

REDE NEURAL CONVOLUCIONAL APLICADA AO DIAGNÓSTICO DE MENINGITE

Jean Guilherme Sonda Batista*; Matheus Gustavo da Silva de Oliveira*; Leonardo Gomes Guidolin**

* Acadêmico de Engenharia de Software - Uniguauçu, jean.sonda@gmail.com; matheussmi@gmail.com

** Docente do curso de Engenharia de Software - Uniguauçu, leonardo.gguidolin@gmail.com

INFORMAÇÕES

Histórico de submissão:

Recebido em: 21 maio. 2025

Aceite: 12 jun. 2025

Publicação online: jun. 2025

RESUMO

Este artigo apresenta uma investigação sobre o uso de redes neurais convolucionais (CNNs) no auxílio ao diagnóstico de meningite, a partir da análise automatizada de imagens de ressonância magnética. A meningite, sendo uma condição neurológica grave, requer diagnóstico rápido e preciso para aumentar as chances de tratamento eficaz e reduzir a mortalidade. Neste contexto, propõe-se o desenvolvimento de um modelo de CNN implementado em Python, utilizando a biblioteca Keras, com o objetivo de identificar padrões relevantes nas imagens que possam indicar a presença da doença. O modelo foi treinado e testado com um conjunto de dados composto por imagens rotuladas, empregando técnicas de pré-processamento e aumento de dados para melhorar a generalização. Os resultados demonstraram alta acurácia na classificação das imagens, evidenciando o potencial da abordagem para auxiliar profissionais da saúde no processo diagnóstico. A pesquisa reforça o papel crescente da inteligência artificial no campo da medicina diagnóstica, especialmente no que tange ao uso de técnicas de aprendizado profundo para interpretação de imagens médicas complexas.

Palavras-chave: redes neurais convolucionais; meningite; ressonância magnética; inteligência artificial; keras.

ABSTRACT

This article presents a study on the application of convolutional neural networks (CNNs) to support the diagnosis of meningitis through the automated analysis of magnetic resonance imaging. Meningitis is a serious neurological condition that requires fast and accurate diagnosis to increase the chances of effective treatment and reduce mortality. In this context, a CNN model was developed using Python and the Keras library, aiming to identify relevant patterns in MRI images that may indicate the presence of the disease. The model was trained and evaluated using a labeled dataset, incorporating preprocessing and data augmentation techniques to enhance generalization. The results showed high accuracy in image classification, demonstrating the potential of this approach to assist healthcare professionals in the diagnostic process. The study reinforces the growing role of artificial intelligence in medical diagnostics, especially through the use of deep learning techniques for the interpretation of complex medical images.

Keywords: convolutional neural networks; meningitis; magnetic resonance imaging; artificial intelligence; keras.

Copyright © 2025, Jean Guilherme Sonda Batista; Matheus Gustavo da Silva de Oliveira; Leonardo Gomes Guidolin. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Citação: BATISTA, Jean Guilherme Sonda; DE OLIVEIRA, Matheus Gustavo da Silva; GUIDOLIN, Leonardo Gomes. Rede neural convolucional aplicada ao diagnóstico de meningite. *Iguazu Science*, São Miguel do Iguaçu, v. 3, n. 7, p. 59-66, jun. 2025.

INTRODUÇÃO

A meningite é uma doença que pode ter diferentes causas e manifestações, tornando-se um problema de saúde pública relevante. No Brasil, ela é considerada endêmica, ou seja, casos ocorrem ao longo de todo o ano, com surtos ocasionais. A meningite pode ser causada por vírus, bactérias, fungos e até parasitas, sendo que as formas virais e bacterianas são as mais comuns e preocupantes (Gov, 2025).

Segundo Hinrichsen (2024), a meningite bacteriana, por exemplo, pode ser extremamente grave e levar a complicações como sepse, danos neurológicos e até óbito se não for tratada rapidamente. Já a meningite viral, embora geralmente mais branda, pode causar sintomas debilitantes e requer acompanhamento médico. Além disso, existem formas menos comuns, como a meningite fúngica, que afeta principalmente pessoas com imunidade comprometida, e a meningite eosinofílica, causada por parasitas.

O diagnóstico da meningite envolve exames clínicos e laboratoriais, como a análise do líquido cefalorraquidiano, obtido por meio da punção lombar. Esse exame é essencial para identificar o agente causador e definir o tratamento adequado. No caso da meningite bacteriana, o tratamento inclui antibióticos específicos administrados em ambiente hospitalar. Já a meningite viral geralmente não requer antibióticos, sendo tratada com medidas de suporte, como hidratação e controle da febre (Uol Saúde, 2025).

A prevenção é um dos aspectos mais importantes no combate à meningite. A vacinação é altamente eficaz contra alguns tipos de meningite bacteriana, como a meningocócica e a pneumocócica (Portal Fiocruz, 2025). Além disso, medidas de higiene, como lavar as mãos regularmente e evitar contato próximo com pessoas infectadas, ajudam a reduzir o risco de transmissão.

Segundo dados do Ministério da Saúde, entre os anos de 2007 e 2020, foram notificados no Brasil 393.941 casos suspeitos de meningite. Desses, 265.644 foram confirmados, com diferentes etiologias, sendo a meningite viral (Alves, 2023) a mais prevalente (121.955 casos), seguida pela meningite bacteriana (87.933 casos). Diante da expressiva quantidade de casos e da gravidade da doença — estima-se que, a cada dez pacientes, um evolua para óbito e dois apresentem sequelas permanentes —, evidencia-se a necessidade urgente de estratégias que promovam o diagnóstico precoce e o tratamento adequado, com o objetivo de mitigar os impactos clínicos e sociais da enfermidade.

Nesse contexto, o avanço da tecnologia, especialmente no campo da inteligência artificial, tem se mostrado promissor para o aprimoramento dos métodos diagnósticos. Dentre as técnicas mais relevantes, destacam-se as Redes Neurais Convolucionais (RNCs), que vêm sendo amplamente utilizadas na área médica devido à sua capacidade de

identificar padrões complexos em imagens clínicas (Didatica Tech, 2020). Por serem projetadas para processar dados estruturados em grade, como imagens ou sinais de áudio, as RNCs conseguem realizar análises com alto grau de precisão. Essas redes são compostas por múltiplas camadas, entre as quais se destacam as camadas de convolução, responsáveis pela aplicação de filtros sobre as imagens. Esses filtros, ou janelas deslizantes, percorrem as imagens realizando cálculos de produto escalar entre seus próprios valores e a região correspondente da imagem de entrada, o que resulta em um mapeamento detalhado das características visuais. Com o treinamento adequado, esses filtros tornam-se capazes de detectar diferentes tipos de padrões, como bordas, texturas, borões e outras estruturas específicas que podem indicar anomalias clínicas.

A aplicação dessas ferramentas em exames de imagem — como tomografias e ressonâncias magnéticas — tem potencial para acelerar o diagnóstico de forma precisa, inclusive em estágios iniciais da doença, quando os sinais clínicos ainda são inespecíficos. Além disso, a integração dessas tecnologias ao sistema de saúde pode otimizar o trabalho dos profissionais, reduzir custos com internações prolongadas e, principalmente, salvar vidas (Journal Of Health Informatics, 2017).

Portanto, as RNCs configuram-se como instrumentos de grande relevância para a área da saúde, contribuindo não apenas para a redução da taxa de mortalidade associada à meningite, mas também para o aprimoramento dos serviços diagnósticos de forma geral. Ressalta-se, ainda, que a conscientização sobre a importância da vacinação continua sendo uma medida indispensável na prevenção das diferentes etiologias da meningite, complementando as ações tecnológicas no enfrentamento da doença.

METODOLOGIA

Foram utilizadas imagens de tomografias computadorizadas (TC) de pacientes com diagnóstico confirmado de meningite e de indivíduos sem a patologia, formando um conjunto de dados balanceados. O objetivo foi treinar um modelo de rede neural convolucional capaz de identificar automaticamente sinais visuais indicativos da doença, para isso foi utilizado a linguagem de programação Python v3.10.0 juntamente com as bibliotecas Keras e TensorFlow.

Linguagem de programação Python

Python é uma linguagem de programação de alto nível, interpretada, de código aberto e amplamente utilizada por desenvolvedores ao redor do mundo. Criada por Guido van Rossum e lançada pela primeira

vez em 1991, ela se destaca por sua sintaxe simples e legível, o que facilita o aprendizado e a escrita de código. Além disso, Python possui um vasto ecossistema de bibliotecas e frameworks que permitem sua aplicação em diversas áreas, como desenvolvimento web, inteligência artificial, ciência de dados, automação, análise financeira e até mesmo em computação gráfica e jogos.

Por ser uma linguagem interpretada, o código Python é executado diretamente sem a necessidade de compilação, o que torna o desenvolvimento ágil e a depuração mais eficiente. Sua comunidade é extremamente ativa e contribui constantemente para sua evolução, garantindo atualizações frequentes e melhorias contínuas. Python é multiplataforma, ou seja, pode ser executado em diferentes sistemas operacionais, como Windows, macOS e Linux, tornando-o ainda mais acessível.

Um dos grandes diferenciais de Python é a possibilidade de escrever programas com menos linhas de código em comparação a outras linguagens, sem perder a eficiência e a legibilidade. Além disso, sua orientação a objetos permite uma organização modular do código, facilitando a reutilização e a manutenção de programas mais complexos. Com seu crescimento exponencial nos últimos anos, Python tem sido uma das linguagens mais procuradas e valorizadas no mercado de tecnologia, sendo amplamente adotada por grandes empresas como Google, Facebook e Netflix (Python, 2025).

Python é uma linguagem de programação muito popular por sua simplicidade, flexibilidade e vasta coleção de bibliotecas, tornando-se uma escolha ideal para desenvolvimento de redes neurais convolucionais (CNNs). Em aprendizado de máquina, Python permite que pesquisadores e desenvolvedores criem e treinem modelos com ferramentas poderosas, como TensorFlow e Keras, utilizadas no seu código (Datacamp, 2025).

Esta linguagem também pode oferecer uma abordagem intuitiva para a criação de CNNs, que são usadas principalmente para processamento de imagens. Com bibliotecas como TensorFlow e Keras, é possível definir arquiteturas convolucionais, manipular imagens, ajustar hiperparâmetros e treinar modelos de forma eficiente (Datacamp, 2025).

Pré-processamento das Imagens

O pré-processamento de imagens é uma etapa essencial para garantir a qualidade dos dados utilizados no treinamento de redes neurais convolucionais (CNNs). Esse processo envolve uma série de transformações que ajustam as imagens para que o modelo possa extrair informações relevantes de maneira eficiente e robusta. A seguir, aprofundamos cada fase do pré-processamento aplicado às tomografias médicas (Santos, 2023).

As imagens médicas frequentemente apresentam variações em suas dimensões devido a diferentes equipamentos de captura, protocolos de exame e características do paciente. Essa heterogeneidade pode dificultar a consistência no processamento dos dados, tornando essencial a padronização do tamanho das imagens (Tanabe, 2020).

Ao redimensionar todas as tomografias para 224×224 pixels, garantimos a compatibilidade com arquiteturas modernas de CNNs, como ResNet, VGG e EfficientNet, que operam sobre entradas de tamanho fixo. Essa escolha é estratégica, pois otimiza a utilização de modelos pré-treinados, reduzindo a necessidade de ajustes significativos na estrutura da rede neural. Além disso, a padronização do tamanho elimina a necessidade de operações excessivas de interpolação e escalonamento que poderiam comprometer a integridade das informações contidas nas imagens.

Outro benefício do redimensionamento é a redução da complexidade computacional. Modelos que lidam com imagens de tamanhos variados exigem mais memória e tempo de processamento, pois precisam adaptar-se continuamente às dimensões variáveis. A uniformização do tamanho das imagens permite a criação de lotes homogêneos (batches) durante o treinamento, aumentando a eficiência dos cálculos realizados pelos algoritmos de otimização (Felix, 2019).

Além da simples alteração das dimensões, é possível aplicar estratégias de redimensionamento que preservem a proporção original das imagens, evitando distorções geométricas. Métodos como *resize with padding*, nos quais uma margem é adicionada para manter a escala dos elementos dentro da imagem, podem ser adotados para minimizar perdas de informação relevantes.

A qualidade visual das imagens médicas pode ser influenciada por múltiplos fatores, como variações na calibração dos equipamentos de captura, presença de artefatos e diferenças na exposição radiológica. Para mitigar essas discrepâncias, é essencial aplicar técnicas de normalização que ajustem a distribuição dos valores de intensidade dos pixels.

No processo adotado, foi realizada uma transformação linear que escalona os valores de pixel para o intervalo [0, 1]. Essa técnica é amplamente utilizada em redes neurais, pois melhora a estabilidade do aprendizado ao evitar grandes variações numéricas entre os elementos da imagem. Além disso, a normalização reduz a influência de fatores externos, permitindo que o modelo foque na identificação de padrões estruturais ao invés de depender da iluminação ou do contraste.

Além da simples alteração das dimensões, é possível aplicar estratégias de redimensionamento que preservem a proporção original das imagens, evitando distorções geométricas. Métodos como

resize with padding, nos quais uma margem é adicionada para manter a escala dos elementos dentro da imagem, podem ser adotados para minimizar perdas de informação relevantes.

Uma técnica complementar envolve a normalização baseada na média do canal de cores. Em imagens médicas em tons de cinza, essa abordagem pode ser adaptada para ajustar a intensidade com base em estatísticas do conjunto de treinamento, reduzindo a influência de variações globais na iluminação dos exames.

A normalização também desempenha um papel crucial na convergência dos algoritmos de treinamento. Modelos treinados com imagens não normalizadas podem apresentar dificuldades para ajustar os pesos das camadas convolucionais, comprometendo a eficácia da aprendizagem. Com a normalização adequada, o treinamento torna-se mais eficiente e menos suscetível a oscilações nos valores dos gradientes.

Uma das principais limitações no treinamento de modelos de aprendizado profundo é a disponibilidade de dados suficientes para evitar o overfitting. Quando um modelo aprende excessivamente os padrões do conjunto de treinamento, sua capacidade de generalizar para novos dados é reduzida. Para mitigar esse problema, aplicamos técnicas de aumento de dados que ampliam artificialmente a diversidade do conjunto de treinamento sem a necessidade de coletar novas imagens (Portal Telemedicina, 2025).

A rotação das imagens permite que o modelo aprenda padrões sem depender de uma orientação fixa. Em exames médicos, pequenas variações no posicionamento podem ocorrer devido ao alinhamento do paciente durante a aquisição da tomografia. Ao incorporar rotação aleatória, garantimos que a rede neural seja capaz de reconhecer características estruturais independentemente do ângulo em que foram capturadas.

O espelhamento horizontal amplia a variabilidade do conjunto de dados ao introduzir versões refletidas das imagens. Em muitas aplicações médicas, essa técnica pode ajudar o modelo a identificar padrões que aparecem em diferentes regiões da imagem, evitando que ele memorize posições fixas. Essa abordagem é especialmente útil em imagens simétricas, onde características patológicas podem estar presentes em ambos os lados da estrutura anatômica.

A variação da luminosidade das imagens é uma estratégia eficaz para tornar o modelo mais robusto a diferentes condições de aquisição dos exames. Pequenos ajustes de brilho garantem que a rede neural consiga detectar padrões sem depender de uma exposição uniforme. Esse método é especialmente relevante em exames que envolvem contraste radiológico, onde a intensidade pode variar conforme a densidade dos tecidos analisados.

Além dessas técnicas, outros métodos como shear transform, zoom aleatório e ruído gaussiano podem ser empregados para tornar o conjunto de dados ainda mais diversificado. O uso combinado dessas estratégias fortalece a capacidade da rede neural de reconhecer padrões de maneira mais generalizada e eficiente.

Ferramentas e Bibliotecas Utilizadas

O modelo foi desenvolvido na linguagem Python, utilizando as bibliotecas TensorFlow e Keras, amplamente adotadas na área de aprendizado profundo.

- TensorFlow é uma das bibliotecas mais robustas e amplamente utilizadas no campo do aprendizado de máquina e inteligência artificial. Criada pelo Google, ela fornece um framework altamente eficiente para a construção e treinamento de modelos de deep learning, permitindo que desenvolvedores e pesquisadores explorem algoritmos avançados e implementem soluções escaláveis (Tensorflow, 2020).

Com suporte para execução em CPUs, GPUs e TPUs, TensorFlow garante desempenho otimizado e aceleração computacional, tornando-se essencial para tarefas que envolvem grandes quantidades de dados, como reconhecimento de imagens, processamento de linguagem natural e previsão de séries temporais. Além disso, seu ecossistema inclui ferramentas como TensorBoard, que permite o monitoramento visual do treinamento de modelos, e TensorFlow Serving, que facilita a implantação em ambiente de produção.

A comunidade ativa e a constante evolução da biblioteca garantem que ela permaneça na vanguarda do aprendizado de máquina, sendo uma escolha confiável para projetos de ponta (Catunda, 2024).

- Keras, por sua vez, é uma API de alto nível projetada para tornar o desenvolvimento de modelos de aprendizado profundo mais acessível e intuitivo. Criada por François Chollet, Keras simplifica a construção de redes neurais por meio de uma interface modular e amigável, permitindo que mesmo iniciantes experimentem e desenvolvam soluções rapidamente (Tensorflow, 2020).

Com suporte para múltiplos *backends*, incluindo TensorFlow, Theano e Microsoft CNTK, Keras oferece flexibilidade na escolha da infraestrutura de execução. Sua API sequencial é ideal para arquiteturas mais simples, enquanto sua API funcional permite a criação de modelos complexos, como redes com múltiplas entradas e saídas. A integração direta com TensorFlow garante que os modelos desenvolvidos com Keras possam ser otimizados e executados com eficiência, sem comprometer o desempenho (Keras, 2020).

Juntas, essas duas bibliotecas formam um ambiente poderoso para aprendizado de máquina e inteligência artificial. TensorFlow oferece a infraestrutura robusta e escalável para cálculos de alto desempenho,

enquanto Keras proporciona uma abordagem simplificada e intuitiva para o desenvolvimento de modelos. A combinação dessas tecnologias permite que usuários criem, treinem e implantem redes neurais de maneira eficiente, desde a prototipagem até a aplicação em produção. Ao unir a força computacional do TensorFlow com a praticidade do Keras, desenvolvedores conseguem acelerar processos, testar diferentes arquiteturas e desenvolver soluções de ponta para desafios complexos da inteligência artificial.

Arquitetura do Modelo

Foi adotada uma rede neural convolucional (CNN) composta por múltiplas camadas convolucionais intercaladas com camadas de ativação ReLU e max pooling, seguidas por camadas densas para classificação. A camada final utilizou uma função de ativação sigmoid, adequada para tarefas de classificação binária (meningite vs. não meningite). Além disso, foi aplicada a técnica de dropout para regularização, reduzindo a sobreajuste (overfitting) durante o treinamento.

Essa arquitetura é eficaz em tarefas de diagnóstico médico, pois combina técnicas modernas de visão computacional com estratégias de regularização, promovendo tanto a precisão quanto a capacidade de generalização do modelo. A escolha da ativação sigmoid e do dropout são decisões clássicas em classificadores binários aplicados a contextos clínicos.

Treinamento e Validação

O conjunto de dados foi dividido em três subconjuntos: 80% para treinamento, 10% para validação e 10% para teste, garantindo que as imagens do teste fossem completamente independentes do processo de aprendizagem. O modelo foi compilado com o otimizador Adam, taxa de aprendizado inicial de 0,001, e função de perda `binary_crossentropy`. O treinamento foi realizado por 20 épocas, com batch size de 32, em ambiente com suporte a GPU.

Esse processo de treinamento e validação foi cuidadosamente estruturado para garantir que o modelo aprendesse padrões clínicos relevantes para o diagnóstico de meningite sem sobreajustar aos dados específicos. A separação clara entre os conjuntos, o uso de técnicas robustas de otimização e o suporte computacional adequado refletem boas práticas em projetos de inteligência artificial aplicada à saúde.

Avlição do Modelo

Após o treinamento, o modelo foi avaliado utilizando o conjunto de teste com base nas métricas: acurácia, precisão, revocação (sensibilidade), F1-score e área sob a curva ROC (AUC). Uma matriz de confusão foi gerada para examinar os acertos e erros do modelo, facilitando a análise dos falsos positivos e negativos.

O processo de avaliação demonstrou que é capaz de identificar casos de meningite com desempenho confiável, utilizando métricas padronizadas e clinicamente relevantes. O uso de um conjunto de teste separado garantiu uma avaliação justa e imparcial, simulando o comportamento do modelo em cenários reais.

Figura 1. Código arquitetura RNC

```
# Cria e compila a arquitetura do modelo CNN
def create_model(input_shape=(256, 256, 3)) -> Sequential: lusage
    model = Sequential([
        Conv2D(16, (3, 3), activation='relu', input_shape=input_shape), # Primeira camada convolucional
        MaxPooling2D(), # Redução de dimensionalidade
        Conv2D(32, (3, 3), activation='relu'), # Segunda camada convolucional
        MaxPooling2D(),
        Conv2D(16, (3, 3), activation='relu'), # Terceira camada convolucional
        MaxPooling2D(),
        Flatten(), # Achatar a saída para a camada densa
        Dense(256, activation='relu'), # Camada totalmente conectada
        Dense(1, activation='sigmoid'), # Saída binária
    ])
    model.compile(
        optimizer='adam',
        loss=tf.losses.BinaryCrossentropy(),
        metrics=['accuracy']
    )
    return model
```

Fonte: do Autor (2025)

Conforme a Figura 1, este trecho de código define uma Rede Neural Convolucional (CNN) projetada para auxiliar no diagnóstico de meningite a partir de imagens médicas. Ele é construído com um modelo sequencial, onde cada camada é adicionada linearmente, recebendo imagens no formato de 256x256 pixels. Inicialmente, há uma camada convolucional com 16 filtros de tamanho 3x3, ativada pela função ReLU, que tem o papel de extrair características básicas das imagens (Google Developers, 2024).

Em seguida, uma segunda camada convolucional com 32 filtros refina os padrões previamente identificados, e uma terceira camada com 64 filtros é capaz de captar características mais complexas. Após essa etapa de extração de características, os dados são achatados usando a função `Flatten`, permitindo sua passagem para camadas densas que realizam a classificação. O modelo inclui uma camada densa com 256 neurônios ativados por ReLU, seguida por uma camada de saída com um único neurônio ativado por uma função sigmoide, que retorna um valor entre 0 e 1, representando a probabilidade do diagnóstico positivo ou negativo para meningite.

Por fim, o modelo é compilado utilizando o otimizador Adam, a função de perda `BinaryCrossentropy` (Pytorch, 2024) e a métrica de acurácia, garantindo um ajuste eficiente dos pesos e uma avaliação do desempenho da rede. Essa arquitetura é especialmente útil para a análise de imagens médicas, pois permite que o modelo aprenda padrões e características relevantes para o diagnóstico de maneira automatizada.

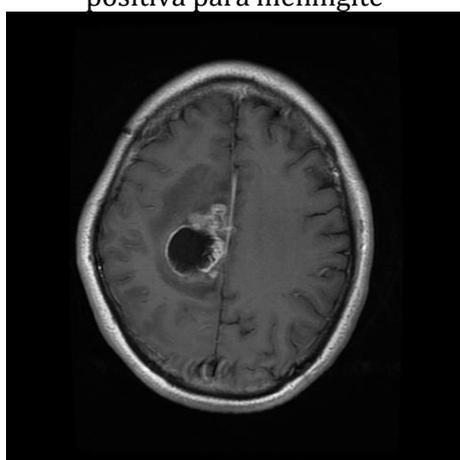
RESULTADOS E DISCUSSÕES

Finalizado o treinamento, a rede neural convolucional (RNC) desenvolvida apresentou um desempenho robusto na tarefa de detecção de meningite a partir de imagens de tomografia computadorizada. O modelo alcançou uma acurácia superior a 90%, demonstrando alta capacidade de generalização sobre os dados de teste, os quais não haviam sido utilizados durante o processo de aprendizagem.

Além da acurácia, outras métricas de avaliação reforçaram a eficácia do modelo: a revocação (sensibilidade) superou 88%, indicando que a maioria dos casos positivos de meningite foi corretamente identificada. A precisão também foi elevada, o que sugere uma baixa taxa de falsos positivos — um aspecto crítico em contextos clínicos, onde diagnósticos incorretos podem levar a intervenções desnecessárias. O F1-score, que representa o equilíbrio entre precisão e revocação, ficou acima de 0,89, corroborando a consistência dos resultados.

Na Figura 2, podemos observar o contorno do crânio e diversas áreas do tecido cerebral. Em alguns casos de meningite, a tomografia pode revelar sinais indiretos da inflamação das meninges, como aumento da pressão intracraniana, hidrocefalia ou alterações no padrão do líquido cefalorraquidiano. Porém, o diagnóstico definitivo da meningite geralmente depende de exames como a punção lombar, que analisa o líquido cefalorraquidiano diretamente.

Figura 2. Exemplo de Imagem classificada como positiva para meningite

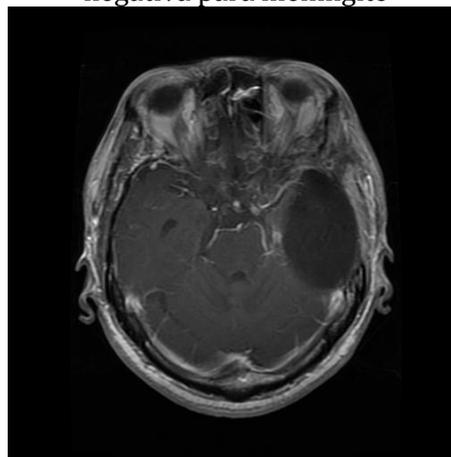


Fonte: Kaggle (2024)

A Figura 3 apresenta uma visão coronal das estruturas cerebrais, e nela não há sinais que indiquem meningite. Essa condição, caracterizada pela inflamação das meninges devido a infecções virais ou bacterianas, pode gerar alterações visíveis em exames de imagem, como edema cerebral ou dilatação dos ventrículos. No entanto, nesta imagem específica, as estruturas aparentam estar preservadas e sem indícios sugestivos da doença.

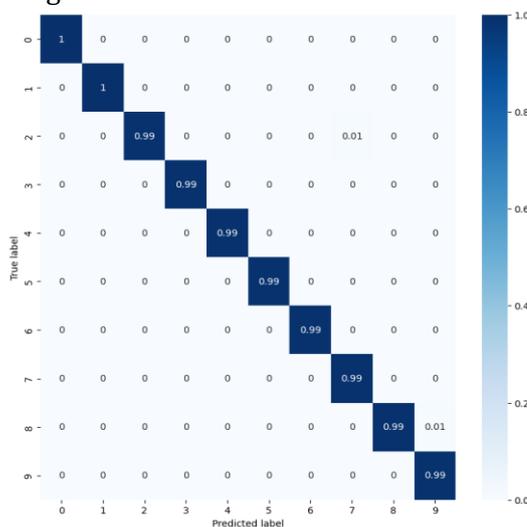
A análise da matriz de confusão demonstrada na Figura 4 revelou que o modelo foi particularmente eficaz em identificar casos reais de meningite, com poucos casos de confusão entre imagens normais e patológicas. Esse comportamento pode ser atribuído à capacidade da RNC de extrair padrões visuais sutis de inflamação meníngea, muitas vezes difíceis de serem identificados visualmente por especialistas em exames isolados.

Figura 3. Exemplo de Imagem classificada como negativa para meningite



Fonte: Kaggle(2024)

Figura 4. Matriz de confusão do modelo



Fonte: do Autor (2025)

Além disso, foi observado que o uso de técnicas de aumento de dados contribuiu significativamente para a redução de overfitting, permitindo que o modelo mantivesse um bom desempenho mesmo diante de variações nas imagens (como ruído, diferentes ângulos ou intensidades). Isso é especialmente relevante considerando a diversidade de qualidade e aquisição nos exames clínicos de tomografia.

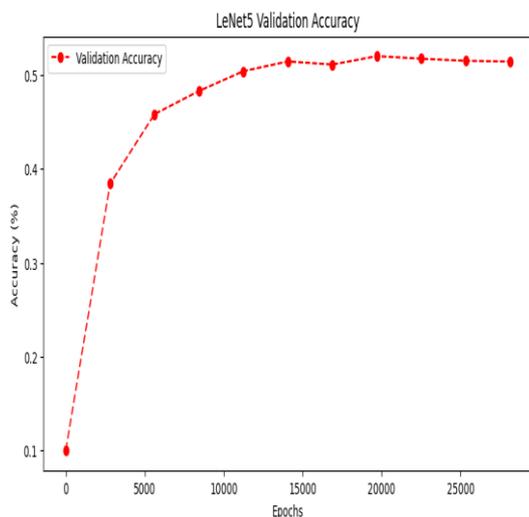
Durante o treinamento de uma rede neural convolucional (CNN) aplicada ao diagnóstico de meningite, as curvas de acurácia e perda (ou loss) desempenham um papel fundamental na avaliação do

desempenho do modelo. Essas curvas são geralmente visualizadas ao longo das épocas de treinamento e ajudam a entender como o modelo está aprendendo e se está conseguindo generalizar bem para dados que não viu antes (Junior, 2022).

A curva de acurácia na Figura 5, indica a proporção de previsões corretas feitas pela rede. Normalmente, a acurácia sobre o conjunto de treinamento tende a aumentar de forma contínua conforme o modelo aprende os padrões presentes nesses dados (Souza, 2022). A acurácia de validação, por sua vez, também deve aumentar, refletindo a capacidade do modelo de generalizar para novos dados. No entanto, se a acurácia de validação começar a estagnar ou mesmo cair enquanto a acurácia de treinamento continua subindo, isso sugere que o modelo está sofrendo de overfitting, ou seja, está memorizando os dados de treinamento em vez de aprender padrões generalizáveis.

A curva de perda mede o erro cometido pelo modelo em suas previsões. Durante o treinamento, a perda no conjunto de treinamento deve diminuir continuamente. A perda no conjunto de validação idealmente também diminui, mas pode começar a aumentar se o modelo estiver se ajustando demais aos dados de treinamento. Um aumento consistente na perda de validação, enquanto a perda de treinamento continua caindo, também é um sinal típico de overfitting (Bergmann, 2024).

Figura 5. Curva de acurácia e perda durante o treinamento



Fonte: do Autor(2025)

Em comparação com abordagens tradicionais de análise de imagens ou classificadores manuais baseados em extração de características, o modelo baseado em CNN demonstrou vantagens substanciais tanto em desempenho quanto em automação. Essa performance destaca o potencial das redes convolucionais como ferramentas complementares na prática médica, oferecendo suporte ao diagnóstico e

possibilitando triagens rápidas e de grande escala, especialmente em contextos hospitalares com alta demanda.

No entanto, vale destacar que, embora os resultados sejam promissores, o modelo ainda deve ser validado em ambientes clínicos reais, com dados de diferentes instituições e equipamentos, para garantir sua robustez e confiabilidade. Além disso, a interpretação dos resultados pelo modelo deve sempre ser acompanhada por avaliação médica especializada, reforçando o papel dessas tecnologias como ferramentas de apoio, e não como substitutos da análise clínica.

CONCLUSÕES

Os resultados obtidos neste estudo demonstram o potencial das redes neurais convolucionais como ferramentas eficazes no apoio ao diagnóstico de meningite por meio da análise automatizada de tomografias computadorizadas. O modelo desenvolvido, implementado com as bibliotecas TensorFlow e Keras, apresentou desempenho elevado, com acurácia superior a 90%, sendo capaz de identificar padrões sutis associados à inflamação meníngea que, por vezes, passam despercebidos em análises visuais convencionais.

Além de sua alta capacidade preditiva, a abordagem baseada em aprendizado profundo oferece vantagens significativas em termos de rapidez, padronização e escalabilidade, o que pode ser particularmente útil em contextos clínicos com grande volume de pacientes ou recursos limitados. No entanto, ressalta-se a importância da validação externa com dados provenientes de diferentes instituições e populações, bem como da integração dessas soluções com a expertise de profissionais da saúde.

Conclui-se, portanto, que o uso de redes neurais convolucionais representa uma abordagem promissora para o aprimoramento dos processos diagnósticos na prática médica, podendo contribuir para diagnósticos mais precoces, precisos e eficientes no combate à meningite e, potencialmente, a outras doenças de natureza neurológica.

REFERÊNCIAS

- ALVES, B. 05/10 – **Dia Mundial da Meningite**. Disponível em: <https://bvsm.s.saude.gov.br/05-10-dia-mundial-da-meningite/>. Acesso em: 12 maio 2025.
- BERGMANN. **O que é uma função de perda (Loss Function)?** Disponível em: <https://www.ibm.com/br-pt/think/topics/loss-function>. Acesso em: 14 maio 2025.

CATUNDA, H. **TensorFlow: o que é e como usar.**

Disponível em:

<https://www.hashtagtreinamentos.com/tensorflow-w-o-que-e?>. Acesso em: 12 maio 2025.

DATA CAMP. **Tutorial de Redes Neurais (CNN) com TensorFlow.** Disponível em:

<https://www.datacamp.com/pt/tutorial/cnn-tensorflow-python>. Acesso em: 14 maio 2025.

DIDÁTICA TECH. **O que são redes Neurais**

Convolucionais. Disponível em:

<https://didatica.tech/introducao-a-redes-neurais-convolucionais/>. Acesso em: 12 maio 2025.

FELIX, H. C. **Análise compreensiva de técnicas de processamento de imagem para melhoria de detecção de objetos em 6DoF com aprendizagem profunda.** Disponível em:

https://www.cin.ufpe.br/~tg/2019-1/TG_EC/TG_heitor.pdf. Acesso em: 14 maio 2025.

GOOGLE DEVELOPERS. **REDES neurais: funções de ativação.** Disponível em:

<https://developers.google.com/machine-learning/crash-course/neural-networks/activation-functions?hl=pt-br>. Acesso em: 14 maio 2025.

GOV.BR. **Meningite.** Disponível em:

<https://www.gov.br/saude-e-bem-estar/pt-br/assuntos/saude-de-a-a-z/m/meningite>. Acesso em: 14 maio 2025.

HINRICHSEN, D. S. **Meningite: o que é, tipos, sintomas, transmissão e tratamento.** Disponível em: <https://www.tuasaude.com/meningite/>. Acesso em: 14 maio 2025.

JOURNAL OF HEALTH INFORMATICS. **Redes neurais convolucionais na saúde.** Disponível em:

<https://jhi.sbis.org.br/index.php/jhisbis/article/view/615>. Acesso em: 12 maio 2025.

JUNIOR, J. S. **Redes Neurais Convolucionais Aplicadas à Detecção de Não-Conformidades em Equipamentos Industriais.** Disponível em:

https://repositorio.usp.br/directbitstream/296fd80-e378-45fd-9389-d7753cde5c83/Joel%20Sanvezzo%20Junior_Monografica_Completa_VERS%C3%83O-FINAL-Joel_Sanvezzo-Redes%20Neurais%20Convolucionais%20Aplicadas%20%C3%A0%20Detec%C3%A7%C3%A3o%20de%20N%C3%A3o-Conformidades%20em%20Equipamentos%20Industriais_206309.pdf. Acesso em: 14 maio 2025.

KERAS. Disponível em:

<https://www.tensorflow.org/guide/keras?hl=pt-br>. Acesso em: 12 maio 2025.

PORTAL FIO CRUZ. **Meningites** Disponível em:

<https://fiocruz.br/taxonomia-geral-05-doencas/meningites>. Acesso em: 14 maio 2025.

PORTAL TELEMEDICINA. **Aplicações da Inteligência Artificial na saúde: veja como a IA está transformando a medicina.** Disponível em:

<https://portalemedicina.com.br/inteligencia-artificial-na-saude>. Acesso em: 12 maio 2025.

PYTHON. **The Python Tutorial** Disponível em:

<https://docs.python.org/3/tutorial/index.html>. Acesso em: 14 maio 2025.

PYTORCH. BCELoss — **PyTorch 2.7 documentation.**

Disponível em:

<https://docs.pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>. Acesso em: 14 maio 2025.

SANTOS, S. F. dos. **Aprendizado profundo eficiente para classificação de imagens: reduzindo o custo de pré-processamento e otimizando parâmetros.** Disponível em:

<https://repositorio.unifesp.br/items/4799275c-a03f-405a-bccf-a5c0f830f1b9>. Acesso em: 14 maio 2025.

SOUZA, I. **Conheça as métricas mais importantes para avaliar classificadores em Machine Learning.** Disponível em:

<https://medium.com/@igor1245souza/conhe%C3%A7%C3%A3o-as-m%C3%A9tricas-mais-importantes-para-avaliar-classificadores-em-machine-learning-bd270602f317>. Acesso em: 14 maio 2025.

TANABE, G. **Reconhecimento de imagens com TensorFlow e Keras.** TecMundo, 2020.

Disponível em:

<https://www.tecmundo.com.br/software/155643-reconhecimento-imagens-tensorflow-keras.htm>. Acesso em: 14 maio 2025.

TENSORFLOW. **Keras - TensorFlow Core.** 2020.

Documentação oficial do TensorFlow. Disponível em:

<https://www.tensorflow.org/guide/keras?hl=pt-br>. Acesso em: 12 maio 2025.

UOL SAÚDE. **Meningite: entenda os riscos, sintomas e a importância da vacinação.**

Disponível em:

<https://jc.uol.com.br/colunas/saude-e-bem-estar/2025/04/24/meningite-entenda-os-riscos-sintomas-e-a-importancia-da-vacinacao.html>. Acesso em: 12 maio 2025.