mais diversos estágios, seja iniciais ou não, podendo ser analisado com um agente de contraste com o intuito de analisar a extensão do tumor. Essas imagens geradas pela RM identificam a posição do tumor, o tamanho e a extensão do mesmo (BAHADURE et al., 2017).

O exame de RM gera imagens que estabelece o grau do tumor em questão, sendo extremamente útil para fechar o diagnóstico médico e fazer com que o tratamento seja mais efetivo. Ademais, todo o processo de tratamento pode ser realizado com o acompanhamento de análise das imagens geradas por este exame.

## **2.2. Visão computacional e Deep learning**

A visão computacional, uma área da inteligência artificial, tem se destacado na aplicabilidade funcional em diversos âmbitos da área da saúde, especialmente no que diz respeito aos exames de imagem. Esses exames, como a RM e a TC, contém uma modelagem tridimensional que define o grau de avanço dos tumores sendo importante ferramenta no diagnóstico (GAO et al., 2018).

O *Deep learning*, de acordo com Crespo Neto (2017), envolve um nível profundo hierárquico, sendo caracterizado como um subtipo de aprendizado de máquina. Fernando e Tsokos (2023) mostram que o DL, devido aos enormes avanços ocorridos na área da computação, são métodos muito utilizados para a classificação e identificação de imagens relativas a exames médicos.

Os campos de aplicação do DL são vastos e constituem um meio eficiente de promover resoluções efetivas dentro do campo da saúde, dentre estas pode-se citar as aplicações na classificação das diferentes doenças e facilitar a identificação com maior precisão (LIU et al., 2021), identificar os locais das lesões dos tumores (MEI et al., 2021) e nas imagens em saúde (BALAKRISHNAN et al., 2018), citando como este campo as imagens de RM.

Por meio do DL a chance de erro de um determinado diagnóstico é mínima, colaborando com que o paciente seja atendido e tenha seu problema de saúde solucionado mais rapidamente, do que se este método não fosse empregado para a análise das imagens da RM.

## **2.3. Redes neurais convolucionais**

As redes neurais convolucionais (RNC) fazem parte de uma classe de redes neurais especializada em processamento de imagens. As RNC para a área da saúde representam a identificação de imagens que mostram focos tumorais mais bem delineados (ALI et al., 2022). Estas redes, segundo Crespo Neto (2017) apresentam menos camadas

ocultas, em comparação com as redes neurais profundas que chegam até 150 camadas, ou seja, contém multicamadas, em que cada camada é formada por uma soma ponderada de todos os elementos anteriores presentes na mesma.

#### 2.4. Trabalhos relacionados

Badza e Barjaktarovic (2020) examinaram três tipos de tumores provindos de uma base de dados com o objetivo de apresentar uma classificação de tumores cerebrais por meio de RNC. Os autores mostraram, em seu experimento desenvolvendo uma nova rede neural, que a identificação por este meio é mais facilitada para diagnósticos.

Hashemzahi et al. (2020) explicam que ao construir um modelo híbrido com RNC e com distribuição neural não linear autorregressiva, o mesmo extrai as características de forma precisa com relação a identificação das imagens de RM em relação aos tumores cerebrais.

Sharif et al. (2020) concluiu que a técnica utilizada no estudo, sendo um método para segmentação das imagens dos tumores e a fusão de recursos de aprendizagem profunda otimizados por meio de um algoritmo e os resultados mostraram que essas etapas auxiliam na construção de um mapa que posteriormente segmenta com precisão a imagem da região tumoral. Cai, Gao e Zhao (2020) apresentaram todas as formas de aplicação de algoritmos de DL na análise de imagens médicas e explicaram as técnicas de classificação e segmentação de aprendizagem profunda com dados atuais. Como resultados demonstraram que o DL em análise de classificação é muito utilizado nos exames de identificação de tumores, mas também na detecção de retinopatia diabética, detecção ultrassonográfica de nódulos mamários, triagem de nódulos pulmonares, detecção precoce da doença de Alzheimer, segmentação ventricular esquerda, câncer gástrico, entre outros. Complementam que com o DL as imagens médicas são mais precisas na detecção, segmentação, classificação e indicação dos focos das doenças, identificando não somente as lesões nos locais acometidos, mas classificando estas lesões e seu grau de evolução e segmentando toda a área.

Liu et al. (2021) em seu estudo delinearão os métodos de segmentação de imagens médicas baseados em DL divididas em 3 categorias: *Fully Convolutional Network* (FCN), *U-Net* e *Generative Adversarial Network* (GAN). Os autores destacam que apesar de os métodos serem extremamente úteis no diagnóstico e avaliação médica, ainda existem alguns desafios a serem explorados pelas pesquisas a fim de proporcionar melhorias junto a cada um dos métodos estudados pelos autores.

Wartergaonkar et al. (2023) analisaram as RNC no processamento da melhoria de imagens da RM para detecção e classificação de tumores de hipófise, glioma e meningioma. Os autores realizaram o processo de importação de dados que, posteriormente ocorreu o processamento das imagens com adição de melhorias com um algoritmo que deixou as mesmas mais nítidas, e logo após a imagem foi aprimorada.

Ashar et al. (2022) demonstraram o processo de melhorias das MRI como forma de classificá-las, após análise dos VGG-16, InceptionB3 e ResNet50. Os autores realizaram um pré-processamento dos dados para testar e validar o modelo com aplicação de vários algoritmos, após foi aplicado a arquitetura *Efficient Network B7* com três diferentes modelos da RNC, em que possuía 8 modelos e 4 componentes. O modelo testado pelo estudo conseguiu identificar a presença ou não de um tumor e também qual o seu tipo e estágio.

Ullah et al. (2020) tiveram como objetivo classificar as imagens de RM em estágio dos tumores como benignos ou não, a fim de aplicar três estágios diferentes no aprimoramento das imagens, sendo que na fase de pré-processamento as mesmas foram

convertidas de escala de cinza para RGB, que oferece mais informações sobre os detalhes da imagem que a escala de cinza. Foi utilizado também um filtro para melhoria da imagem, suavizando os ruídos e para um melhor aprimoramento foi aplicado o *Contrast Limited (CLAHE)* e decomposta utilizando o *Wavelet e Feedforward Neural Network (FNN)*. Com estes métodos aplicados nas etapas de aprimoramento das imagens, os autores concluíram que as imagens dos exames de RM ficarão mais claras e assim ficará mais fácil para os médicos afirmarem com precisão o diagnóstico, se um tumor é benigno ou não.

Kang, Ullah e Gwak (2022) utilizaram de 13 RNC (*ResNet-50, ResNet-101, DenseNet-121, DenseNet-169, VGG-16, VGG-19, AlexNet, Inception V3, ResNext-50, ResNext-101, ShuffleNet, MobileNet, MnasNet*) e 9 Aprendizado de máquina (*FC layer, Gaussian NB, AdaBoost, k-NN, RF, SVM*) com 3 diferentes *kernels (linear, sigmoid, and RBF, ELM)*. Os autores aprimoraram as imagens com o método empregado de forma que as imagens pudessem ser mais claramente identificadas pelos médicos.

### 3. Metodologia

Esse artigo tem como objetivo dissertar sobre um experimento de rede neural convolucional para predição de tipos de tumores cerebrais. Para isso, a implementação dos códigos foi realizada utilizando o ambiente *Google Collab*. Além disso, utilizou-se a biblioteca de aprendizagem de máquina *Keras* e a plataforma *Tensor Flow*. A arquitetura da rede neural convolucional utilizada se organizou em cinco camadas convolucionais e outras camadas de filtros aplicados.

#### 3.1. Dataset

A base de dados utilizada foi disponibilizada pelo site *Kaggle*, intitulada “*Brain Tumor Classification (MRI)*”. Ela contém imagens de RM de tumores cerebrais, classificadas em quatro tipos: glioma, meningioma, hipófise e nenhum tumor, também, já está separada em dois diretórios, para treinamento e para teste. O conjunto já estava dividido em dois diretórios: treino, com 2.870 imagens (826 gliomas, 822 meningiomas, 827 hipófises e 395 sem tumor), e teste, com 381 imagens (87 gliomas, 115 meningiomas, 74 hipófises e 105 sem tumor). O balanceamento entre as classes do conjunto de dados foi avaliado com gráficos de distribuição, como ilustrado na Figura 2. Observou-se um leve desbalanceamento nas classes de treinamento, o que pode influenciar na capacidade do modelo de generalizar para algumas categorias (ALI et al., 2022).

#### 3.2. Pré-processamento

Como as imagens já estavam separadas em dois diretórios, elas foram carregadas para dentro de dois *arrays*, um de treino e outro de teste. Após isso, foram redimensionadas para 150x150 *pixels* como uma forma de diminuir o peso dos *inputs* para treinar o modelo. Separou-se em dois *arrays* separados para treino e teste: *X\_train, X\_test (dados)* e *y\_train, y\_test (rótulos)*. Também foi utilizada a codificação *one-hot* para adaptar os rótulos às classes para classificação.

O teste *X\_train* e *X\_test* para armazenar a referência das imagens e, *y\_train* e *y\_test* para seus *labels*. Além do mais, também foram criadas variáveis para armazenar os *labels* encodados em índices, para serem utilizados na predição. Após essa etapa, foram realizadas algumas visualizações para que seja certificado que tudo ocorreu conforme o planejado.

#### 3.3. Arquitetura

A arquitetura dessa RNC foi disposta da seguinte forma, uma camada convolucional com 32 filtros e função de ativação *relu*, uma camada convolucional com 64 filtros e

função de ativação *relu*, uma camada convolucional com 128 filtros e função de ativação *relu*, uma camada convolucional com 256 filtros e função de ativação *relu*, quatro camadas de *MaxPool2D*, uma camada *Flatten*, uma camada densa com 128 neurônios e função de ativação *relu*, uma camada de *dropout* com parâmetro de 0.4 e por fim, uma camada densa com 4 neurônios (mesmo número de classes) e função de ativação *softmax*. O otimizador usado foi o Adam, pois é amplamente utilizado nos trabalhos relacionados observados, mantendo a taxa de aprendizado em 0.001, peso de decaimento de 0.0001, a *loss categorical\_crossentropy* e métricas de acurácia.

### 3.4. Treino, validação e teste

Para treino foram utilizadas 2.870 imagens, destas 10% foram utilizadas para fazer validar o treino e criar a curva loss e definir a acurácia. Para testar o modelo de fato, utilizou-se 381 imagens que não estiveram envolvidas no treino do modelo. Esse modelo foi treinado em 15 épocas com *batch size* de 128.

No teste, o modelo atingiu uma acurácia de 95%, mas ao avaliar a matriz de confusão (Figura 4), foi evidente a dificuldade de prever corretamente a classe sem tumor, que apresentou taxa de erro mais alta. Esse problema pode ser mitigado por técnicas de aumento de dados (*data augmentation*), como rotações e ajustes de brilho (WATEGAONKAR et al., 2023).

### 3.5. Visualizações e Métricas

Além da matriz de confusão, foram criados mapas de ativação (*activation maps*) para reconhecer áreas que influenciaram a decisão do modelo. Conforme ilustrado na Figura 6, diferentes regiões do cérebro exibiram graus variados de importância para a categorização. Esta metodologia possibilita confirmar a confiabilidade das previsões (MEI et al., 2021).

Outras métricas analisadas incluem a precisão, a reversão (*recall*) e o *F1-score*, de acordo com o relatório de classificação apresentado na Figura 5. A curva ROC será incorporada em futuras pesquisas para uma melhor compreensão do rendimento do modelo por classe.

## 4. Resultado e Discussão

A elaboração dessa experimentação empregou redes neurais convolucionais para solucionar questões de visão computacional, utilizando imagens de RM de tumores cerebrais. O procedimento foi complexo, requerendo boas práticas em todas as fases metodológicas, desde o pré-processamento até a modificação de hiperparâmetros. As resoluções de problemas relacionados à visão computacional, por meio do uso de uma base de dados de imagens de RM de tumores cerebrais foi significativa para que a solução se apresentasse multifacetada, pois para seus resultados serem significativos demanda o uso de boas práticas e técnicas em todas as etapas de sua metodologia. Por exemplo, as primeiras etapas de pré-processamento de dados são tão essenciais para a eficácia quanto às etapas de ajuste de hiperparâmetros.

Para o pré-processamento de dados e arquitetura, esse estudo envolveu a separação das imagens em dois diretórios (treino e teste), referenciou o caminho das imagens em *arrays*, e a seu redimensionamento para 150x150 *pixels*, como forma de reduzir o tamanho das imagens e assim reduzir o tempo de treinamento. Contudo, é importante observar que essas reduções trazem perdas de detalhes da imagem e deve ser avaliado com base na literatura e em trabalhos correlatos a melhor escolha de dimensão para a solução do problema.

Esta opção teve como objetivo diminuir o tempo de treinamento, porém resultou na perda de detalhes relevantes das imagens, um aspecto que precisa ser cuidadosamente analisado com base na literatura. Depois dessa fase, utilizamos gráficos de distribuição para confirmar o equilíbrio das classes no conjunto de dados. A estrutura da rede neural foi estabelecida de maneira empírica, fundamentada em experimentos e referências passadas. Ela incorporou camadas convolucionais, densas e *dropout*, com o objetivo de minimizar o *overfitting*. O Adam, com uma taxa de aprendizado de 0,001 e um decaimento de peso de 0,00001, foi empregado para aprimorar a curva de perdas.

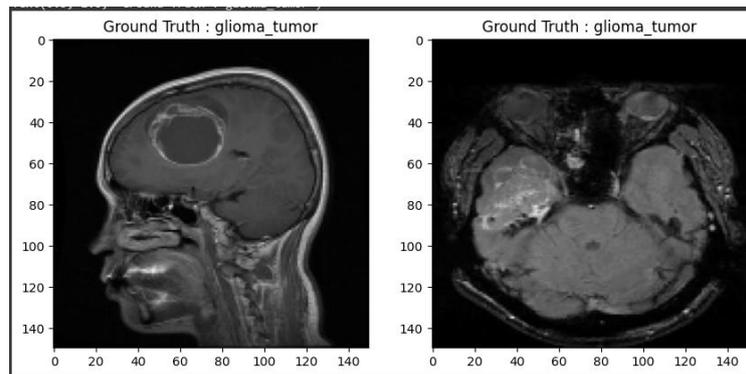


Figura 1 - Imagem do dataset redimensionada  
Fonte: Autoria própria

Depois de pré-processar as imagens, foi vital conferir a disposição das imagens nos *arrays* para confirmar se o equilíbrio entre as classes estava em conformidade. Esta fase é importante para assegurar que o modelo não seja influenciado por dados desbalanceados, o que poderia comprometer sua habilidade de generalização. A avaliação do equilíbrio foi feita por meio da representação gráfica de gráficos de distribuição, que mostraram a distribuição de imagens em cada classe.

Os diagramas de dispersão possibilitaram uma percepção nítida do número de imagens disponíveis para as categorias "glioma", "meningioma", "hipófise" e "sem tumor". Esta avaliação indicou um ligeiro desequilíbrio entre as classes, particularmente na classe "sem tumor", que exibiu um número reduzido de amostras em comparação com as demais.

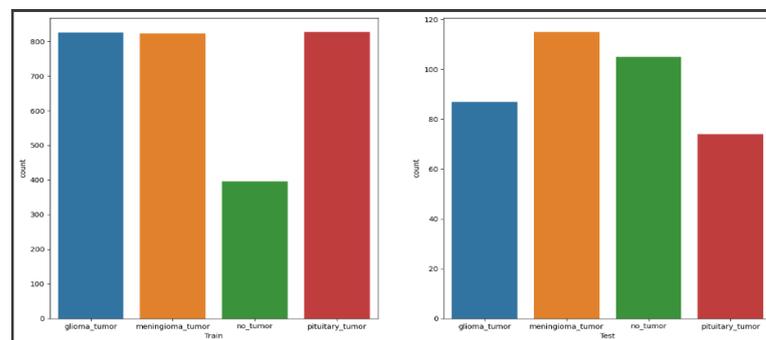


Figura 2 - Gráficos de distribuição de imagens  
Fonte: Autoria própria

Este desbalanceamento pode afetar adversamente o rendimento do modelo, tornando mais difícil a identificação precisa de imagens normais. Para minimizar essa questão, uma opção seria o uso de métodos de ampliação de dados, tais como rotações, inversões

e ajustes de brilho, que poderiam incrementar artificialmente o número de imagens em categorias menos representadas. Ademais, uma estratégia alternativa poderia ser a revisão do dataset original para adicionar mais imagens da classe minoritária, visando aprimorar o equilíbrio e, conseqüentemente, o rendimento do modelo. Assim, a avaliação do balanceamento é essencial no processo de processamento de dados, uma vez que afeta diretamente a efetividade do treinamento e a habilidade do modelo de categorizar adequadamente as diversas categorias de imagens.

Para a arquitetura do modelo de rede neural, iniciou-se definindo uma semente aleatória para manter o estado de inicialização padrão e assim poder realizar os ajustes dos hiperparâmetros de forma mais precisa. A criação desse modelo se deu de forma empírica, ou seja, através da experimentação e observação, com base nas referências e trabalhos correlatos utilizados, principalmente ao se tratar da escolha do número de camadas e filtros. Para tentar mitigar questões de overfitting, utilizou-se das camadas densa, *dropout* e *flatten*, pois seu uso foi observado em trabalhos correlatos. O otimizador Adam foi escolhido, pois é amplamente utilizado devido a sua característica de adaptar a sua taxa de aprendizado, entretanto essa ficou definida com seu valor padrão de 0.001 e se utilizou o decaimento de peso de 0.0001 para otimizar a curva loss. Ao observar a curva loss e de acurácia disposta na figura 3 abaixo, pode-se perceber algumas questões. Na curva loss não houve uma linearidade ideal entre os dados de treinamento e os 10% usados para a validação, entretanto seu decaimento não aparenta ser péssimo. Quando observada a curva de acurácia, pode notar que há mais oscilação na linha de validação do que na de treinamento, também indicando que a validação do treino não foi ideal. Contudo, identifica-se uma maior aproximação entre elas no final das épocas de treinamento. Além disso, a maior acurácia de treino atingida foi de 95% e a maior acurácia de validação do treino atingida foi de 95%, na época de número 14.

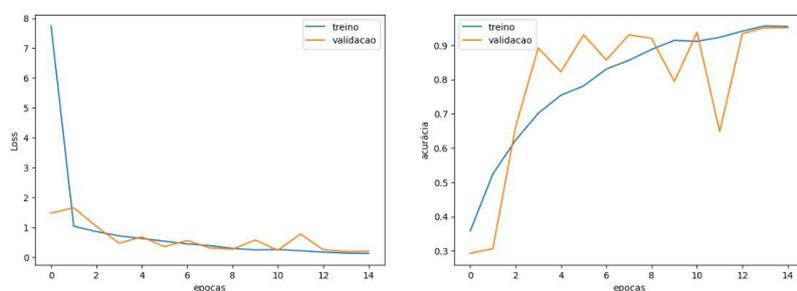


Figura 3 - Curva de Loss e acurácia

Fonte: Autoria própria

Outra métrica que pode ser considerada importante para ser visualizada e que irá nos ajudar a dimensionar a qualidade do modelo é a matriz de confusão, nesse caso, ela está associada com um *heatmap*, destacando a frequência de previsões corretas e incorretas para cada classe, facilitando a identificação de padrões de erro e possíveis fraquezas no modelo. Com a matriz de confusão, normalmente, pode-se inferir a quantidade de previsões corretas por classe. Na matriz de confusão, cada célula representa a interseção entre os rótulos verdadeiros e as predições feitas pelo modelo. Por exemplo, os valores na diagonal principal indicam o número de previsões corretas para cada classe, enquanto os valores fora dessa diagonal refletem erros de classificação. Por meio dessa análise, é possível identificar classes com alto número de falsos positivos ou falsos negativos, o que aponta para dificuldades específicas do modelo em distinguir certas categorias.

No caso deste trabalho, a análise da matriz de confusão evidenciou que a classe "sem tumor" foi a mais problemática, apresentando alta taxa de falsos negativos. Isso significa que o modelo frequentemente classifica imagens normais como pertencentes a outras classes, possivelmente devido ao desequilíbrio de dados ou à dificuldade em identificar características distintivas nessa categoria. A adição de um *heatmap* à matriz facilita a visualização, possibilitando identificar rapidamente quais categorias são mais bem ou menos bem classificadas. Por exemplo, tonalidades mais fortes na diagonal principal sinalizam alta acurácia para essas classes, enquanto tonalidades mais suaves fora dessa diagonal ressaltam os erros.

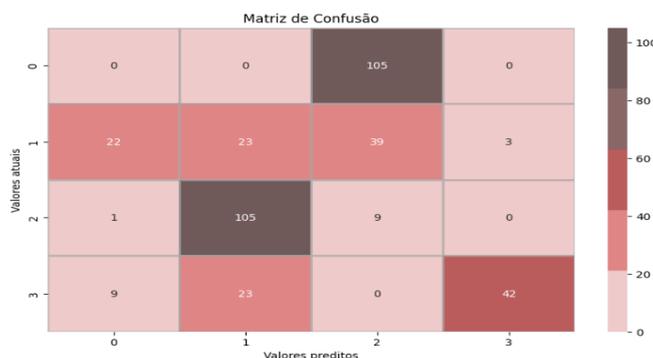


Figura 4 - Matriz de Confusão  
Fonte: Autoria própria

Embora as figuras acima não demonstrem resultados muito dramáticos, a tabela gerada pelo *classification report*, após a classificação de dados não reconhecida pelo modelo treinado, não ilustram resultados tão positivos, indicando algum problema na disposição dos dados treinados. Essa tabela destacou problemas na classificação de algumas classes, sendo particularmente notável o desempenho insatisfatório na classe "sem tumor".

Ao observar os valores detalhados de precisão, *recall* e *F1-score*, percebe-se que a classe "sem tumor" apresentou valores significativamente mais baixos em comparação com as demais classes, indicando dificuldades do modelo em distinguir imagens normais de outras categorias. Essa limitação pode estar associada ao desequilíbrio no dataset, uma vez que a classe "sem tumor" conta com um menor número de exemplos disponíveis para o treinamento. Além disso, características menos evidentes nas imagens dessa classe podem ter dificultado o aprendizado do modelo.

A precisão elevada observada na classe "hipófise" (93%) reforça que o modelo consegue identificar padrões bem definidos quando presentes, enquanto classes com características mais sutis ou menos representadas enfrentam dificuldades. Isso indica que são necessários ajustes no pré-processamento dos dados e no equilíbrio do dataset para aprimorar a generalização do modelo.

	precision	recall	f1-score	support
Class 0	0.00	0.00	0.00	105
Class 1	0.15	0.26	0.19	87
Class 2	0.06	0.08	0.07	115
Class 3	0.93	0.57	0.71	74
accuracy			0.19	381
macro avg	0.29	0.23	0.24	381
weighted avg	0.23	0.19	0.20	381

Figura 5 - Tabela de reporte da classificação  
Fonte: Autoria própria

O modelo de RNC implementado apresentou resultados promissores, mas também destacou desafios importantes no processo de análise e classificação. Seguindo o treinamento com 2.870 imagens e a validação com 381 imagens inéditas, o modelo alcançou uma acurácia de 95%, demonstrando uma capacidade sólida de classificação geral. Contudo, ao examinar métricas mais detalhadas, como a matriz de confusão e o relatório de classificação, foram observadas discrepâncias relevantes.

Este estudo alcançou resultados positivos, como uma acurácia global de 95% durante o teste, indicando que a arquitetura selecionada e os métodos de otimização empregados foram eficazes na maioria das situações. Ademais, as categorias ligadas a tumores, tais como glioma, meningioma e hipófise, mostraram alta precisão e recall, sugerindo que o modelo é eficiente em identificar imagens com características associadas a tais condições. A análise dos mapas de ativação, por outro lado, mostrou que o modelo é capaz de reconhecer padrões significativos nas imagens de RM. Isso está em consonância com a literatura que enfatiza a efetividade das redes neurais convolucionais em análises médicas (MEI et al., 2021). No entanto, notaram-se alguns desafios consideráveis.

A avaliação da matriz de confusão revelou que a categoria "sem tumor" apresentou menor precisão e maior quantidade de falsos negativos, demonstrando a complexidade do modelo em diferenciar imagens normais de tumores com características discretas. Ao longo do treinamento, a curva de validação mostrou maior instabilidade em comparação à curva de treinamento, indicando a possibilidade de superajuste ou problemas ligados ao desequilíbrio inadequado do *dataset*. Adicionalmente, o corte das imagens para 150x150 *pixels*, apesar de ter contribuído para a diminuição do tempo de treinamento, pode ter prejudicado a retenção de detalhes cruciais, indispensáveis para uma análise mais acurada.

Ao comparar os resultados obtidos com outros estudos mencionados no artigo, como os de Ashar et al. (2022) e Wategaonkar et al. (2023), nota-se que a combinação de estratégias, como a aplicação de filtros avançados e o uso de técnicas de data augmentation, pode contribuir significativamente para melhorar a performance em classes desafiadoras. Esses estudos também destacam a relevância de arquiteturas mais profundas e o uso de abordagens híbridas.

Para melhorar os resultados do modelo, algumas alternativas de aprimoramento podem ser levadas em conta. A utilização de métodos de ampliação de dados, tais como rotação, inversão e ajustes de brilho, tem o potencial de ampliar a representatividade das categorias menos frequentes, especialmente a classe "sem tumor", contribuindo para o equilíbrio do conjunto de dados. Ademais, modificações na arquitetura, como a inclusão de camadas adicionais e a utilização de arquiteturas mais sofisticadas, como *ResNet* ou *EfficientNet*, podem aprimorar a habilidade do modelo de se generalizar para variados tipos de dados. Outra tática importante é o uso da curva ROC para cada classe, que pode proporcionar uma avaliação mais minuciosa do desempenho do modelo em variados contextos, apontando áreas específicas para melhorias. Finalmente, o equilíbrio das amostras por classe.

## 5. Considerações Finais

Este estudo fornece uma avaliação minuciosa da aplicação de redes neurais convolucionais na visão computacional, concentrando-se na execução de um modelo destinado à previsão de tumores cerebrais através de imagens de RM. No período de treinamento, o modelo atingiu uma precisão de 95% tanto nos dados de treinamento

quanto nos de teste. Este resultado destaca a capacidade da metodologia para categorizar imagens médicas complexas e auxiliar no progresso do diagnóstico por imagem. No entanto, uma avaliação mais detalhada, apontou falhas consideráveis na categorização de algumas categorias, particularmente a "sem tumor". Essas discrepâncias indicam a necessidade de mais estudos, com o desequilíbrio das classes durante o treinamento sendo uma hipótese inicial para explicar essa questão. Ademais, é essencial levar em conta que o desequilíbrio pode ter restringido a habilidade do modelo de generalizar eficazmente para todas as categorias do conjunto de dados.

Outro ponto que precisa ser considerado é a importância de expandir as maneiras de analisar as métricas do modelo. A incorporação de indicadores como a curva ROC para cada categoria poderia proporcionar uma visão mais aprofundada do desempenho em variados contextos, contribuindo para a identificação de padrões de falha e áreas para aprimoramento. Também seria benéfico incorporar métodos de visualização como *heatmaps* mais sofisticados e a avaliação das áreas de interesse desencadeadas pelo modelo, o que contribuiria para a compreensão do modelo.

Com base na teoria e nos testes conduzidos, a aplicação de redes neurais convolucionais, aliadas a ferramentas como *Keras* e *TensorFlow*, mostrou-se uma estratégia promissora para solucionar desafios de visão computacional. Contudo, para potencializar o efeito desta aplicação, é imprescindível implementar táticas que minimizem os obstáculos identificados, como o desequilíbrio de classes, além de explorar arquiteturas mais sólidas. Essas melhorias têm o potencial de tornar o modelo uma ferramenta ainda mais eficaz e segura na área de análise de imagens médicas.

## Referências

AMERICAN ASSOCIATION OF NEUROLOGICAL SURGEONS. **Neurosurgical Conditions and Treatments: Glioblastoma Multiforme.** Disponível em: <https://www.aans.org/en/Patients/Neurosurgical-Conditions-and-Treatments/Glioblastoma-Multiforme>. Acesso em: 27 out. 2023.

ALI, S. et al. A comprehensive survey on brain tumor diagnosis using deep learning and emerging hybrid techniques with multi-modal MR image. **Archives of Computational Methods in Engineering**, v. 29, n. 7, p. 4871-4896, 2022.

BAHADURE, N. B.; RAY, A. K.; THETHI, H. P. Image analysis for MRI based brain tumor detection and feature extraction using biologically inspired BWT and SVM. **International Journal of Biomedical Imaging**, v. 2017, n. 1, p. 9749108, 2017.

BALAKRISHNAN, G. et al. An unsupervised learning model for deformable medical image registration. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**, 2018, p. 9252-9260.

BAUR, D.; KROBOTH, K.; HEYDE, C. E.; VOELKER, A. Convolutional neural networks in spinal magnetic resonance imaging: A systematic review. **World Neurosurgery**, v. 116, n. 1, p. 60-70, 2022.

BERNAL, J.; KUSHIBAR, K.; ASFAW, D. S.; VALVERDE, S.; OLIVER, A.; MARTÍ, R.; LLADÓ, X. Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: A review. **Artificial Intelligence in Medicine**, v. 95, n. 1, p. 64-81, 2019.

BHUVAJI, S.; KADAM, A.; BHUMKAR, P.; DEDGE, S. **Brain Tumor Classification (MRI)**. [Data set]. Kaggle, 2020.

CAI, L.; GAO, J.; ZHAO, DI. A review of the application of deep learning in medical image classification and segmentation. **Annals of Translational Medicine**, v. 8, n. 11, p. 713, 2020.

CRESPO NETO, S. A. H. **Reconhecimento de tumores cerebrais utilizando redes neurais convolucionais**. 2017. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Universidade Federal do Pampa, Campus Alegrete, Alegrete, 2017.

DATA SCIENCE ACADEMY. **Camadas de Pooling em Redes Neurais Convolucionais**. Deep Learning Book, 2022.

FERNANDO, K. R. M.; TSOKOS, C. P. Deep and statistical learning in biomedical imaging: State of the art in 3D MRI brain tumor segmentation. **Information Fusion**, v. 92, n. 1, p. 450-465, 2023.

GAO, J.; YANG, Y.; LIN, P.; PARK, D. S. Computer vision in healthcare applications. **Journal of Healthcare Engineering**, v. 2018, n. 1, p. 5157020, 2018.

HASHEMZEHI, R.; MAHDAVI, S. J. S.; KHEIRABADI, M.; KAMEL, S. R. Detection of brain tumors from MRI images based on deep learning using a hybrid model CNN and NADE. **Biocybernetics and Biomedical Engineering**, v. 40, n. 3, p. 1225-1232, 2020.

INSTITUTO NACIONAL DE CÂNCER. **Estimativa 2023: Incidência de câncer no Brasil**. 1. ed. Rio de Janeiro: INCA, 2022.

KANG, J.; ULLAH, Z.; GWAK, J. MRI-based brain tumor classification using an ensemble of deep features and machine learning classifiers. **Sensors**, v. 21, n. 6, p. 2222, 2021.

LIU, X.; SONG, L.; LIU, S.; ZHANG, Y. A review of deep-learning-based medical image. **Sustainability**, v. 13, n. 3, p. 1224, 2021.

MCNEILL, K. A. Epidemiology of brain tumors. **Neurologic Clinics**, v. 34, n. 4, p. 981-998, 2016.

MEI, J.; CHENG, M. M.; XU, G.; WAN, L. R.; ZHANG, H. SANet: A slice-aware network for pulmonary nodule detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 44, n. 8, p. 4374-4387, 2021.

MICKEVICIUS, N. J.; CARLE, A. B.; BLUEMEL, T.; SANTARRIAGA, S.; SCHLOEMER, F.; SHUMATE, D.; LAVIOLETTE, P. S. Location of brain tumor intersecting white matter tracts predicts patient prognosis. **Journal of Neuro-oncology**, v. 125, n. 1, p. 393-400, 2015.

SHARIF, M. I.; LI, J. P.; KHAN, M. A.; SALEEM, M. A. Active deep neural network feature selection for segmentation and recognition of brain tumors using MRI images. **Pattern Recognition Letters**, v. 129, p. 181-189, 2020.

SOCIEDADE BRASILEIRA DE CIRURGIA ONCOLÓGICA. **Câncer de Cérebro: Tudo que você precisa saber sobre a doença**. 2022. Disponível em: <https://sbco.org.br/cancer-de-cerebro-tudo-que-voce-precisa-saber-sobre-a-doenca/> Acesso em: 30 out. 2023.

ULLAH, Z.; FAROOQ, M. U.; LEE, S. H.; AN, D. A hybrid image enhancement-based brain MRI images classification technique. **Medical Hypotheses**, v. 143, p. 109922, 2020.

UNICAMP. Departamento de Neurologia. **Neuropatologia e Neuroimagem**. Banco de imagens e textos. s.d. Disponível em: <https://anatpat.unicamp.br/neuro1.html>. Acesso em: 30 out. 2023.

WATEGAONKAR, S.; WADWANI, R.; SORATE, H.; VIBHUTE, S.; YADAV, R. Noble approach to locate brain tumor using deep convolution technique. In: **2023 7th International Conference on Intelligent Computing and Control Systems (ICICCS)**, 2023, p. 87-92. IEEE.