

# Detecção Automática de COVID-19 e Pneumonia em Radiografias Torácicas Utilizando Redes Neurais Profundas

João P. Bianchini<sup>1</sup>, Lucas T. Leite<sup>2</sup>, Victor C. Nova<sup>3</sup>, Ivan Carlos A. de Oliveira<sup>4</sup>

<sup>1,2,3,4</sup>Faculdade de Computação e Informática – Universidade Presbiteriana Mackenzie - São Paulo – SP – Brasil

{joaopedrobianchini195@gmail.com<sup>1</sup>, lucastoonin@gmail.com<sup>2</sup>, victorcostanova@gmail.com<sup>3</sup>, ivan.oliveira@mackenzie.br<sup>4</sup>}

**Resumo.** Este trabalho tem como objetivo implementar um modelo de detecção automática de COVID-19 e Pneumonia por meio de radiografias torácicas, utilizando técnicas de redes neurais profundas. A partir de um dataset público de imagens radiográficas torácicas de pacientes com COVID-19, pneumonia e normal, foram utilizadas redes neurais convolucionais explorando variações nos seus hiperparâmetros para encontrar o melhor modelo preditivo, segundo métricas de avaliação de erro. O modelo definitivo obtido incorporou 9.568 imagens de treinamento, alcançando uma acurácia média de 94% e precisão de 97%. A partir disso, uma aplicação web simples foi desenvolvida para integração do classificador e facilitando o seu acesso.

**Palavras-chaves:** redes neurais convolucionais, aplicação web, detecção, COVID-19, pneumonia.

**Abstract.** This work aims to implement an automatic detection model for COVID-19 and pneumonia through chest X-rays, using deep neural network techniques. Leveraging a public dataset of chest X-ray images from patients with COVID-19, pneumonia, and normal cases, convolutional neural networks were employed, exploring variations in their hyperparameters to find the best predictive model based on error evaluation metrics. The final model incorporated 9,568 training images, achieving an average accuracy of 94% and precision of 97%. Subsequently, a web application was developed for integrating the classifier, making it easily accessible.

**Keywords:** Convolutional Neural Networks, web application, detection, COVID-19, pneumonia.

## 1. Introdução

A pandemia da COVID-19 tornou-se um dos grandes desafios do século XXI, principalmente afetando a saúde e a economia da população mundial (BRAGA *et al.*, 2020).

Segundo a Organização Mundial da Saúde (OMS, 2023), até novembro de 2023, foram confirmados em torno de 771 milhões de casos e cerca de 6.97 milhões de mortes no mundo. No Brasil, desde o registro do primeiro caso em 25 de fevereiro de 2020 até novembro de 2023, foram registrados pouco mais de 37 milhões de casos e aproximadamente 705 mil mortes (OMS, 2023).

De acordo com o Ministério da Saúde, os sintomas mais comuns de pacientes contaminados pelo coronavírus são coriza, tosse, dor de garganta e dificuldade para respirar. A transmissão do SARS-CoV-2 ocorre de pessoa para pessoa, através da exposição direta à tosse, espirro e inalação de gotículas em um raio cerca de 1.8 metros (LAUXMANN; SANTUCCI; AUTRÁN-GÓMEZ, 2020), ou em contato com superfícies contaminadas.

A detecção de pessoas infectadas é crucial no combate a COVID-19, pois o paciente diagnosticado rapidamente recebe o tratamento e todo o cuidado necessário, além de se isolar, controlando e reduzindo a disseminação do vírus (RAHMAN *et al.*, 2021). Para isso, o principal método de detecção utilizado é a transcrição reversa seguida de reação em cadeia da polimerase, do inglês *Reverse Transcription-Polymerase Chain Reaction* (RT-PCR), a partir da coleta de amostras de secreção respiratória (WANG; LIN; WONG, 2020).

Mesmo sendo altamente específico, o teste PCR não é barato (SHAH *et al.*, 2021), possui um tempo de espera significativo, e um processo manual complicado até a obtenção do resultado (WANG; LIN; WONG, 2020), o qual pode ser falso-negativo e a pessoa estar infectada com o vírus (SHAH *et al.*, 2021). Além disso, em várias regiões do mundo, a disponibilidade do PCR é limitada (SHAH *et al.*, 2021), principalmente para a população de baixa renda e nas redes de saúde pública (SILVEIRA *et al.*, 2022).

Tendo em vista essas limitações, uma alternativa para detectar a COVID-19 são os exames de imagens, como o raio-X (RX) e a Tomografia Computadorizada (TC) (SHAH *et al.*, 2021). Fortemente utilizadas para detecção de doenças pulmonares, como a pneumonia e a tuberculose (RAHMAN *et al.*, 2021), as imagens radiográficas podem ser empregadas para análise médica que busca indicadores visuais associados à COVID-19, realizando assim o diagnóstico de maneira efetiva.

Embora as imagens de TC sejam mais detalhadas, imagens de raio-X torácico possuem diversas vantagens na detecção da COVID-19, particularmente em áreas com recursos limitados. RX-torácico permite uma rápida triagem de pacientes com suspeita de COVID-19, sendo feito paralelamente ao teste PCR, que leva tempo. Por ser considerado equipamento padrão na maioria dos sistemas de saúde, o exame de RX é bastante acessível, ainda mais com a possibilidade de máquinas portáteis, podendo então ser realizados em salas com isolamento (WANG; LIN; WONG, 2020).

Segundo Silveira *et al.* (2022), “Dado o potencial a ser explorado na utilização de imagens de raio-X torácico para detecção da COVID-19, pesquisadores acreditam que um sistema baseado na radiologia torácica pode ser uma ferramenta eficaz na detecção, quantificação e acompanhamento dos casos de COVID-19”.

Por sua vez, a pneumonia é uma enfermidade epidêmica que se manifesta por uma infecção grave no pulmão. Foi considerada como a maior causa de fatalidades infantis no mundo, correspondendo a 14% de todas as mortes de crianças com até cinco anos de idade, em 2019, correspondendo a cerca de 740 mil mortes (OMS, 2022).

O melhor método para detecção e diagnóstico da pneumonia é pela radiografia de tórax (RAHMAN *et al.*, 2020). Mesmo assim, imagens de raio-X podem não ser claras,

sendo confundidas com outras doenças (RAHMAN *et al.*, 2020). A pneumonia pode ser causada tanto por vírus como por bactéria, podendo ser tratada de maneiras diferentes.

“A radiografia de tórax é uma ferramenta comum utilizada para diagnosticar pneumonia, permitindo visualizar opacidades nos pulmões que podem indicar a presença da doença” (FIGUEIREDO, 2009). Porém, a detecção manual pode ser demorada e a busca por métodos mais eficientes, como o uso de algoritmos de aprendizado de máquina, pode promover um diagnóstico eficaz e automático. “A prevenção das infecções virais que causam pneumonia comunitária inclui, dependendo do vírus, vacinas e imunização passiva” (FIGUEIREDO, 2009).

Em busca de melhora na análise das imagens médicas, métodos de aprendizagem profunda (*deep learning*) estão sendo utilizados para identificação de síndromes respiratórias através de exames de imagens (XIASONG *et al.*, 2017). Nos últimos anos, essa tecnologia obteve um progresso significativo, principalmente devido ao aumento de poder computacional, assim como a melhoria dos métodos de *deep learning* e seus algoritmos (YANG *et al.*, 2021).

Frente ao exposto, o presente trabalho tem como objetivo implementar um protótipo de aplicação para classificação de imagens de raios-X torácico, fazendo uso de modelos de redes neurais profundas para realizar a detecção automática da COVID-19 e pneumonia, podendo funcionar como uma ferramenta de auxílio no diagnóstico de pacientes.

O classificador obtido é capaz de detectar pacientes com COVID-19, Pneumonia, e normais (não apresenta COVID-19 nem pneumonia). Para treinamento e validação do classificador, foi utilizado um *dataset* público de raios-X torácico, disponibilizados por um time de pesquisadores da Universidade do Qatar, contendo mais de 10 mil imagens (RAHMAN *et al.*, 2022).

O trabalho está estruturado em diversas seções com o intuito de fornecer uma abordagem abrangente e organizada sobre o tema. Na Seção 2, são discutidas bases conceituais e teóricas relevantes para a implementação desta proposta, assim como trabalhos relacionados, que propõem a detecção automática de COVID-19 e pneumonia. Na Seção 3, são detalhados os passos e procedimentos adotados para implementação do modelo de classificação. Na Seção 4, são apresentados o *dataset* e ajustes realizados, os resultados encontrados com treinamento da rede neural, bem como as métricas de avaliação do modelo, além da aplicação *web* implementada. Por fim, na Seção 5, são listados uma síntese de todo o processo de desenvolvimento do trabalho, assim como sugestões de trabalhos futuros.

## **2. Referencial Teórico**

Nesta seção são apresentados os fundamentos pesquisados e estudados que nortearam o desenvolvimento deste projeto, a saber: COVID-19, pneumonia, radiografia, visão computacional, processamento de imagens, *deep learning*, métrica de avaliação de erros e trabalhos relacionados.

## 2.1. COVID-19

A COVID-19 é uma doença infectocontagiosa causada pelo coronavírus da síndrome respiratória aguda grave 2 (SARS-CoV-2) (BRAGA et al., 2020).

Segundo a OMS, no final de dezembro de 2019, em Wuhan, na China, foram descritos os primeiros casos da doença, até então desconhecida, e reportados às autoridades de saúde. Em março de 2020, a OMS elevou a classificação da COVID-19 como pandêmica, devido à sua rápida disseminação global. Até o dia 21 de abril de 2020 foram relatados casos de COVID-19 em 213 países, territórios ou áreas (BRAGA *et al.*, 2020).

Segundo Braga *et al.* (2020), “Por se tratar de uma infecção respiratória aguda, o SARS-CoV-2 se dissemina principalmente por gotículas, secreções respiratórias e contato direto com o paciente infectado. Diante dessa perspectiva, destaca-se a capacidade do vírus ser transmitido de humano para humano (transmissão direta)”. Além disso, Van Doremalen *et al.* (2020) realizaram um estudo no qual demonstrou que o tempo que o SARS-Cov-2 pode permanecer viável e infeccioso em aerossóis pode chegar até 3 horas após ser exposto no ambiente.

Segundo Lauxmann, Santucci e Autrán-Gómez (2020), os sintomas mais comuns reportados são febre, tosse, dores muscular ou fadiga, seguidos por pneumonia e dispneia, enquanto os menos comuns incluem dores de cabeça, diarreia e hemoptise. A Tabela 1 demonstra os sintomas registrados em 191 pacientes de COVID-19, em janeiro de 2020.

**Tabela 1. Resumo dos sintomas registrados em 191 pacientes confirmados com COVID-19 hospitalizados no Hospital Jinyintan ou Wuhan Pulmonary Hospital antes de 31 de janeiro, 2020**

Febre(temperatura > 37°C)	Tosse	Escarro	Mialgia(dor muscular)	Fadiga	Diarreia	Náusea ou vômito
180 (94%)	151 (79%)	44 (23%)	29 (15%)	44 (23%)	9 (5%)	7 (4%)

Fonte: (LAUXMANN; SANTUCCI; AUTRÁN-GÓMEZ, 2020)

## 2.2. Pneumonia

Segundo Figueiredo (2009), “Em humanos, os tipos de infecção mais comuns são as infecções do trato respiratório, entre as quais predominam as infecções virais. Os vírus também podem infectar o trato respiratório inferior, causando bronquiolite, bronquite e pneumonia”. “Diferentes tipos de vírus podem acometer os pulmões e causar a pneumonia, infectando de forma significativa idosos, crianças e adultos, imunodeprimidos ou não. [...] Sendo uma infecção que acomete as trocas gasosas a nível alveolar, causando inflamação do parênquima pulmonar, e infecção do trato respiratório.”

Compreende-se a possibilidade de ocorrer dois tipos distintos de pneumonias, de origem viral, ou de origem bacteriana. Porém, segundo LEE *et al.* (2010), “há controvérsia sobre o fato de ser possível distinguir se as pneumonias têm origem viral ou

bacteriana, através de achados laboratoriais e de radiografias torácicas no momento da internação.”.

### **2.2.1 Pneumonia Viral**

Como diz Nolte (2008), “As infecções do trato respiratório são as formas de infecção mais comuns que afetam o homem e, dentre essas, predominam as de causa viral. Sabe-se hoje da existência de 1.200 vírus que infectam o trato respiratório, embora muitos deles, provavelmente, não causem doença.”.

Eccles (2005) complementa: “Como consequência de infecções do trato respiratório por vírus, destacam-se duas doenças muito comuns, mas de difícil distinção: o resfriado, que tem pequena gravidade e duração, cursando com cefaleia, espirros, calafrios e dor de garganta, evoluindo com coriza, obstrução nasal, tosse e mal-estar; e a gripe, mais grave, de instalação súbita com febre, cefaleia, tosse, dor de garganta, mialgia, espirros, fraqueza e hiporexia.”.

Infecções virais podem culminar em uma manifestação clínica de pneumonia. Isso ocorre devido à propensão das infecções nas vias aéreas superiores (cavidades nasais, faringe e laringe), que podem facilitar a entrada de agentes infecciosos nas vias inferiores, notadamente nos pulmões, resultando na ocorrência de pneumonia.

### **2.2.2 Pneumonia Bacteriana**

A pneumonia bacteriana é uma inflamação nos pulmões, causada pela multiplicação desordenada de bactérias.

“Ao chegar ao pulmão, os microrganismos envolvidos colonizam e invadem a região. Em indivíduos imunocomprometidos, até mesmo bactérias de média e baixa virulência podem estar relacionadas. Assim, levam a um quadro de infecção do parênquima pulmonar, região importante para as trocas gasosas de competência do sistema respiratório. Logo, os bronquíolos e alvéolos são preenchidos por exsudato inflamatório, dificultando a hematose e levando ao quadro clássico de insuficiência respiratória” (ASSUNÇÃO; PEREIRA; ABREU, 2018).

## **2.3. Radiografia**

Segundo MEC (2018), "A história da radiologia começou em 1895, com a descoberta experimental dos raios-X pelo físico alemão Wilhelm Conrad Roentgen. As aplicações médicas da descoberta revolucionaram a medicina, pois havia se tornado possível a visão do interior dos pacientes". Dentro do estudo da radiologia temos a radiografia, que são técnicas de representação bidimensional de estruturas corporais tridimensionais (GOODMAN, 2001).

Segundo Nibib (2022), radiografia consiste em “raios-X que são uma forma de radiação eletromagnética, semelhante à luz visível. Ao contrário da luz, no entanto, os raios-X têm energia mais alta e podem passar pela maioria dos objetos, incluindo o corpo. Raios-X médicos são usados para gerar imagens de tecidos e estruturas dentro do corpo. Se os raios-X que viajam pelo corpo também passarem por um detector de raios-X do

outro lado do paciente, será formada uma imagem que representa as “sombras” formadas pelos objetos dentro do corpo.”

Atualmente, tem-se duas técnicas de radiografia, a convencional e a digital. A diferença entre elas consiste nos detectores de raios-X. Na convencional é necessário um filme radiográfico que precisa ser revelado para gerar a imagem, enquanto na radiografia digital os raios-X são capturados por uma placa de circuitos sensível à radiação, sendo mais ágil e permitindo alterações como ajustes de contraste, podendo assim ser armazenada, enviada digitalmente ou até mesmo impressa.

## 2.4 Visão Computacional

Visão Computacional é a área responsável pela "visão" de uma máquina, a forma como um computador enxerga o meio ao seu redor, extraindo informações consideráveis a partir de imagens capturadas por câmeras de vídeo, sensores, scanners, entre outros dispositivos (DE MILANO; HONORATO, 2010). Estas informações permitem reconhecer, manipular e pensar sobre os objetos que compõem uma imagem (DE MILANO; HONORATO, 2010).

Quando a COVID-19 alcançou o status de pandemia, diante da ausência de testes, foram aconselhados modelos de visão computacional para a detecção da doença a partir de imagens de radiografias (SHAH et al., 2021), operando algoritmos de inteligência artificial treinados em *datasets* para esse objetivo. O processamento dessas imagens em computadores envolvem a recuperação, criação, análise e visualização das imagens (SUGANYADEVI; SEETHALAKSHMI; BALASAMY, 2022).

“Como o olho humano é limitado em relação à percepção de alguns padrões em imagens e na detecção de imagens com ruídos ou contraste muito baixo, muitas vezes interpretando-as de forma diferente, o uso de recursos computacionais pode ajudar neste reconhecimento, servindo, por exemplo, como um auxiliar no diagnóstico de algumas doenças, evitando um diagnóstico impreciso ou equivocado.” (DE MILANO; HONORATO, 2010).

## 2.5. Processamento de Imagens

A área de processamento de imagens desperta interesse devido à sua capacidade de viabilizar aplicações em duas categorias distintas: o aprimoramento de informações pictóricas para interpretação humana e a análise automática de informações extraídas de uma cena (MARQUES FILHO; NETO, 1999).

Os componentes de um sistema genérico de processamento de imagens são encontrados em uma ampla gama de dispositivos, desde sistemas de baixo custo até estações de trabalho avançadas usadas em aplicações que exigem um processamento intensivo de imagens (MARQUES FILHO; NETO, 1999). Segundo Marques Filho e Neto (1999), “as principais operações que se pode efetuar sobre uma imagem, a saber: aquisição, armazenamento, processamento e exibição.”

Segundo Martins *et al.* (2020), “O problema de diagnóstico de exames por imagens é comumente abordado na literatura da Visão Computacional quando aplicada à saúde”. Esses sistemas visam detectar padrões e gerar informações adicionais sobre os

elementos presentes na imagem, contribuindo assim para uma melhor análise e interpretação dos exames (MARTINS *et al.*, 2020).

## 2.6. Deep Learning

*Deep Learning* é uma área em desenvolvimento acelerado na inteligência artificial e é utilizado para exploração de informações, implantação de conhecimento e previsão baseada em conhecimento. As aplicações de *Deep Learning* na área da saúde abordam uma ampla variedade de questões, incluindo triagem de câncer, monitoramento de infecções e aconselhamento personalizado para tratamento (SUGANYADEVI; SEETHALAKSHMI; BALASAMY, 2022).

Segundo Lecun *et al.* (2015), “O *Deep Learning* descobre estruturas complexas em grandes conjuntos de dados usando o algoritmo de retropropagação para indicar como uma máquina deve alterar seus parâmetros internos usados para calcular a representação em cada camada a partir da representação na camada anterior.”

Temos diversas aplicações como “aprender a distinguir entre imagens diferentes tal como humanos fazem com a experiência. Por exemplo, a rede aprende o que são cães ao analisar imagens de muitos tipos deles – grandes, pequenos e de diversas raças e cores. Da mesma forma, a rede pode diferenciar gatos, onças, tigres e leões após analisar imagens previamente classificadas” (SOUZA *et al.* 2020). O uso de *Deep Learning* com imagens de radiografia de tórax permite, por exemplo, identificar a Covid-19 e pneumonia (MARTINS *et al.* 2020).

Embora as técnicas de *Deep Learning* não sejam novas, devido à interseção de redes neurais profundamente estratificadas e ao uso de GPUs para acelerar sua execução, elas estão experimentando um desenvolvimento exponencial (SUGANYADEVI; SEETHALAKSHMI; BALASAMY, 2022).

Há uma diferença entre *Deep Learning* e redes neurais, onde redes neurais podem existir com apenas uma camada de neurônios artificiais, *Deep Learning* possuem múltiplas camadas de neurônios artificiais interconectados, que compõem a rede neural profunda. Atualmente há diversos tipos de redes neurais que mudam a arquitetura em que os nós (neurônios artificiais) se comunicam entre si.

### 2.6.1. Redes Neurais Convolucionais (CNN)

A Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*) é uma arquitetura de aprendizado profundo amplamente conhecida e inspirada no mecanismo de percepção visual dos seres vivos. Sua criação foi influenciada por uma descoberta feita por Hubel e Wiesel em 1959, onde eles identificaram células no córtex visual de animais responsáveis por detectar luz em campos receptivos (GU *et al.*, 2018).

A CNN tem se mostrado uma ferramenta poderosa para a análise de imagens, especialmente em tarefas como reconhecimento de padrões e detecção de objetos. Seu sucesso primário se deve a sua capacidade de aprender características automaticamente a partir de imagens específicas do domínio, ao contrário dos métodos clássicos de aprendizado de máquina (ABBAS; ABDELSAMEA; GABER, 2021). Sua capacidade de

extrair características relevantes e realizar o processamento de informações de maneira eficiente a torna uma escolha ideal para várias aplicações em diferentes áreas, com conquistas superiores no domínio de imagens médicas (ABBAS; ABDELSAMEA; GABER, 2021).

Segundo Abbas, Abdelsamea e Gaber (2021), a estratégia popular para treinar a arquitetura CNN é transferir o conhecimento aprendido de uma rede pré-treinada que realizou uma tarefa em uma nova tarefa. Este método é mais rápido e fácil de aplicar, sem a necessidade de um grande conjunto de dados anotados para treinamento. Por esse motivo, muitos pesquisadores tendem a aplicar essa estratégia, especialmente em imagens médicas.

Segundo Chowdhury *et al.* (2020), “Redes neurais convolucionais profundas geralmente apresentam um desempenho melhor com um conjunto de dados maior do que um menor. A transferência de aprendizado pode ser usada no treinamento de CNNs profundas quando o conjunto de dados não é grande.”.

## **2.7. Métricas de Avaliação de Erros.**

De acordo com Carvalho *et al.* (2011), as métricas de avaliação de erros são medidas que permitem avaliar o desempenho de algoritmos, modelos ou sistemas em relação às previsões ou resultados gerados. Essas métricas ajudam a quantificar o quão bem um modelo ou sistema está funcionando e identificar onde estão ocorrendo erros. Existem várias métricas de avaliação de erros, e a escolha da métrica adequada depende do tipo de problema e dos objetivos da análise.

### **2.7.1 Matriz de Confusão**

A matriz de confusão da Tabela 2 ilustra o número de previsões corretas e incorretas em cada classe. Para um determinado conjunto de dados e duas classes (positiva e negativa), as linhas dessa matriz representam as classes verdadeiras, e as colunas, as classes previstas pelo classificador.

- VP corresponde ao número de verdadeiros positivos, ou seja, o número de exemplos da classe positiva classificados corretamente.
- VN corresponde ao número de verdadeiros negativos, ou seja, o número de exemplos da classe negativa classificados corretamente.
- FP corresponde ao número de falsos positivos, ou seja, o número de exemplos cuja classe verdadeira é negativa, mas que foram classificados incorretamente como pertencendo à classe positiva.
- FN corresponde ao número de falsos negativos, ou seja, o número de exemplos pertencentes originalmente à classe positiva que foram incorretamente previstos como da classe negativa.



**Tabela 2. Matriz de confusão (Fonte: Autoria Própria)**

		Classe Preditiva	
		+	-
Classe verdadeira	+	VP	FN
	-	FP	VN

### 2.7.2 Acurácia

A taxa de acerto de  $f$  ou acurácia é obtida pelo complemento da taxa de erro, ou seja: “ $ac(f) = 1 - err(f)$ ”. Essa taxa varia entre 0 e 1, onde valores mais próximos a 1 correspondem à alta acurácia. A Figura 1 define o cálculo da acurácia total que representa o número de previsões corretas do modelo. É calculada pela soma dos valores da diagonal principal da matriz de confusão, e dividida pela soma dos valores de todos os elementos da matriz.

$$ac(f) = \frac{VP + VN}{n}$$

**Figura 1. Cálculo da acurácia, a partir da matriz de confusão (Fonte: Autoria Própria)**

### 2.7.3 Precisão

Precisão é a proporção de exemplos positivos classificados corretamente entre todos aqueles preditos como positivos por  $f$ . A Figura 2 define o cálculo, com a divisão dos verdadeiros positivos pela soma dos verdadeiros positivos e falsos positivos encontrados na matriz de confusão.

$$prec(f) = \frac{VP}{VP + FP}$$

**Figura 2. Cálculo da precisão, a partir da matriz de confusão (Fonte: Autoria Própria)**

## 2.8. Trabalhos Correlatos

Foram encontrados estudos e trabalhos relacionados para detecção de COVID-19 e pneumonia a partir de imagens de Raio-X. Alguns deles nortearam as escolhas de algumas tecnologias, bem como da rede neural profunda CNN, utilizadas neste projeto. A seguir, serão destacados alguns deles.

Apostolopoulos e Mpesiana (2020) avaliam o desempenho de arquiteturas avançadas de CNNs propostas nos últimos anos para a classificação de imagens médicas. Especificamente, foi adotado o procedimento chamado de *Transfer Learning*. Com a transferência de aprendizado, a detecção de várias anormalidades em pequenos *datasets* de imagens médicas é um objetivo alcançável. Foram testadas as arquiteturas VGG-19, Mobilenet v2, *Inception*, *Xception*, e *Inception ResNet v2*. Os resultados sugerem que o Aprendizado Profundo com imagens de raio-x pode extrair biomarcadores significativos relacionados à doença Covid-19, sendo que a melhor acurácia, sensibilidade e

especificidade obtidas foram de 96,78%, 98,66% e 96,46% (*MobileNet v2*), respectivamente.

Em Yang *et al.* (2021), foram analisadas e comparadas diferentes técnicas de *Deep Learning* aplicadas a imagens médicas de raio-x e tomografia computadorizada (*CT-scan*) para a detecção de COVID-19. Foram utilizados quatro modelos de CNNs pré treinadas para a classificação binária de imagens de CT, VGG16, *DenseNet121*, ResNet50 e ResNet152. Para classificação binária e de múltiplas classes de raio-x, foram utilizados modelos avançados de transferência *deep learning* VGG16. Foram obtidos altos resultados na detecção com imagens de raio-x pelo modelo aprimorado VGG16, alcançando acurácia de 99%. Enquanto a classificação de imagens de *CT-scan*, os modelos de CNN com *Fast.AI* obtiveram acurácia, *F1-score* e precisão acima de 96%.

Em Abbas, Abdelsamea e Gaber (2021), foi investigado o desempenho de uma arquitetura de CNN profunda, chamada DeTraC (do inglês *Decompose, Transfer, and Compose*), para classificação de imagens de Raio-X com COVID-19. O DeTraC consegue lidar com irregularidades no conjunto de dados, investigando os limites de classe por meio de um mecanismo de decomposição de classe. O estudo comparou o desempenho de modelos de CNN pré-treinados com e sem DeTraC. Os resultados experimentais demonstraram a capacidade do DeTraC em alcançar uma alta precisão de 93,1% na detecção de imagens de raio-x de COVID-19 em casos normais e de síndrome respiratória aguda grave. Além disso, o método apresentou uma sensibilidade de 100%, destacando sua eficácia na identificação precisa de casos de COVID-19.

De Souza Filho *et al.* (2022) propuseram um modelo automático de diagnóstico da COVID-19, utilizando uma abordagem *Radiomics* em imagens de Raio-X de tórax, com o *algoritmo Multi-Layer Perceptron* (MLP). Alcançaram o melhor resultado utilizando todos os descritores de textura analisados juntos, alcançando acurácia de 96,8%, precisão de 97,1%, *recall* de 96,4% e especificidade de 97,8%, demonstrando a eficácia do *Radiomics* no diagnóstico da COVID-19 por imagens.

Em Togni e Attux (2021), foi realizada uma análise comparativa de métodos para detecção de infecção por COVID-19 em imagens radiográficas. Foram utilizadas oito CNNs pré-treinadas: *SqueezeNet*, *DenseNet*, *ResNet*, *AlexNet*, VGG, *GoogleNet*, *ShuffleNet*, *MobileNet*. Na abordagem multiclasse, a rede *DenseNet* obteve a melhor acurácia, 97,4%. Na abordagem binária, as redes VGG, ResNet e *Mobile* obtiveram os melhores resultados, com uma acurácia de 98,98%.

Em Rahman *et al.* (2020), foi implementado um método para detecção automática de pneumonia, a partir de raio-X de tórax, com o diferencial de conseguir detectar pneumonia viral ou pneumonia bacteriana. Para transferência de aprendizado, foram utilizados quatro modelos de CNNs pré-treinadas, *AlexNet*, *ResNet18*, *DenseNet201* e *SqueezeNet*. Foram pré-processadas e treinadas 5247 imagens de raio-X de tórax, contendo pneumonia viral e bacteriana, além de normalidade. Os autores separaram três classificações diferentes: normal vs. pneumonia, com 98% de acurácia; pneumonia bacteriana vs. pneumonia viral, com 95% de acurácia, e pneumonia bacteriana vs. pneumonia viral vs. Normal, com 93% de acurácia.

### 3. Metodologia de pesquisa

Este trabalho pode ser descrito como uma pesquisa aplicada para a implementação de um classificador de imagens de radiografia torácicas.

No começo, foram realizadas buscas nas bases de trabalhos acadêmicos a respeito da temática deste projeto com a finalidade de encontrar literatura e tecnologias para sua implementação, além de *datasets*. Os textos selecionados foram lidos e incorporados.

Em seguida, foram coletados *datasets* contendo imagens de raio-X de tórax de pacientes, classificadas em três categorias: *COVID-19*, Pneumonia e normal (não apresenta *COVID-19* nem pneumonia). Neste trabalho, foi utilizado o *COVID-19 Radiography Database*, disponível no Kaggle<sup>1</sup>, contendo radiografias das três classes.

Foram implementadas as etapas para o treinamento do modelo, utilizando o *YOLO v8*<sup>2</sup>. A configuração e hiperparâmetros da rede foram definidos com base em experimentos preliminares e em diretrizes estabelecidas na literatura.

Criou-se um repositório no *Roboflow*<sup>3</sup>, plataforma *open-source* para armazenar a *database* de imagens, distinguindo-as para treinamento, testes e validação. Nesse repositório foram inseridas as imagens normais do *dataset*, além delas com rotações de 15 graus de diferença, e eliminação de imagens invertidas, promovendo assim uma base de imagens complexa, com maior abrangência para treinamento e distinção de classes.

Para o treinamento da CNN, implementada no *Google Colaboratory*, foi utilizada uma GPU adequada para processar a enorme quantidade de dados. Com o conjunto de dados, as imagens foram alimentadas na rede juntamente com suas respectivas classes (*COVID-19*, pneumonia e normal).

Todos os modelos e procedimentos adotados acima foram implementados através da linguagem *Python*, utilizando as bibliotecas *pandas*, *roboflow*, *ultralytics* e *yolo*, além de ser estabelecida uma análise dos resultados, avaliando a acurácia, precisão, *recall* e especificidade do modelo, assim como suas limitações e possíveis direções para pesquisas futuras.

A partir do melhor modelo obtido, foi construído um protótipo de aplicação analítica em Flask que permite classificar uma imagem radiográfica torácica em *COVID-19*, pneumonia e normal.

Tendo por base o descrito, as etapas desta pesquisa foram:

1. Revisão bibliográfica.
2. Coleta e manipulação do *dataset*.
3. Inserção da base de dados no *roboflow*.
4. Realização da análise dos dados do *dataset*.
5. Apuração de potenciais propriedades relevantes para a detecção das imagens.

---

<sup>1</sup> <https://www.kaggle.com/>.

<sup>2</sup> <https://yolov8.com/>.

<sup>3</sup> <https://roboflow.com/>.

6. Seleção e preparação dos dados.
7. Estudo das técnicas de *deep learning* e seleção da CNN, de acordo com trabalhos correlatos.
8. Criação dos modelos iniciais a partir da técnica escolhida, alterando seus hiperparâmetros.
9. Definição do melhor modelo preditivo dentre os gerados, considerando as métricas de avaliação de erros.
10. Construção do protótipo de software *em Flask*, integrando a API do *roboflow* com o melhor modelo obtido, e que classifica a imagem em COVID-19, pneumonia ou normal.
11. Testes na aplicação e análise dos resultados.
12. Discussão das análises obtidas e considerações.
13. Elaboração da documentação desta pesquisa.

## 4. Resultados

Nesta seção, são apresentados os resultados alcançados neste projeto, discorrendo sobre as decisões de implementação, desde a aquisição dos dados, até a geração do modelo preditivo final e o desenvolvimento do protótipo de aplicação analítica.

### 4.1. Criação da *database*


Um time de pesquisadores da Universidade do Qatar, em Doha, no Qatar, e da Universidade de Dhaka, em Bangladesh, em colaboração com seus parceiros do Paquistão e da Malásia, juntamente com médicos, criaram um banco de dados de imagens de raio-X de tórax para casos positivos de COVID-19, juntamente com imagens de pneumonia viral e normal, o *dataset COVID-19 Radiography Database* que encontra-se na plataforma *Kaggle* (RAHMAN *et al.*, 2022), e apresenta 3.616 radiografias de COVID-19, 1.345 de Pneumonia Viral e 10.192 radiografias torácicas normais. A Figura 3 corresponde às imagens de RX-torácico coletadas do *dataset*, representando pulmões com COVID-19, pneumonia e normal, da esquerda para a direita.



**Figura 3. Raios-X de pacientes com COVID-19, com Pneumonia e normal, da esquerda para a direita (Fonte: RAHMAN *et al.*, 2022).**

Para implementação do classificador, foram utilizadas 2.117 imagens para COVID-19, 2.400 normais e 1.734 com pneumonia, constituindo 6.251 imagens originais de Raio-X de tórax. Além das imagens originais, foram adicionadas 4.787 imagens duplicatas, contendo rotações (15 graus) e mudança de direção (direita-esquerda), sendo 1.535 normais, 1.620 de pneumonia e 1.632 de COVID-19. Com isso, o *dataset* final totalizou 11.038 imagens, sendo 3749 de COVID-19, 3354 de Pneumonia e 3935 normais.

A Figura 4 contém dois gráficos. O gráfico à esquerda apresenta o número e porcentagem de imagens originais de cada classe, antes da manipulação do *dataset*. Por sua vez, o gráfico à direita, apresenta as estatísticas do *dataset* final, contendo as classes quase balanceadas.



**Figura 4. Gráficos representativos de cada classe, na esquerda correspondendo somente as imagens coletadas do *dataset* público, e direita, correspondendo a quantidade total de imagens, incluindo as duplicadas (Fonte: Autoria própria)**

## 4.2. Experimentos e métricas obtidas

Antes de iniciar os testes do modelo, foi desenvolvido um ambiente no *Google Colaboratory*, fazendo uso da linguagem de programação Python e contendo as bibliotecas da *ultralytics*, *YOLO* e *roboflow*.

A estrutura de rede neural utilizada foi a rede neural convolucional (CNN) do *YOLO-v8* encontrada na biblioteca *TensorFlow*.

Após a instauração do ambiente no *Google Colaboratory*, procedeu-se para a integração do *dataset* de imagens ao *Roboflow*. Foram realizados experimentos iniciais com a finalidade de compreender o funcionamento de todas as bibliotecas e da CNN. Nesse sentido, diversos modelos foram formulados, com um aumento gradativo de imagens para cada atualização.

Ao todo foram utilizados 10 tamanhos de *dataset* (de V3 a V12) nos experimentos, incluindo, ao final, o *dataset* com 11.038 imagens. A Tabela 3 compreende a evolução dos *datasets* utilizados, conforme o incremento de imagens. Os testes realizados nos conjuntos de V3 a V11 não são apresentados aqui devido aos resultados não satisfatórios.

**Tabela 3. Quantidade de imagens para cada versão, indicando um aumento gradativo (Fonte: Autoria própria)**

Modelo	qtde. de imagens
V3	1.269
V4	1.884
V5	2.450
V6	2.474
V7	2.437
V8	2.257
V9	6.744
V10	9.250
V11	10.230
V12	11.038

Tendo por base o *dataset* final V12 (Tabela 3), prosseguiu-se para a sucessão de testes, explorando variações nas proporções de imagens para treinamento e teste, além dos hiperparâmetros *Epochs*, que define a quantidade de vezes que a imagem foi filtrada pela CNN (HASTOMO *et al.*, 2021), e *Batch Size*, que se refere ao número de exemplos (lotes de imagens) de treinamento utilizados em cada interação (ou passo), durante o processo de treinamento do modelo (YOU; GITMAN; GINSBURG, 2017).

A Tabela 4 compreende o comparativo dos modelos V12, indicando algumas variações em relação ao total de modificações, envolvendo: a proporção de imagens para treinamento e teste, adição de imagens duplicadas, e os hiperparâmetros *Batch Size* e *Epoch*. Para cada variação, calculou-se as métricas de acurácia, precisão e recall. Vale ressaltar que não haverá alteração na quantidade de imagens, com apenas rotações, assim como apenas mudança de sentido, comparado com os dois parâmetros ativos. Isso porque as imagens duplicadas serão rotacionadas e com sentidos opostos, juntamente.

**Tabela 4. Métricas obtidas para diferentes versões do classificador (Fonte: Autoria própria)**

Modelo	Proporção	Rotação (15°)	esq/dir.	Acur.	Prec.	Rec.	Epochs	Batch size	qtde. de Img.
V12	75/25	sim	sim	0.94	0.97	0.93	10	16	11.038
V13	80/20	sim	sim	0.88	0.96	0.60	10	16	11.038
V14	80/20	sim	não	0.91	0.85	0.70	10	9	11.038
V15	75/25	não	sim	0.91	0.88	0.65	10	9	11.038

Diante dos resultados da Tabela 4, nota-se melhor desempenho, o modelo V12 com proporção 75/25; imagens duplicadas com rotação de 15° e sentidos opostos; *Epochs* em 10, que é uma boa referência para uma base de dados maiores; e *batch size* 16. As métricas chegaram em acurácia de 94%, precisão de 97% e *recall* de 93%.

Complementando, a Tabela 5 compreende a matriz de confusão desse melhor modelo, assim como os valores de verdadeiro positivo, falso positivo e falso negativo para cada classe.

**Tabela 5. Matriz de confusão e medidas de verdadeiros positivos, falsos positivos, falsos negativos e (Fonte: Autoria própria).**

Classe	Modelo	VPositivo	FPositivo	FNegativo	Matriz Conf.
Covid-19	V12	0.94	0.06	0.04	0.94 0.02 0.04
Normal	V12	0.97	0.03	0.02	0.01 0.97 0.02
Pneumonia	V12	0.93	0.04	0.03	0.03 0.04 0.93

### 4.3. Aplicação Desenvolvida

Uma aplicação web foi desenvolvida utilizando o framework *Flask* em *Python*, com o propósito de possibilitar aos usuários a análise de imagens de raio-X do pulmão e identificar se é uma imagem normal, com pneumonia ou com COVID-19. O objetivo primordial desse sistema é integrar o modelo preditivo obtido na Seção 4.2 em um ambiente prático e simples ao usuário acessado pelo navegador.

Ao submeter uma imagem de raio-X de tórax na interface web, a aplicação realiza uma avaliação por meio do modelo previamente treinado, para analisar e interpretar os padrões presentes na imagem. A aplicação oferece aos usuários uma avaliação automatizada que emite além da previsão de COVID-19, pneumonia ou normalidade, a taxa de confiança.

Essa funcionalidade visa fornecer uma ferramenta complementar aos profissionais de saúde, auxiliando o processo de triagem e permitindo uma resposta mais rápida na identificação de possíveis patologias pulmonares. A Figura 5 apresenta a tela inicial da aplicação, com a seleção da imagem de RX de tórax, enquanto as Figuras 6, 7 e 8 ilustram a previsão de pneumonia, COVID-19 e normal, respectivamente. Vale ressaltar que nas Figuras 6, 7 e 8 foram utilizadas radiografias torácicas externas ao *dataset* de treinamento e a aplicação acertou os resultados de cada uma das imagens inseridas.

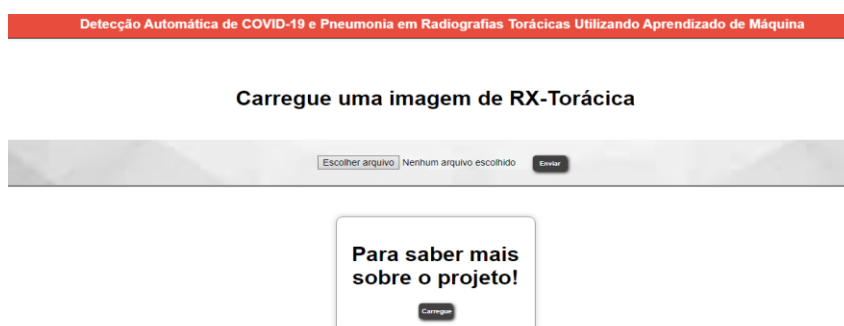


Figura 5. Protótipo Aplicação *Flask*, tela inicial do classificador (Fonte: Autoria Própria)



Figura 6. Aplicação *Flask*: Tela com resultado Pneumonia, pós predição do classificador (Fonte: Autoria Própria)




Figura 7. Aplicação *Flask*: Tela com resultado COVID-19, pós predição do classificador (Fonte: Autoria Própria)

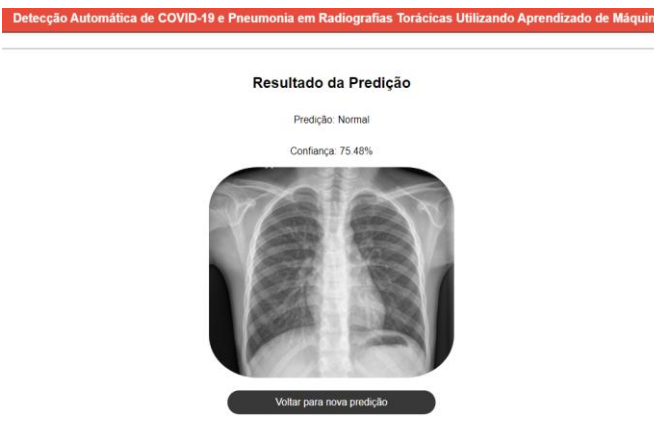


Figura 8. Aplicação *Flask*: Tela com resultado Normal, após predição do classificador (Fonte: Autoria Própria)

A Tabela 6 corresponde aos testes de imagens externas a *dataset* de treinamento do modelo V12, realizados na aplicação *Flask*. Para cada classe foram testadas 10 imagens (exceto Normal, contendo 11), indicando a quantidade de acertos e erros do classificador.

**Tabela 6. Testes com a aplicação, fazendo uso de imagens que não foram utilizadas na etapa de treino do modelo, com as estatísticas de acertos/erros (Fonte: Autoria própria).**

Classe	Total imag.	Acertos	Erros
Covid-19	10	10	0
Normal	11	7	4
Pneumonia	10	10	0

A partir dos resultados da Tabela 6, pode-se dizer que foi obtido 87% de acertos considerando o total de 31 imagens, sendo o erro maior concentrado na avaliação de imagens de pacientes normais.



## 5. Considerações Finais e Trabalhos Futuros.

Após a revisão da literatura, um *dataset* público contendo imagens de RX de tórax de pacientes com COVID-19, pneumonia e normal foi obtido. Foi criado um novo *dataset*, contendo imagens do *dataset* público, além de imagens duplicadas, rotacionadas em 15° e em sentidos opostos. Foi utilizada a técnica de rede neural convolucional, especificamente a CSPDarknet-53, com o *Yolo-v8*, para criação de um modelo preditivo. No uso dessa técnica, foram exploradas variações nos hiperparâmetros, como o Epoch e Batch Size, com o uso ou não das imagens com rotação e sentido oposto, bem como variação na proporção de dados para treinamento e teste. Então, foram obtidos modelos preditivos que foram avaliados com base nas métricas de acurácia, precisão e *recall*.

O melhor modelo obtido foi com a CNN do *Yolo-v8*, proporção de 75% para treinamento e 25% para teste, com imagens rotacionadas e sentido oposto, e *Epochs* em 10. O modelo alcançou uma acurácia média de 94% e precisão de 97%, sendo capaz de lidar com imagens de diferentes fontes e qualidades.

Ao comparar o desempenho deste modelo com aqueles encontrados nos trabalhos relacionados, nota-se uma menor acurácia, como Apostolopoulos e Mpesiana (2020), que obteve acurácia de 96,78% em seu classificador de COVID-19, e Rahman *et al.* (2020), com acurácia de 98% em seu classificador de Pneumonia. Isso pode ter ocorrido pelo tamanho maior do *dataset* ou arquitetura da CNN utilizada nesses trabalhos, ou ainda, pelo modelo deste projeto ser multiclasse (COVID-19, pneumonia e normal), enquanto os demais trabalhos utilizaram apenas duas classes.

Desenvolveu-se também uma aplicação *web*, possibilitando a integração do classificador com um sistema simples e de fácil acesso.

A hipótese deste projeto que infere que é possível realizar a detecção de doenças pulmonares, como COVID-19 e Pneumonia, pelo uso de um classificador que faz uso de redes neurais profundas com boa assertividade foi validada.

É importante ressaltar que, apesar dos resultados alcançados pelo classificador, a aplicação não substitui a avaliação e o diagnóstico médico especializado. Recomenda-se sempre buscar a orientação de um profissional de saúde qualificado para uma avaliação mais abrangente e confirmação do diagnóstico. A aplicação *web* desenvolvida pode auxiliar, por exemplo, em uma triagem para encaminhar o paciente ao médico que se encarregará de fazer a investigação e diagnóstico completo.

Este projeto apresentou algumas limitações e dificuldades, que podem ser abordadas em pesquisas futuras. Por exemplo, não foi realizado pré-tratamento e pré-processamento das imagens treinadas, isso pode dificultar a identificação de padrões mais complexos. Além disso, aumentar a diversidade e a quantidade de dados utilizados pode oferecer um modelo mais assertivo.

## Referências

ABBAS, Asmaa; ABDELSAMEA, Mohammed M.; GABER, Mohamed Medhat. Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Applied Intelligence*, v. 51, p. 854-864, 2021.

APOSTOLOPOULOS, Ioannis D.; MPESIANA, Tzani A. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and engineering sciences in medicine*, v. 43, p. 635-640, 2020.

ASSUNÇÃO, Raíssa Guará; PEREIRA, Wellison Amorim; ABREU, Afonso Gomes. Pneumonia bacteriana: aspectos epidemiológicos, fisiopatologia e avanços no diagnóstico. *Rev Inv Biomédica*, v. 10, n. 1, p. 83-91, 2018.

BRAGA, Isaque Oliveira et al. Pandemia da COVID-19: o maior desafio do século XXI. *Vigilância Sanitária em Debate: Sociedade, Ciência & Tecnologia*, v. 8, n. 2, p. 54-63, 2020.

CARVALHO, André et al. Inteligência Artificial—uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 2011. recurso online.

CHOWDHURY, Muhammad EH et al. Can AI help in screening viral and COVID-19 pneumonia?. *Ieee Access*, v. 8, p. 132665-132676, 2020.

DA SILVA MELO, Andréa Paula; DE FREITAS CARNAÚBA, Soraya Mendonça. Pneumonia viral: principais sintomas, fisiopatologias, diagnóstico, tratamento e prevenção Viral pneumonia: main symptoms, pathophysiology, diagnosis, treatment and prevention. *Brazilian Journal of Development*, v. 7, n. 7, p. 68673-68679, 2021.

DE MILANO, Danilo; HONORATO, Luciano Barrozo. Visão computacional. Faculdade de Tecnologia, Universidade Estadual de Campinas, 2010.

DE SOUSA FILHO, Emanuel LC et al. Um Método Baseado em Radiomics e MLP para Diagnóstico Automático de COVID-19 a partir de Raio-X de Tórax. In: *Anais da X Escola Regional de Computação do Ceará, Maranhão e Piauí*. SBC, 2022. p. 188-197.

ECCLES, Ron. Understanding the symptoms of the common cold and influenza. *The Lancet infectious diseases*, v. 5, n. 11, p. 718-725, 2005.

FIGUEIREDO, Luiz Tadeu Moraes. Pneumonias virais: aspectos epidemiológicos, clínicos, fisiopatológicos e tratamento. *Jornal Brasileiro de pneumologia*, v. 35, p. 899-906, 2009.

GU, Jiuxiang et al. Recent advances in convolutional neural networks. *Pattern recognition*, v. 77, p. 354-377, 2018.

HASTOMO, Widi et al. Characteristic parameters of epoch deep learning to predict Covid-19 data in Indonesia. In: *Journal of Physics: Conference Series*. IOP Publishing, 2021. p. 012050.

LAUXMANN, Martin Alexander; SANTUCCI, Natalia Estefanía; AUTRÁN-GÓMEZ, Ana María. The SARS-CoV-2 coronavirus and the COVID-19 outbreak. *International braz j urol*, v. 46, p. 6-18, 2020.

LEE, Kyung-Yil et al. Pneumonia por micoplasma, pneumonia bacteriana e pneumonia viral. *Jornal de Pediatria*, v. 86, p. 448-450, 2010.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. *nature*, v. 521, n. 7553, p. 436-444, 2015.

MARQUES FILHO, Ogê; NETO, Hugo Vieira. Processamento digital de imagens. Brasport, 1999.

MARTINS, João Victor Gomes et al. Classificação da COVID-19 em Radiografias do Tórax Utilizando Redes Neurais Profundas e Padrões Binários Locais. *Journal of Health Informatics*, v. 12, 2020.

NIBIB. X-rays. 2022. Disponível em: <https://www.nibib.nih.gov/science-education/science-topics/x-rays>

NOLTE, Frederick S. Molecular diagnostics for detection of bacterial and viral pathogens in community-acquired pneumonia. *Clinical infectious diseases*, v. 47, n. Supplement\_3, p. S123-S126, 2008.

RAHMAN, Tawsifur et al. Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest X-ray. *Applied Sciences*, v. 10, n. 9, p. 3233, 2020.

RAHMAN, Tawsifur et al. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in biology and medicine*, v. 132, p. 104319, 2021.

RAHMAN, T. et al. COVID-19 Radiography Database. Kaggle, 2022. Disponível em: <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>.

SHAH, Faisal Muhammad et al. A comprehensive survey of covid-19 detection using medical images. *SN Computer Science*, v. 2, n. 6, p. 434, 2021.

SILVEIRA, Luiza Carvalho et al. Combinação de técnicas de aprendizado profundo para a classificação de raio-x torácico em apoio ao diagnóstico de Covid-19. 2022. Dissertação de Mestrado. Universidade Federal de Pernambuco.

SOUZA, Ewerton Pacheco de et al. Aplicações do Deep Learning para diagnóstico de doenças e identificação de insetos vetores. *Saúde em Debate*, v. 43, p. 147-154, 2020.

SUGANYADEVI, S.; SEETHALAKSHMI, V.; BALASAMY, K. A review on deep learning in medical image analysis. *International Journal of Multimedia Information Retrieval*, v. 11, n. 1, p. 19-38, 2022.

TOGNI, Jimi; ATTUX, Romis. Comparação de Modelos Neurais de Classificação de Imagens de Raios-X para Detecção de COVID-19, 2021.

VAN DOREMALEN, Neeltje et al. Aerosol and surface stability of SARS-CoV-2 as compared with SARS-CoV-1. *New England journal of medicine*, v. 382, n. 16, p. 1564-1567, 2020.

WANG, Linda; LIN, Zhong Qiu; WONG, Alexander. Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific reports*, v. 10, n. 1, p. 1-12, 2020.

XIASONG Wang, Yifan Peng, Le Lu, Zhiyong Lu, Mohammadhadi Bagheri, Ronald Summers, ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases, *IEEE CVPR*, pp. 3462-3471, 2017.

YANG, Dandi et al. Detection and analysis of COVID-19 in medical images using deep learning techniques. *Scientific Reports*, v. 11, n. 1, p. 19638, 2021.

YOU, Yang; GITMAN, Igor; GINSBURG, Boris. Large batch training of convolutional networks. *arXiv preprint arXiv:1708.03888*, 2017.