

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X**CONSTRUCTION OF A CONVOLUTIONAL NEURAL NETWORK MODEL FOR DETECTION OF PULMONARY DISEASES IN X-RAY IMAGES****CONSTRUCCIÓN DE UN MODELO DE RED NEURONAL CONVOLUCIONAL PARA DETECCIÓN DE ENFERMEDADES PULMONARES EN IMÁGENES DE RAYOS X**

Vladimir Costa de Alencar¹, Elias Dias Costa Neto², Jefferson Vieira dos Santos³, Érika Fialho Moraes Xavier⁴,
Sílvio Fernando Alves Xavier Junior⁵, Tiago Alessandro Espínola Ferreira⁶

e6106849

<https://doi.org/10.47820/recima21.v6i10.6849>

PUBLICADO : 10/2025

RESUMO

Em 2019, infecções respiratórias inferiores impactaram cerca de 489 milhões de pessoas no mundo, sendo a pneumonia responsável por aproximadamente 4 milhões de mortes anuais, representando 7% do total de óbitos. Essa doença é uma das principais causas de mortalidade global, com maior impacto em países em desenvolvimento, especialmente entre crianças menores de 5 anos e idosos acima de 70 anos. O diagnóstico de doenças pulmonares frequentemente utiliza radiografias torácicas, que revelam a gravidade por meio de opacidades pulmonares e acúmulo de líquido pleural. Este estudo desenvolveu um modelo baseado em Redes Neurais Convolucionais (CNN) para detectar automaticamente patologias pulmonares em imagens de raios-X. O modelo obteve uma acurácia superior a 80%, com a matriz de confusão indicando 91,8% de precisão para casos sem alterações e 69,5% para casos patológicos. A solução foi integrada a uma aplicação web para classificação de imagens radiográficas.

PALAVRAS-CHAVE: Aprendizado Profundo. Redes Convolucionais. Patologias Pulmonares.

ABSTRACT

In 2019, lower respiratory infections affected approximately 489 million people worldwide, with pneumonia accounting for around 4 million annual deaths, representing 7% of all fatalities. This disease is one of the leading causes of global mortality, with the greatest impact in developing countries, particularly among children under five and elderly individuals over seventy years old. The diagnosis of pulmonary diseases frequently relies on chest X-rays, which reveal severity through pulmonary opacities and pleural fluid accumulation. This study developed a model based on Convolutional Neural Networks (CNN) to automatically detect pulmonary pathologies in X-ray images. The model achieved an accuracy above 80%, with the confusion matrix indicating 91.8% precision for normal cases and 69.5% for pathological cases. The solution was integrated into a web application for the classification of radiographic images.

KEYWORDS: Deep Learning. Convolutional Neural Networks. Lung Pathologies.

¹ Professor de doutorado, pesquisador, escritor e engenheiro de inteligência artificial. Doutorado em Recursos Naturais com ênfase em modelos de otimização baseados em programação linear (UFCG, Brasil). Mestrado em Ciência da Computação (UFCG, Brasil). Diplomado em Ciência da Computação (UFCG, Brasil) e Radiologia (Faculdade Mauricio de Nassau, Brasil). Professor e Pesquisador da Universidade Estadual da Paraíba (UEPB), Campina Grande, PB, Brasil.

² Universidade Estadual da Paraíba.

³ Mestrando em Biometria e Estatística Aplicada - UFRPE - Universidade Federal Rural de Pernambuco.

⁴ Professora no Departamento de Estatística - UEPB. Pesquisadora vinculada ao CIDACS - BA. Universidade Federal Rural de Pernambuco.

⁵ Universidade Estadual da Paraíba.

⁶ Professor Titular do DEINFO - UFRPE - Universidade Federal Rural de Pernambuco.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvia Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

RESUMEN

En 2019, las infecciones respiratorias inferiores afectaron a aproximadamente 489 millones de personas en todo el mundo, siendo la neumonía responsable de alrededor de 4 millones de muertes anuales, lo que representa el 7% del total de fallecimientos. Esta enfermedad es una de las principales causas de mortalidad a nivel global, con mayor impacto en países en desarrollo, especialmente en niños menores de 5 años y adultos mayores de 70 años. El diagnóstico de enfermedades pulmonares suele basarse en radiografías torácicas, que revelan la gravedad mediante opacidades pulmonares y acumulación de líquido pleural. Este estudio desarrolló un modelo basado en Redes Neuronales Convolucionales (CNN) para detectar automáticamente patologías pulmonares en imágenes de rayos X. El modelo alcanzó una precisión superior al 80%, con una matriz de confusión que indicó un 91,8% de exactitud para casos normales y un 69,5% para casos patológicos. La solución se integró en una aplicación web para la clasificación de imágenes radiográficas.

PALABRAS CLAVE: Aprendizaje Profundo. Redes Convolucionales. Patologías Pulmonares.

1. INTRODUÇÃO

A pneumonia permanece entre as principais causas de mortalidade mundial, impactando milhões de indivíduos a cada ano (Vos *et al.*, 2020; Komiya *et al.*, 2016). Estimativas do *Global Burden of Diseases* (2019) apontam que aproximadamente 489 milhões de pessoas foram acometidas pela enfermidade, resultando em cerca de 4 milhões de óbitos — o que representa 7% das mortes globais no período (GBD 2019 Diseases and Injuries Collaborators, 2020). As populações pediátricas e idosas figuram entre as mais vulneráveis, especialmente em países com condições sanitárias e nutricionais limitadas (Walker *et al.*, 2013).

A pneumonia caracteriza-se como uma infecção respiratória que compromete os alvéolos e as vias aéreas inferiores, podendo evoluir com elevada morbimortalidade (Torres *et al.*, 2021). Sua etiologia é multifatorial e inclui bactérias, vírus e fungos, com variações regionais marcantes na prevalência dos agentes causadores (Jain *et al.*, 2015). O quadro clínico é composto por sintomas respiratórios e sistêmicos, sendo o diagnóstico confirmado pela integração entre a avaliação clínica e os exames radiológicos (Wunderink *et al.*, 2017).

O diagnóstico preciso é essencial para o manejo terapêutico adequado, uma vez que o atraso na identificação do agente infeccioso pode levar a complicações graves e óbito (Metersky *et al.*, 2017). A radiografia torácica constitui um dos exames mais acessíveis e úteis para a detecção e o acompanhamento da pneumonia, permitindo avaliar a extensão da infecção e suas manifestações, como derrames pleurais e opacidades pulmonares (Torres *et al.*, 2021; Franquet *et al.*, 2018).

Entre os principais métodos diagnósticos de doenças pulmonares, incluem-se radiografia de tórax, tomografia computadorizada, ressonância magnética e broncoscopia (Nas *et al.*, 2021; Khan *et al.*, 2021). Contudo, a interpretação de radiografias pode ser desafiadora devido à



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvio Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

sobreposição de padrões com outras doenças pulmonares, o que pode gerar divergências entre avaliadores (Jahan *et al.*, 2021).

O uso de técnicas de aprendizado de máquina (machine learning) tem se mostrado promissor para auxiliar na interpretação de imagens médicas, permitindo automatizar o processo diagnóstico (Goodfellow *et al.*, 2017; Krizhevsky *et al.*, 2012). Em especial, métodos baseados em *deep learning* demonstram elevada capacidade de reconhecer padrões complexos, contribuindo para diagnósticos mais rápidos e precisos (Rajpurkar *et al.*, 2017). De acordo com Kong e Cheng (2021), o *deep learning* possibilita que algoritmos processem imagens de forma autônoma, extraindo e abstraindo informações relevantes.

Considerando o papel essencial dos radiologistas e o caráter intensivo do processo de análise de imagens, a incorporação de sistemas automatizados baseados em redes neurais pode otimizar o diagnóstico e reduzir a sobrecarga de trabalho (Liang; Zheng, 2020). Assim, o presente estudo propõe o desenvolvimento de um modelo preditivo baseado em *deep learning* voltado à identificação de pneumonia e outras doenças pulmonares em radiografias de tórax.

2. MÉTODOS

2.1. Redes Neurais Artificiais (RNAs)

Redes Neurais Artificiais (RNAs) são sistemas computacionais formados por unidades elementares — os neurônios artificiais — organizadas em camadas interconectadas. Cada neurônio recebe entradas numéricas que são ponderadas por parâmetros sinápticos; esses sinais ponderados são agregados e transformados por uma função de ativação, produzindo a saída da unidade (Haykin, 2000). A aprendizagem na RNA consiste na adaptação desses pesos por meio de algoritmos que minimizam uma função de erro, permitindo que a rede generalize padrões a partir de exemplos fornecidos.

Estruturalmente, as RNAs típicas dispõem-se em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A capacidade de modelar relações não lineares torna essas arquiteturas indicadas para problemas complexos, nos quais a relação entre variáveis não é conhecida a priori. Além disso, RNAs podem ser ajustadas para aplicações diversas — regressão, classificação e reconhecimento de padrões — mediante escolhas apropriadas de arquitetura, função de ativação e método de treinamento (Spörl *et al.*, 2011).

Em aplicações com imagens, por exemplo, os vetores de entrada representam valores de pixels, e as redes aprendem representações internas que capturam características relevantes sem necessidade de extração manual. Contudo, o desempenho depende fortemente da qualidade dos dados, do volume de amostras e do cuidado na regularização e validação do modelo, a fim de evitar o sobreajuste e garantir boa capacidade de generalização.

Na estrutura de uma rede neural artificial (Figura 1), o neurônio artificial atua como o

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

elemento básico de processamento. Cada uma de suas entradas recebe um valor numérico associado a um peso, que representa a intensidade da conexão com outras unidades. Esses valores ponderados são então combinados — geralmente por meio de uma soma — e o resultado passa por uma função de ativação, responsável por determinar o nível de resposta do neurônio diante do estímulo recebido (Haykin, 2000).




Figura 1. Neurônio artificial Fonte: Adaptado de Mohri & Talwalkar, 2012

Em uma rede neural artificial, cada unidade processa informações recebidas de múltiplas entradas representadas por $x = [x_1, x_2, \dots, x_N]$, ponderadas por coeficientes sinápticos $w = [w_1, w_2, \dots, w_N]$. O estímulo interno do neurônio, indicado por z , resulta da soma ponderada das entradas e de um valor de polarização b , conforme expresso em (Haykin, 2000).

$$z = \sum_{i=1}^N x_i w_i + b \quad (1)$$

2.2. Backpropagation

O processo de *backpropagation* constitui o núcleo do aprendizado supervisionado em redes neurais profundas, pois possibilita o ajuste sistemático dos pesos de conexão com base na diferença entre a saída obtida e o valor esperado. Por meio da derivação da função de erro em relação a cada parâmetro, o algoritmo identifica a direção de maior redução do erro e atualiza os pesos de forma iterativa até atingir um ponto de equilíbrio (Werbos, 1974; Rumelhart *et al.*, 1985).

A operação ocorre em duas etapas complementares:

1. Fase direta, em que os sinais atravessam a rede até a obtenção da resposta;
2. Fase inversa, que propaga o erro calculado em sentido contrário, promovendo a correção gradual dos parâmetros sinápticos.

Esse mecanismo, repetido por várias iterações, conduz o modelo à minimização da função de custo e à estabilização do aprendizado.

2.3. Deep Learning

O aprendizado profundo (*Deep Learning*, DL) é um subcampo da aprendizagem de máquina voltado à extração automática de representações complexas por meio de redes neurais compostas por múltiplas camadas ocultas. Cada camada processa as informações recebidas e transmite sua saída como entrada para a próxima, formando uma estrutura hierárquica de transformações. A primeira camada é denominada camada de entrada, pois recebe diretamente os dados originais; a última é a camada de saída, responsável pelas previsões; e as intermediárias são as camadas ocultas, nas quais ocorre a extração progressiva de características.

Esse paradigma tornou-se viável com o avanço do poder computacional, especialmente das GPUs, e com a ampliação dos conjuntos de dados disponíveis, fatores que impulsionaram sua aplicação em tarefas como visão computacional, processamento de linguagem natural e diagnóstico automatizado em saúde (Goodfellow *et al.*, 2017; Raschka; Mirjalili, 2017; Mendes *et al.*, 2023; Santana, 2019).

A Figura 2 ilustra o fluxo de informação em uma rede neural profunda, no qual cada camada realiza operações matemáticas simples — como combinações lineares e funções de ativação — que, em conjunto, permitem à rede representar relações não lineares complexas entre as variáveis de entrada e saída.




Figura 2. Rede Perceptron Multicamadas (MLP), Fonte: Adaptado de Mohri, 2012

As arquiteturas de *deep learning* são altamente complexas e requerem grandes volumes de dados, o que torna indispensável o uso de recursos computacionais avançados. O treinamento desses modelos depende da execução paralela em GPUs, capazes de processar milhões de operações simultâneas, enquanto a CPU atua em tarefas sequenciais. O desenvolvimento do DL só se tornou viável com o avanço das tecnologias de computação paralela, do uso de CUDA e da consolidação do *Big Data*, conforme ilustrado na Figura 3 (Santana, 2019; Raschka; Mirjalili, 2017; Mendes *et al.*, 2023).




Figura 3. Uso da CPU X Uso da GPU. Fonte: Mendes *et al.*, 2023

A principal vantagem das arquiteturas de *deep learning* reside na capacidade de conectar múltiplos neurônios artificiais em estruturas complexas, capazes de representar e solucionar problemas de alta dimensionalidade.

Essas arquiteturas podem assumir diferentes formas, como as redes Multilayer Perceptron (MLP), compostas por dezenas ou até milhares de camadas; as *Convolutional Neural Networks* (CNNs), especializadas em análise e processamento de imagens; e as *Long Short-Term Memory* (LSTM), voltadas à interpretação de sinais temporais e de voz, entre outras variantes (Goodfellow *et al.*, 2017).

2.4. Redes Neurais Convolucionais (CNN - *Convolutional Neural Network*)

As Redes Neurais Convolucionais (CNNs) constituem uma categoria de modelos de aprendizado profundo especialmente projetada para processar dados que apresentam organização espacial, como imagens bidimensionais. Inspiradas na estrutura do córtex visual humano, essas redes utilizam camadas convolucionais que funcionam como filtros treináveis, capazes de identificar automaticamente padrões locais — como contornos, formas e texturas — diretamente a partir das amostras de entrada.

Diferentemente das abordagens tradicionais, nas quais os filtros precisavam ser definidos manualmente, as CNNs aprendem autonomamente as representações mais relevantes durante o processo de treinamento (Goodfellow *et al.*, 2017; Mendes *et al.*, 2023).

Uma arquitetura típica combina múltiplas camadas convolucionais, funções de ativação não lineares (por exemplo, ReLU), camadas de *pooling* para redução da dimensionalidade e, ao final, um conjunto de camadas densas responsáveis pela etapa de classificação. Essa organização permite capturar relações espaciais de maneira eficiente e, ao mesmo tempo, reduzir o número total de parâmetros, o que favorece a generalização do modelo. Em aplicações médicas, as CNNs têm

se mostrado eficazes para a análise de radiografias e detecção de anomalias pulmonares (Dettmers, 2015; Goodfellow *et al.*, 2017).

Em comparação a outros métodos de classificação, as CNNs demandam um pré-processamento significativamente menor, pois aprendem automaticamente os filtros e características mais relevantes, eliminando a necessidade de ajustes manuais (Goodfellow *et al.*, 2017).

A estrutura de conectividade das CNNs reflete, em parte, o comportamento observado no sistema visual biológico. Cada neurônio convolucional responde a estímulos provenientes de uma pequena região da imagem — denominada campo receptivo — e o conjunto desses campos sobrepostos cobre todo o espaço visual, permitindo uma representação completa da cena (Goodfellow *et al.*, 2017; Mendes *et al.*, 2023).

De modo geral, uma CNN pode ser dividida em duas grandes etapas:

1. Aprendizado de características (*Feature Learning*), no qual a rede extrai padrões e componentes de baixo e alto nível da imagem (como bordas, formas e estruturas específicas);
2. Classificação, etapa em que as características aprendidas são transformadas em uma representação unidimensional (*Flatten*) e processadas por camadas densas e uma ativação final *Softmax*, responsável pela decisão de classe (ex.: pessoa, veículo etc.).

A Figura 4 apresenta o fluxo básico dessa arquitetura, que pode ser expandida com a adição de novas camadas ou funções específicas, conforme a complexidade da tarefa (Goodfellow *et al.*, 2017).




Figura 4. Arquitetura de Rede Neural Convolucional (*Convolutional Neural Network*)

Fonte: Mendes *et al.*, 2023

As Redes Neurais Convolucionais (CNNs) identificam automaticamente padrões espaciais e temporais presentes nas imagens por meio de filtros aprendidos durante o treinamento.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvia Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

Essa arquitetura reduz o número de parâmetros necessários e aproveita a reutilização de pesos, tornando o ajuste aos dados mais eficiente. As camadas convolucionais extraem características relevantes, ajustando-se à natureza da tarefa — como forma, cor ou textura — e, com isso, otimizam o reconhecimento de objetos e a diferenciação entre categorias visuais (Dettmers, 2015; Goodfellow *et al.*, 2017; Mendes *et al.*, 2023).

2.5. A curva ROC

A *Receiver Operating Characteristic* (ROC) é uma ferramenta estatística amplamente empregada na avaliação do desempenho de classificadores binários, com destaque para aplicações médicas e de aprendizado de máquina. Em contextos diagnósticos, os resultados são frequentemente classificados em categorias dicotômicas — como presença ou ausência de uma condição clínica. No entanto, muitos testes produzem resultados contínuos ou ordinais, exigindo a definição de um limiar (*threshold*) que determina a fronteira entre resultados positivos e negativos. Assim, a presença de uma doença pode ser inferida com base nesse ponto de corte (Nahm, 2022).

Originalmente, a curva ROC foi desenvolvida para mensurar a capacidade de distinguir entre sinal verdadeiro e ruído falso na detecção de radares durante a Segunda Guerra Mundial. Posteriormente, passou a ser aplicada em estudos psicológicos (Tanner; Swets, 1954; Lusted, 1971) e, mais tarde, consolidou-se como uma métrica essencial na medicina, auxiliando na avaliação da acurácia de testes diagnósticos (Lee *et al.*, 2020). A métrica associada — a área sob a curva (*Area Under the Curve*, AUC) — expressa a capacidade discriminativa global do modelo: quanto mais próxima de 1, maior é a eficiência na diferenciação entre classes positivas e negativas (Metz, 1978; Fawcett, 2006).

No presente estudo, a curva ROC foi aplicada para mensurar o desempenho do modelo CNN proposto, verificando sua habilidade em distinguir corretamente radiografias de pacientes com e sem patologias pulmonares. Essa abordagem complementa as informações fornecidas pela matriz de confusão, oferecendo uma análise mais ampla e precisa da performance do classificador.

3. RESULTADOS E DISCUSSÃO

3.1. Dados

Foram utilizados dois conjuntos de dados públicos amplamente disponibilizados para a comunidade científica, compostos por radiografias torácicas rotuladas como Normal ou Doença Pulmonar.

O conjunto de raios-X dos Estados Unidos foi obtido a partir do programa de controle de tuberculose do Departamento de Saúde e Serviços Humanos do Condado de Montgomery, em



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvia Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

Maryland (EUA). Esse acervo contém 138 imagens pósterio-anteriores no formato PNG, sendo 80 classificadas como normais e 58 com indícios radiográficos de tuberculose. Todas as imagens foram devidamente anonimizadas, garantindo a privacidade e a ética no uso dos dados.

O conjunto de raios-X da China originou-se do Hospital de Shenzhen, localizado na província de Guangdong, como parte de procedimentos clínicos de rotina. Esse conjunto é composto por 662 radiografias torácicas no formato PNG, das quais 326 foram rotuladas como normais e 336 apresentam sinais patológicos compatíveis com tuberculose.

Para a etapa experimental, os dados combinados foram divididos em 85% para treinamento e 15% para teste, assegurando uma amostra equilibrada entre as classes. Esses bancos de dados representam recursos de grande relevância para pesquisas em diagnóstico assistido por imagem, especialmente no contexto do aprendizado profundo aplicado à detecção automática de doenças pulmonares. Estudos como o de Fatti *et al.*, (2020) também analisaram bases de dados similares utilizando escalas comparáveis de avaliação.

3.2. Modelo CNN

O modelo proposto de *Convolutional Neural Network* (CNN) foi estruturado conforme apresentado na Tabela 1, contendo múltiplas camadas convolucionais (*Conv2D*), camadas de *Max Pooling* para redução espacial das imagens e camadas de *Dropout* destinadas à prevenção de *overfitting*. Ao todo, o modelo compreende 1.661.186 parâmetros treináveis, distribuídos entre os diferentes blocos de processamento.

Essa configuração possibilita à rede capturar padrões hierárquicos de textura e forma, reduzindo a complexidade do modelo sem comprometer sua capacidade de generalização. O balanceamento entre convolução, *pooling* e regularização assegura um desempenho estável durante o treinamento e a validação do modelo.

Tabela 1. Modelo CNN. Fonte: Autoria própria (2025)

Camada (tipo)	Output Shape	Parâmetros (quantitativo)
conv2d_18 (Conv2D)	(None, 94,94,32)	896
conv2d_19 (Conv2D)	(None, 92,92,32)	9248
conv2d_20 (Conv2D)	(None, 90, 90, 32)	9248
max_pooling2d_6 (MaxPooling2D)	(None, 45, 45, 32)	0
dropout_8 (Dropout)	(None, 45, 45, 32)	0
conv2d_21 (Conv2D)	(None, 43, 43, 64)	18496

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvia Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

conv2d_22 (Conv2D)	(None, 41, 41, 64)	36928
conv2D_23 (Conv2D)	(None, 39, 39, 64)	36928
max_pooling2d_7 (MaxPooling2D)	(None, 19, 19, 64)	0
dropout_9 (Dropout)	(None, 19, 19, 64)	0
conv2d_24 (Conv2D)	(None, 17, 17, 128)	73856
conv2d_25 (Conv2D)	(None 15, 15, 128)	147584
conv2d_26 (Conv2D)	(None, 13, 13, 128)	147584
max_pooling2d_8 (MaxPooling2D)	(None, 6, 6, 128)	0
dropout_10 (Dropout)	(None, 6, 6, 128)	0
flatten_2 (Flatten)	(None, 4608)	0
dense_4 (Dense)	(None, 256)	1179984
dropout_31 (Dropout)	(None, 256)	0
dense_5 (Dense)	(None, 2)	514

O modelo foi treinado com 250 épocas (*epochs*), utilizando o otimizador RMSProp (*Root Mean Square Propagation*), proposto por Geoffrey Hinton em seus cursos sobre redes neurais (*Neural Networks for Machine Learning*, Coursera). O RMSProp é amplamente reconhecido por sua capacidade de estabilizar o processo de aprendizado em redes profundas ao ajustar dinamicamente a taxa de aprendizado com base na média móvel dos gradientes quadráticos.

Diversos estudos recentes demonstram a eficiência desse otimizador em aplicações médicas. Tripatti *et al.*, (2021) reportaram uma precisão de 96,14% ao empregar RMSProp, superando os otimizadores Adam e SGD. De forma semelhante, Sharma *et al.*, (2022) verificaram desempenho superior do RMSProp na classificação de radiografias torácicas, enquanto Swapnarekha *et al.*, (2021) obtiveram acerto em 78 imagens infectadas por COVID-19 utilizando a mesma abordagem.

Para a avaliação do modelo, foram utilizadas as métricas de acurácia e matriz de confusão, assegurando uma análise detalhada do desempenho. Diversas combinações de hiperparâmetros foram testadas até a obtenção da configuração ideal, que apresentou acurácia de treino de 81,77%, validação de 80,83% e teste de 80,65%, conforme ilustrado nas Figuras 5 e 6.




Figura 5. Acurácia do modelo em treinamento




Figura 6. Acurácia modelo de validação

A matriz de confusão é amplamente reconhecida como uma das principais ferramentas para a avaliação de sistemas de aprendizado profundo e de máquina, sendo considerada o padrão-ouro na mensuração do desempenho de classificadores. Essa matriz organiza os resultados do modelo em quatro categorias: Verdadeiros Positivos (VP) e Verdadeiros Negativos (VN), que representam

as classificações corretas, e Falsos Positivos (FP) e Falsos Negativos (FN), que correspondem aos erros de predição.

No contexto deste estudo, VP refere-se às radiografias corretamente identificadas como portadoras de tuberculose, enquanto VN designa as imagens corretamente reconhecidas como normais. FP indica radiografias normais incorretamente classificadas como tuberculose, e FN representa casos de tuberculose diagnosticados erroneamente como normais.

Estudos prévios reforçam a relevância dessa métrica. Fatti *et al.* (2020) relataram que o sistema ResNet-50 + SVM atingiu precisão de 92,3% para a classe *normal* e 98,5% para *tuberculose*. De modo semelhante, o modelo GoogLeNet + SVM obteve 96,9% e 97,0%, respectivamente, para as mesmas categorias.

No presente trabalho, a análise da matriz de confusão indicou uma acurácia de 91,8% para a classe *Normal* — correspondente à categoria com maior número de amostras — e 69,5% para a classe *Doença Pulmonar*. Observou-se que, mesmo no melhor modelo, 18 das 59 imagens de tuberculose foram classificadas incorretamente como normais, enquanto 5 das 61 radiografias normais foram categorizadas de forma equivocada como tuberculose. Esses resultados são consistentes com os achados de Rahman *et al.* (2020), que reportaram proporções semelhantes em conjuntos de dados de raios-X torácicos voltados à detecção de tuberculose.




Figura 7. Matriz de Confusão

Apresentam-se na figura 8 as métricas de desempenho do modelo (*recall*, *precision*, *accuracy* e *f1-score*). Portanto, as equações padrão utilizadas para mensurar o desempenho dos

sistemas obtêm seus dados por meio da matriz de confusão.

Melhor Epoca do modelo: 139
Acurácia do Modelo em treino (train_acc): 0.81765
Acurácia do Modelo em Validação (val_acc): 0.80833

Relatório do Modelo em Teste				
	precision	recall	f1-score	support
Normal	0.76	0.92	0.83	61
Tuberculose	0.89	0.69	0.78	59
accuracy			0.81	120
macro avg	0.82	0.81	0.81	120
weighted avg	0.82	0.81	0.81	120

Figura 8. Métricas utilizadas para avaliar o modelo em estudo

Uma característica relevante da *Receiver Operating Characteristic* (ROC) é sua independência em relação às proporções entre casos e controles dentro da amostra avaliada para uma determinada condição clínica. Essa propriedade garante que a estimativa da curva ROC permaneça estável, mesmo diante de variações na distribuição das classes (Metz, 1978). De maneira análoga ao estudo de Sathitratanacheewin *et al.*, (2020), as curvas ROC e as respectivas áreas sob a curva (*Area Under the Curve* – AUC) foram utilizadas neste trabalho para mensurar o desempenho do modelo e determinar o ponto de corte ideal para a detecção de tuberculose. O classificador de melhor desempenho alcançou $AUC = 0,81$, indicando boa capacidade discriminativa. Os modelos pré-treinados apresentaram valores de AUC superiores aos modelos não treinados, diferença estatisticamente significativa ($p < 0,001$). A Figura 9 ilustra graficamente o comportamento do modelo ajustado, evidenciando sua eficiência na distinção entre imagens normais e aquelas com sinais patológicos pulmonares.




Figura 9. Curva ROC



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvio Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

Os resultados obtidos confirmam a eficácia das redes neurais convolucionais como ferramentas promissoras para o diagnóstico automatizado de doenças pulmonares a partir de radiografias torácicas. A acurácia próxima de 80% observada neste estudo está em consonância com achados prévios de Rajpurkar *et al.*, (2017) e Rahman *et al.*, (2020), que relataram desempenhos variando entre 76% e 90%, conforme o balanceamento amostral e a complexidade das arquiteturas aplicadas. Esses resultados evidenciam que, mesmo sob limitações de dados e infraestrutura computacional, modelos de *deep learning* podem alcançar níveis de desempenho clínico relevantes, favorecendo triagens rápidas em contextos com carência de especialistas em radiologia.

Entretanto, foi identificado um desbalanceamento entre as classes “Normal” e “Doença Pulmonar”, refletido na diferença de acurácia observada — 91,8% e 69,5%, respectivamente. Esse tipo de desequilíbrio é recorrente em bases médicas e pode introduzir vieses que reduzem a sensibilidade do modelo (Chicco; Jurman, 2020). Estratégias como *data augmentation* e *transfer learning* e o uso de arquiteturas mais sofisticadas — como ResNet e EfficientNet (Tan; Le, 2019) — podem mitigar esse efeito, aprimorando a extração de características e promovendo maior equilíbrio entre as classes. Além disso, abordagens híbridas que combinam aprendizado supervisionado com mecanismos de atenção têm demonstrado desempenho superior em tarefas de diagnóstico por imagem (Dosovitskiy *et al.*, 2021).

A implementação do modelo em uma plataforma web amplia consideravelmente seu potencial de aplicação prática, sobretudo em cenários de atenção primária à saúde. Soluções dessa natureza, quando integradas a fluxos clínicos, contribuem para reduzir o tempo de diagnóstico e otimizar o uso de recursos hospitalares (Lundervold, 2019). Contudo, a adoção em ambientes reais requer validação clínica abrangente, utilização de bases de dados diversificadas e adesão a normas éticas e de privacidade, de modo a assegurar confiabilidade, segurança e responsabilidade no uso da inteligência artificial em contextos médicos.

4. CONSIDERAÇÕES

O modelo proposto, fundamentado em Redes Neurais Convolucionais (CNNs), demonstrou desempenho consistente na classificação de doenças pulmonares por meio de radiografias torácicas. Os resultados obtidos evidenciam acurácia global superior a 80% nas etapas de treinamento (81,77%), validação (80,83%) e teste (80,65%), confirmando a robustez do método.

A análise da matriz de confusão revelou desempenho expressivo, com 91,8% de acurácia para casos normais e 69,5% para casos patológicos. Essa diferença pode ser atribuída ao desbalanceamento entre as classes, visto que o número de amostras normais é significativamente maior. A implementação do modelo em um ambiente web representa um avanço relevante, ao disponibilizar uma ferramenta de suporte diagnóstico acessível e eficiente.

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Silvio Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

Tal aplicação é especialmente valiosa em regiões com alta incidência de doenças pulmonares e escassez de profissionais especializados, como em países em desenvolvimento e entre populações vulneráveis — crianças menores de cinco anos e idosos acima de setenta.

Para trabalhos futuros, propõe-se o aperfeiçoamento do modelo por meio da aplicação de técnicas de *data augmentation oversampling* a fim de mitigar o desbalanceamento entre as classes e elevar a acurácia da categoria “Doença Pulmonar”. Além disso, recomenda-se a exploração de arquiteturas mais avançadas, como *ResNet* e *Vision Transformers*, que podem potencializar a extração de características relevantes e aprimorar a capacidade de generalização do sistema em diferentes contextos clínicos.

REFERÊNCIAS

- CHICCO, D.; JURMAN, G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. **BMC Genomics**, v. 21, n. 1, p. 6, 2020.
- DETTMERS, T. Deep learning in a nutshell: Core concepts. **NVIDIA Developer Blog**, 2015. Disponível em: <https://devblogs.nvidia.com/deep-learning-nutshell-core-concepts>. Acesso em: 2 maio 2019.
- DOSOVITSKIY, A. *et al.* An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. **ICLR**, 2021.
- FATI, S. M.; SENAN, E. M.; ELHAKIM, N. Deep and hybrid learning technique for early detection of tuberculosis based on X-ray images using feature fusion. **Applied Sciences**, v. 12, n. 14, p. 7092, 2022.
- FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [S. l.]: MIT Press, 2017.
- HAYKIN, S. **Neural networks: A comprehensive foundation**. 2nd ed. [S. l.]: Prentice Hall, 2000.
- JAHAN, N.; ANOWER, M. S.; HASSAN, R. Automated diagnosis of pneumonia from classification of chest x-ray images using efficientnet. *In: 2021 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD)*. February 2021. p. 235–239.
- JAIN, S.; SELF, W. H.; WUNDERINK, R. G.; FAKHRAN, S.; BALK, R.; BRAMLEY, A. M.; GRIJALVA, C. G. Community-acquired pneumonia requiring hospitalization among U.S. adults. **New England Journal of Medicine**, v. 373, n. 5, p. 415–427, 2015. doi: 10.1056/NEJMoa1500245.
- KHAN, M. A.; KADRY, S.; ZHANG, Y. D.; AKRAM, T.; SHARIF, M.; REHMAN, A.; SABA, T. Prediction of COVID-19-pneumonia based on selected deep features and one class kernel extreme learning machine. **Computers & Electrical Engineering**, v. 90, p. 106960, 2021.
- KOMIYA, K.; ISHII, H.; KADOTA, J. Healthcare-associated pneumonia and aspiration pneumonia. **Respiration**, v. 92, n. 5, p. 307–317, 2016. doi: 10.1159/000449102

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

KONG, L.; CHENG, J. Based on improved deep convolutional neural network model pneumonia image classification. **PloS one**, v. 16, n. 11, e0258804, 2021.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. **Advances in Neural Information Processing Systems**, p. 1-9, 2012.

LEE, S.; CHO, H.R.; YOO, J. S.; KIM, Y.U. The prognostic value of median nerve thickness in diagnosing carpal tunnel syndrome using magnetic resonance imaging: a pilot study. **Korean Journal of Pain**, v. 33, p. 54–59, 2020. doi: 10.3344/kjp.2020.33.1.54.

LIANG, G.; ZHENG, L. A transfer learning method with deep residual network for pediatric pneumonia diagnosis. **Computer methods and programs in biomedicine**, v. 187, 104964, 2020.

LUNDERVOLD, A. S.; LUNDERVOLD, A. An overview of deep learning in medical imaging focusing on MRI. **Zeitschrift für Medizinische Physik**, v. 29, n. 2, p. 102–127, 2019.

LUSTED, L. B. Signal detectability and medical decision-making. **Science**, v. 171, p. 1217–1219, 1971. doi: 10.1126/science.171.3977.1217.

MEHRYAR MOHRI, A.; TALWALKAR, A. **Foundations of machine learning**. [S. l.: s. n.], 2012.

MENDES, D. *et al.* **Deep learning book**. [S. l.: s. n.], 2023. Disponível em: <http://deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/>

METERSKY, M. L.; MASTERTON, R. G.; LODE, H.; FILE, T. M. Hospital-acquired pneumonia in adults: diagnosis, assessment of severity, initial antimicrobial therapy, and preventative strategies. A consensus document. **American Journal of Respiratory and Critical Care Medicine**, v. 196, n. 10, p. 1336-1344, 2017. doi: 10.1164/rccm.201710-2080ST.

METZ, C. E. Basic principles of ROC analysis. *In*: **Seminars in nuclear medicine**, v. 8, n. 4, p. 283-298, October 1978.

NAHM, F. S. Receiver Operating Characteristic Curve: Overview and Practical Use for Clinicians. **Korean Journal of Anesthesiology**, v. 75, p. 25–36, 2022. Disponível em: <https://doi.org/10.4097/kja.21209>. Acesso em: 16 out. 2025.

NAZ, J.; KHAN, M. A.; ALHAISONI, M.; TARIQ, U.; KADRY, S. Segmentation and Classification of Stomach Abnormalities Using Deep Learning. **Computers, Materials & Continua**, v. 69, n. 1, 2021.

RAHMAN, T.; KHANDAKAR, A.; KADIR, M. A.; ISLAM, K. R.; ISLAM, K. F.; MAZHAR, R.; CHOWDHURY, M. E. Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization. **Ieee Access**, v. 8, p. 191586-191601, 2020.

RAJPURKAR, P. *et al.* CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. **arXiv preprint**, arXiv:1711.05225, 2017.

RASCHKA, S.; MIRJALILI, V. **Python machine learning: Machine learning and deep learning with Python, scikit-learn, and Tensor Flow**. 2nd ed. [S. l.]: Packt Publishing Ltd, 2017.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. [S. l.: s. n.], 1985.

SANTANA, M. Deep learning: Do conceito às aplicações. **Data Hackers**, 2019. Disponível em:



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

CONSTRUÇÃO DE UM MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X
Vladimir Costa de Alencar, Elias Dias Costa Neto, Jefferson Vieira dos Santos, Érika Fialho Moraes Xavier, Sílvia Fernando Alves Xavier Junior, Tiago Alessandro Espínola Ferreira

<https://medium.com/datahackers/deeplearningdoconceito%c3%a0saplica%c3%a7%c3%b5es-e8e91a7c7eaf>

SATHITRATANACHEEWIN, S.; SUNANTA, P.; PONGPIRUL, K. Deep learning for automated classification of tuberculosis-related chest X-Ray: dataset distribution shift limits diagnostic performance generalizability. **Heliyon**, v. 6, n. 8, 2020.

SHARMA, S.; GUPTA, S.; GUPTA, D.; RASHID, J.; JUNEJA, S.; KIM, J.; ELARABAWY, M. M. Performance evaluation of the deep learning based convolutional neural network approach for the recognition of chest X-ray images. **Frontiers in oncology**, v. 12, p. 932496, 2022.

SPÖRL, C.; CASTRO, E.; LUCHIARI, A. Aplicação de redes neurais artificiais na construção de modelos de fragilidade ambiental. **Revista do Departamento de Geografia**, v. 21, p. 113-135, 2011.

SWAPNAREKHA, H.; BEHERA, H. S.; ROY, D.; DAS, S.; NAYAK, J. Competitive deep learning methods for COVID-19 detection using X-ray images. **Journal of The Institution of Engineers (India): Series B**, v. 102, n. 6, p. 1177-1190, 2021.

TAN M.; LE, Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. **ICML**, 2019.

TANNER JR, W. P.; SWETS, J. A. A decision-making theory of visual detection. **Psychological Review**, v. 61, p. 401–409, 1954. doi: 10.1037/h0058700.

TRIPATHI, A.; SINGH, T.; NAIR, R. R. Optimal pneumonia detection using convolutional neural networks from x-ray images. *In*: **2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)**. July 2021. p. 1-6.

VOS, Theo et al. Global burden of 369 diseases and injuries in 204 countries and territories, 1990-2019: a systematic analysis for the Global Burden of Disease Study 2019. **The Lancet**, v. 396, n. 10258, p. 1204-1222, 2020. doi: 10.1016/S0140-6736(20)30925-9

WERBOS, P. **Beyond regression**: New tools for prediction and analysis in the behavioral sciences. Thesis (PhD) - Committee on Applied Mathematics, Harvard University, Cambridge, MA, 1974.