



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Paulo Ricardo Andrade Gomes

Diagnóstico de COVID-19 em imagens de raios-X de tórax utilizando Redes neurais residuais

São Luís - MA

2022

Paulo Ricardo Andrade Gomes

Diagnóstico de COVID-19 em imagens de raios-X de tórax utilizando Redes neurais residuais

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Universidade Federal do Maranhão

Orientador: Prof. Dr. Geraldo Braz Junior

São Luís - MA

2022

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Gomes, Paulo Ricardo Andrade.

Diagnóstico de COVID-19 em imagens de raios-X de tórax
utilizando Redes neurais residuais / Paulo Ricardo Andrade
Gomes. - 2022.

45 p.

Orientador(a): Geraldo Braz Junior.

Monografia (Graduação) - Curso de Ciência da
Computação, Universidade Federal do Maranhão, São Luís -
MA, 2022.

1. Aprendizado por transferência. 2. COVID-19. 3.
Imagens médicas. 4. Raio-x do tórax. 5. Redes residuais.
I. Junior, Geraldo Braz. II. Título.

Paulo Ricardo Andrade Gomes

Diagnóstico de COVID-19 em imagens de raios-X de tórax utilizando Redes neurais residuais

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Prof. Dr. Geraldo Braz Junior
Orientador
Universidade Federal do Maranhão

Profa. Dra. Simara Vieira da Rocha
Examinador Interno
Universidade Federal do Maranhão

**Prof. Dr. Carlos Eduardo Portela
Serra de Castro**
Examinador Interno
Universidade Federal do Maranhão

São Luís - MA
2022

Dedico este trabalho a todos os que me ajudaram ao longo desta trajetória.

Agradecimentos

Agradeço a minha família, em especial meus pais, que sempre me deram apoio e confiança para continuar este trabalho. A minha mãe, que sempre me incentivou a estudar, mesmo nos momentos mais difíceis ou nos dias mais cansativos. Ao homem que hoje posso chamar de pai, que me acolheu nos momentos de maior dificuldade que passei com minha mãe em vida e me deu condições de ter uma educação e um futuro promissor. Obrigado, Iwan e Conceição.

Agradeço a Larissa Costa, que me ajudou muito a finalizar este trabalho depois de todo e qualquer desânimo ou frustração. Devo metade deste trabalho a ela e a dedicação que ela colocou para me ajudar no término desta monografia. E, acima de tudo, foi minha maior motivação para que pudesse seguir em frente e terminar este presente trabalho.

Agradeço a meu amigo Dayvson, que me ajudou com parte do trabalho e tornou parte da produção deste mais leve e conseguiu contribuir para minha formação. Agradeço também a meu amigo Micael que também me motivou a terminar este trabalho.

Agradeço ao professor Geraldo Braz pela oportunidade e por aceitar ser meu orientador neste trabalho, além de um amigo e um ótimo professor.

Ao núcleo de computação aplicada, que me proporcionou o primeiro contato com Aprendizado de máquina e pesquisa científica.

A Universidade Federal do Maranhão, que me proporcionou: um ambiente para início deste trabalho, amigos que tive o prazer de conhecer e a oportunidade de fazer o curso de Ciência da computação.

"Aprendizagem nunca esgota a mente."

(Leonardo da Vinci)

Resumo

A pandemia originada em dezembro de 2019, na cidade de Wuhan, na China, trás até hoje efeitos colaterais de sua existência e manifestação pelo mundo inteiro. Atualmente, o vírus do COVID-19 já contaminou mais de 250 milhões de pessoas, e, dessas, mais de 5 milhões morreram acometidas pelo vírus por todo o mundo. Um ponto importante no combate a pandemia é a detecção da doença em pacientes que apresentam sintomas relacionados a ela. Imagens de raio-X do tórax podem ser importantes na detecção de patologias como a do próprio COVID-19, porém isso se torna um processo demorado e sujeito a variabilidade entre os especialistas. Assim sendo, este trabalho tem como objetivo propor um método automatizado capaz de auxiliar na detecção e diagnóstico do COVID-19 por meio das imagens de raio-X do tórax. O método proposto possui quatro etapas principais: (1) Aquisição de imagens por meio de bases públicas; (2) Pré-processamento e preparação das imagens; (3) Treinamento e aprendizado por transferência utilizando Redes residuais; (4) Classificação das imagens em COVID-19 ou não COVID-19, utilizando as redes ResNet50, ResNet101 e ResNet152. Após a realização dos experimentos, o método proposto conseguiu atingir resultados promissores. A rede ResNet50 conseguiu atingir uma acurácia de 99% e uma precisão de 98,5%, enquanto que a ResNet152 conseguiu atingir 98,5% de sensibilidade, a maior entre as 3, e ambas conseguiram atingir 98% de *F1-score*. A rede ResNet101 apresentou a pior performance dentre as 3, e ainda assim alcançou uma acurácia de 98%, uma precisão de 98%, uma sensibilidade de 96% e um *F1-score* de 96,5%. Neste estudo, foi mostrado que as redes residuais (ResNet), com auxílio de técnicas de pré-processamento na base e aprendizado por transferência, são eficientes e promissoras na tarefa de classificação de imagens médicas de raio-X como COVID-19 ou não COVID-19. O presente estudo oferece uma alternativa promissora para que a área médica possa enfrentar a pandemia do COVID-19.

Palavras-chave: Raio-x do tórax, COVID-19, Pré-processamento, Aprendizado por transferência, Redes Residuais, Imagens médicas.

Abstract

The pandemic originated in December 2019, in the city of Wuhan, China, until today brings side effects of its existence and manifestation around the world. Currently, the COVID-19 virus has infected more than 250 million people, and of these, more than 5 million have died from the virus worldwide. An important point in combating the pandemic is the detection of the disease in patients who have symptoms related to it. Chest X-ray images can be important in detecting pathologies such as COVID-19 itself, but this becomes a time-consuming process and subject to variability among specialists. Therefore, this work aims to propose an automated method capable of assisting in the detection and diagnosis of COVID-19 through chest X-ray images. The proposed method has four main steps: (1) Image acquisition through public databases; (2) Pre-processing and preparation of images; (3) Training and transfer learning using residual networks; (4) Classification of images as COVID-19 or not COVID-19, using the ResNet50, ResNet101 and ResNet152 networks. After carrying out the experiments, the proposed method managed to achieve promising results. The ResNet50 network managed to achieve an accuracy of 99% and a precision of 98.5%, while the ResNet152 managed to achieve a sensitivity of 98.5%, the highest among the 3, and both managed to achieve 98% of *F1-score*. The ResNet101 network had the worst performance among the 3, but still achieved an accuracy of 98%, a precision of 98%, a sensitivity of 96% and a *F1-score* of 96.5%. In this study, it was shown that residual networks (ResNet), with the aid of pre-processing techniques applied to the base and transfer learning, are efficient and promising in the task of classifying medical X-ray images as COVID-19 or non-COVID-19. The present study offers a promising alternative for the medical field to face the COVID-19 pandemic.

Keywords: Chest x-ray, COVID-19, Pre-processing, Transfer learning, Residual networks, Medical imaging.

Lista de ilustrações

Figura 1 – Imagem de raios-X de um paciente com COVID-19.	19
Figura 2 – Equipamento utilizado em exame de raios-X do tórax.	20
Figura 3 – Bloco residual da ResNet.	21
Figura 4 – Arquitetura da ResNet.	22
Figura 5 – Exemplo de utilização da técnica <i>flipping</i> na horizontal.	25
Figura 6 – Exemplo de utilização da técnica <i>flipping</i> na vertical.	25
Figura 7 – Da esquerda para à direita as imagens são rotacionadas 90 graus no sentido horário em relação à anterior.	25
Figura 8 – Exemplos de imagens com translação a partir da original.	26
Figura 9 – Fluxograma da metodologia proposta.	31
Figura 10 – Exemplos da base de imagens: (a) Casos de pacientes em condições normais. (b) Casos de pacientes diagnosticados com COVID-19.	32
Figura 11 – Exemplos da base de imagens: (a) Imagem original. (b) Imagem com deslocamento. (c) Imagem com rotação. (d) Imagem invertida horizontalmente.	33
Figura 12 – Evolução da acurácia e <i>loss</i> durante o ajuste da rede base.	37

Lista de tabelas

Tabela 1 – Trabalhos relacionados.	29
Tabela 2 – Relação entre imagens usadas para treinamento, validação e teste . . .	35
Tabela 3 – Classificação utilizando apenas o topo ajustado	36
Tabela 4 – Classificação utilizando as redes completamente ajustadas	38
Tabela 5 – Comparação com trabalhos relacionados.	38

Lista de abreviaturas e siglas

ACC	<i>Acurácia</i>
CNN	<i>Convolutional Neural Network</i>
F1	<i>F1-score</i>
FN	<i>Falso Negativo</i>
FP	<i>Falso Positivo</i>
PRE	<i>Precisão</i>
RELU	<i>Rectified Linear Unit</i>
ResNet	<i>Residual Neural Network</i>
SARS	<i>Síndrome Respiratória Aguda Grave</i>
SARS-CoV-2	<i>Síndrome Respiratória Aguda Grave de Coronavírus 2</i>
SEN	<i>Sensibilidade</i>
VN	<i>Verdadeiro Negativo</i>
VP	<i>Verdadeiro Positivo</i>

Sumário

1	INTRODUÇÃO	14
1.1	Objetivos	15
1.1.1	Objetivos Específicos	15
1.1.2	Contribuições	15
1.2	Organização do Trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	COVID-19	17
2.2	Raio-x do tórax	18
2.3	Reconhecimento de padrões	20
2.4	Redes residuais	21
2.5	Transfer learning	23
2.6	Data augmentation	24
2.6.1	Flipping	24
2.6.2	Rotação	25
2.6.3	Translação	25
2.7	Métricas de desempenho	26
3	TRABALHOS RELACIONADOS	28
4	METODOLOGIA	31
4.1	Base de dados	31
4.2	Pré-processamento	32
4.3	Transfer learning	33
4.4	Classificação de diagnóstico utilizando redes residuais	34
5	RESULTADOS	35
5.1	Configuração Experimental	35
5.2	Divisão e preparação da base	35
5.3	Treinamento	36
5.3.1	Ajuste do Classificador	36
5.3.2	Ajuste da Rede Base (tunning)	36
5.4	Classificação	37
5.5	Discussão dos resultados	38
6	CONCLUSÃO	40

REFERÊNCIAS 42

1 Introdução

Em dezembro de 2019 surgiu um novo tipo de pneumonia na Cidade de Wuhan, China, (ZHANG et al., 2020a). Inúmeros novos casos começaram a surgir velozmente em países asiáticos, tais como Tailândia, Japão, Coréia do Sul e Singapura, posteriormente se alastrando para a Europa e demais continentes (AQUINO et al., 2020), levando a Organização Mundial de Saúde (OMS) a decretar uma Emergência de Saúde Pública de Importância Internacional em 30 de janeiro de 2020. Posteriormente a doença foi denominada Síndrome Respiratória Aguda Grave de Coronavírus 2 (SARS-CoV-2), sendo elevada a uma pandemia mundial no dia 11 de março de 2020 (ORGANIZATION, 2020).

O SARS-CoV-2 aparece como um novo subtipo de síndrome respiratória aguda grave (SARS-CoV) humana, caracterizada por sua alta capacidade de transmissão e indução de quadros de infecção respiratória severa (ZHOU et al., 2020). Ainda que a letalidade da doença causada pelo novo coronavírus seja inferior se comparada a outros coronavírus, sua alta transmissibilidade tem provocado um maior número absoluto de mortes do que a combinação das epidemias produzidas pelos SARS-CoV e o MERS-CoV (MAHASE, 2020). A transmissão do COVID-19 ocorre predominantemente, por meio de gotículas contaminadas de secreções da orofaringe de uma pessoa infectada para uma pessoa não infectada, pelo contato com superfícies e objetos contaminados, onde o vírus pode permanecer ativo por até 72 horas (DOREMALEN et al., 2020), ou por via fecal-oral (WANG et al., 2020).

Os principais sintomas da COVID-19 surgem após alguns dias da infecção pelo vírus, algumas pessoas podem não sentir os sintomas, mas mesmo assim, foram infectadas e podem transmitir a doença. No paciente infectado pode se manifestar febre, tosse e fadiga, além de uma produção de expectoração, alteração do paladar, perda de olfato, distúrbios gastrintestinais, cefaleia, hemoptise, dispneia e linfopenia (ROTHAN; BYRAREDDY, 2020). A pessoa que apresentar alguns desses sintomas deve se manter em isolamento por pelo menos 14 dias, para evitar a transmissão do vírus, impedindo uma infecção generalizada (BOCCIA; RICCIARDI; IOANNIDIS, 2020).

Apesar de já possuímos melhores condições de lidar com a pandemia, a comunidade global está em constante busca por novas soluções que possuam eficiência ao investigar e diagnosticar a doença. Hoje, processos de análise de imagem são altamente consolidados e utilizados para auxiliar no diagnóstico de patologias. As imagens de raios-X do tórax são mecanismos utilizados em larga escala para auxiliar especialistas a identificar certas doenças, como o COVID-19 (HEMDAN; SHOUMAN; KARAR, 2020).

Diversos métodos foram propostos para auxiliar na tarefa de detecção e diagnóstico

de doenças. O diagnóstico auxiliado por computador (*Computer-aided diagnosis* - CAD) se tornou um dos objetos de pesquisa mais explorados na área de imagens médicas e radiologia diagnóstica (DOI, 2007). Esses métodos computacionais podem auxiliar diretamente os especialistas na tarefa do diagnóstico de COVID-19, fornecendo uma segunda opinião, ajudando na percepção da patologia e, por conseguinte, auxiliando os especialistas a tomarem decisões.

1.1 Objetivos

O objetivo geral deste trabalho consiste em analisar a transferência de aprendizado e redes neurais convolucionais aplicada ao diagnóstico de COVID-19 usando imagens de Raio-X.

1.1.1 Objetivos Específicos

- Desenvolver um método para diagnosticar, a partir de imagens de raios-x de tórax, pacientes como infectados ou não pela COVID-19;
- Utilizar a técnica de transfer learning para criar um modelo de predição sólido a partir de modelos já existentes;
- Colaborar com uma ferramenta proficiente para o diagnóstico de COVID-19.

1.1.2 Contribuições

Destacam-se como principais contribuições:

- um método totalmente automatizado para classificar imagens de raios-x de tórax de casos de COVID-19 ou não COVID-19;
- Utilização de técnicas de Image Augmentation em imagens de raios-x de tórax;
- Utilização da técnica de transfer learning com redes residuais pré-treinadas para classificação de imagens de raios-x;

1.2 Organização do Trabalho

Este trabalho está estruturado da seguinte forma:

- O Capítulo 2 disserta a fundamentação teórica essencial para a construção e desenvolvimento deste trabalho. São abordados os conceitos referentes ao COVID-19,

exame de raio-x do tórax, redes ResNet50, ResNet101 e ResNet152, transfer learning e reconhecimento de padrões.

- O Capítulo 3 aborda trabalhos relacionados à temática deste estudo, a partir de pesquisas realizadas por meio de testes com raio-x de tórax.
- O Capítulo 4 apresenta a metodologia e materiais utilizados nos estudos para classificar pacientes infectados pela COVID-19 através de imagens de Raio-x de tórax.
- O Capítulo 5 aponta os resultados alcançados pelo método proposto juntamente a discussão dos resultados obtidos.
- O Capítulo 6 apresenta as considerações finais do trabalho e sugestões para trabalhos futuros.

2 Fundamentação Teórica

Neste capítulo serão apresentados e descritos os tópicos essenciais para o entendimento das técnicas utilizadas na elaboração deste trabalho. As seguintes seções tratam de conceitos sobre o COVID-19, o exame de raio-x do tórax, redes ResNet50, ResNet101 e ResNet152, *Transfer learning*, *Data augmentation*, reconhecimento de padrões e as métricas de desempenho para validação dos resultados.

2.1 COVID-19

Disseminadas em diversas proporções, as doenças virais estão espalhadas em todos os lugares do mundo e suas consequências podem variar de acordo com as características de cada espécie do vírus. Os danos causados pelas infecções virais podem causar simples sequelas ou até a morte dependendo da infecção viral adquirida. Uma das espécies mais relevantes e constantemente causadoras de patologias virais são os coronavírus. Esses foram identificados como nocivos à saúde humana nos anos 60, sua estrutura em formato de coroa é o motivo da sua denominação, vinda da palavra latina corona. Apesar de estar presente apenas entre animais, a infecção pode ocorrer devido a proximidade desses animais com pessoas, conseqüentemente o vírus poderá sofrer mutações necessárias para atingir humanos (ROSA et al., 2020; JIANG, 2020).

O coronavírus, representante da ordem Nidovirales, família Coronaviridae e subfamília Coronaviridae, são grandes responsáveis por doenças hepáticas, neurológicas, respiratórias, entre outras. Por serem patogênicos aos seres humanos, suas sequelas podem variar de corpo para corpo, entre essas estão fibrose pulmonar, comprometimento da respiração, entre lesões nos sistemas vascular, nervoso e outros vitais para o funcionamento do corpo humano (LI et al., 2019).

Apesar de existirem múltiplas variações de coronavírus que podem infectar humanos, o responsável pela atual pandemia é o SARS-CoV-2 (conhecido popularmente como COVID-19), um perigoso patógeno humano que atingiu o mundo em grandes partes, causando todas as mudanças que se vive atualmente, levando milhões de pessoas a morte (LI et al., 2019; KIM et al., 2020).

Em Dezembro de 2019, surgiram os primeiros casos de infecção pelo novo coronavírus na cidade de Wuhan, China. Inicialmente foi tratado como um surto de pneumonia de causas desconhecidas, e posteriormente amostras respiratórias dos enfermos detectaram a presença do SARS-CoV-2, agente causador da doença COVID-19. Mesmo com o isolamento daquela e outras cidades no entorno para evitar o contágio, o vírus se propagou de maneira

acelerada, levando a Organização Mundial da Saúde (OMS), declarar em 11 de março de 2020, a infecção pelo novo coronavírus uma pandemia mundial (BEECHING et al., 2020).

Sabe-se atualmente que o SARS-CoV-2 pode ser transmitido de várias formas, dependendo da proximidade entre os indivíduos ou contato com objetos infectados em um determinado ambiente. Essa transmissão pode ocorrer por inalação ou contato direto com secreções contaminadas. A propagação do vírus pode se suceder através de tosse, espirros, contato corpo a corpo e com superfícies contaminadas. Caso ocorra o contágio, os sintomas mais frequentes são a febre, tosse, mialgias, fadigas e dispneias, mormente, contudo algumas pessoas podem ser assintomáticas, ou seja, não sentir nenhum dos sintomas citados, porém pode transmitir a doença apesar de sua condição (ROSA et al., 2020; SINGHAL, 2020).

Existem diversas formas de se obter o diagnóstico do novo coronavírus. De acordo com o Ministério da Saúde (SAÚDE, 2020), o quadro clínico inicialmente é classificado como Síndrome Gripal, o diagnóstico pode ser identificado através de investigação clínica-epidemiológica, anamnese ou exame físico caso o paciente apresente os sintomas mais comuns da doença, além de considerar o histórico de proximidade do mesmo com pessoas infectadas ou suspeitas de infecção. Ademais, existem outros métodos para a detectar a presença do vírus no corpo, como o diagnóstico laboratorial (feito por meio de exames laboratoriais), biologia molecular (RT-PCR) e imunológicos e o teste rápido (imunoensaio por eletroquimioluminescência). Outro método utilizado para o diagnóstico do SARS-CoV-2 é a investigação de imagem, geralmente feita em laboratórios específicos, são investigadas lesões em imagens de Raio-x do tórax para classificar uma pessoa com o Covid-19 ou uma outra infecção viral e pessoas saudáveis (JIANG, 2020; SUN et al., 2020).

2.2 Raio-x do tórax

O exame de raio-x é um método comumente usado no diagnóstico de doenças e problemas respiratórios, pois é rápido e simples, além de possuir um custo relativamente baixo, de forma que as pessoas possam acompanhar o tratamento de diversos tipos de doença ou problemas de saúde. A partir dele, é possível acompanhar a situação de muitas partes dentro do corpo, dentre elas: as vias aéreas, os pulmões, possíveis fissuras ou fraturas nos ossos, condição do coração, o COVID-19, veias sanguíneas e até mesmo o posicionamento de dispositivos médicos (COLLINS; STERN, 2008).

A radiografia de tórax é o exame de radiografia de diagnóstico mais comum. Os raios X são a forma mais antiga e mais usada de imagem médica. Esses exames são realizados com a ajuda de um tubo de produção de raios-x, normalmente localizado a dois metros de distância, expondo o paciente a uma pequena dose de radiação ionizante para produzir imagens do interior do corpo. O exame também pode ser realizado com o paciente deitado e o tubo de produção logo acima do mesmo, e uma placa de gravação logo abaixo do

paciente. O paciente pode ser solicitado a se posicionar de maneiras diferentes para se obter a visualização de perspectivas diferentes, normalmente da frente e das laterais do tórax. Ao atravessar as estruturas internas do paciente como órgãos ou ossos, quanto mais sólida for a mesma, mais branca ela aparecerá no filme gravado (INFO, 2020; PFENNINGER; FOWLER, 2010). A Figura 1 ilustra uma imagem de raios-X do tórax de um paciente contaminado pelo COVID-19.

Figura 1 – Imagem de raios-X de um paciente com COVID-19.



Para a produção da imagem radiológica, é necessário: uma fonte geradora de radiação, o objeto de irradiação (corpo do paciente) e um sistema de registro do resultado da interação do feixe de radiação com o corpo. Os equipamentos utilizados possuem várias formas e tamanhos. Os aparelhos fixos ficam localizados em uma sala reservada para sua utilização, com fornecimento adequado de energia e espaço para movimentação do paciente, do técnico e da equipe de enfermagem, e também necessitam de um local reservado para o operador controlar o equipamento a distância, armários e uma mesa para que sejam realizados os exames, entre outras coisas. Já os equipamentos móveis dispensam a utilização de uma mesa de exames, e os controles estão fisicamente juntos com a unidade que gera a radiação (SOARES; LOPES, 2015). A Figura 2 ilustra um aparelho usado em exames de raios-x do tórax.

Na visualização frontal, o paciente fica de pé paralelo à placa, posicionando os braços e controlando a respiração conforme solicitado pelo técnico de raios-X. Prender a respiração após inspirar ajuda os pulmões e o coração a aparecerem mais nitidamente na imagem. Os exames de radiografia são indolores e o paciente não sente nada quando a radiação passa pelo seu corpo (PFENNINGER; FOWLER, 2010).

Uma grande parte das imagens de raios-X são arquivos eletrônicos armazenados em

Figura 2 – Equipamento utilizado em exame de raios-X do tórax.



Fonte: (SOARES; LOPES, 2015)

bases de dados de fácil acesso para que futuramente possam ser utilizadas para diagnóstico e controle de doenças.

2.3 Reconhecimento de padrões

O processo de reconhecimento de padrões visa ordenar e reconhecer objetos em uma determinada classe ou categoria por meio da análise de suas características (THEODORIDIS; KOUTROUMBAS, 2009). Desse modo, desenvolve-se uma representação simplificada de um conjunto de dados por intermédio de suas principais características, viabilizando sua partição em classes (HART; STORK; DUDA, 2000).

O reconhecimento de padrões ocorre por meio de duas etapas em seu processo, sendo essas a classificação e reconhecimento. A etapa de classificação consistem na partição de uma amostra de uma população em classes. Durante a etapa de reconhecimento, uma amostra desconhecida, mas integrante da mesma população, é prontamente reconhecida como componente de classes criadas anteriormente (LOONEY, 1997).

Os métodos de classificação são separados em duas categorias: supervisionada e não supervisionada. A classificação supervisionada consiste em uma técnica de treinamento de

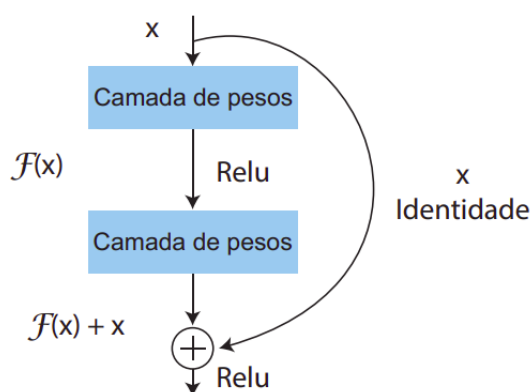
um classificador para captar padrões desejados, de modo que, a posteriori, seja capaz de classificar qualquer objeto desconhecido de uma mesma população. Na classificação não supervisionada, não existe a priori uma informação sobre as classes que cada amostra é pertencente (PEDRINI; SCHWARTZ, 2008).

Neste trabalho, para a classificação supervisionada, foram utilizadas redes neurais residuais (HE et al., 2015), sendo estas ResNet50, ResNet101, ResNet152 (técnicas abordadas no a Seção 2.4 deste capítulo), de modo que ocorresse a distinção entre as classes COVID-19 e não COVID-19.

2.4 Redes residuais

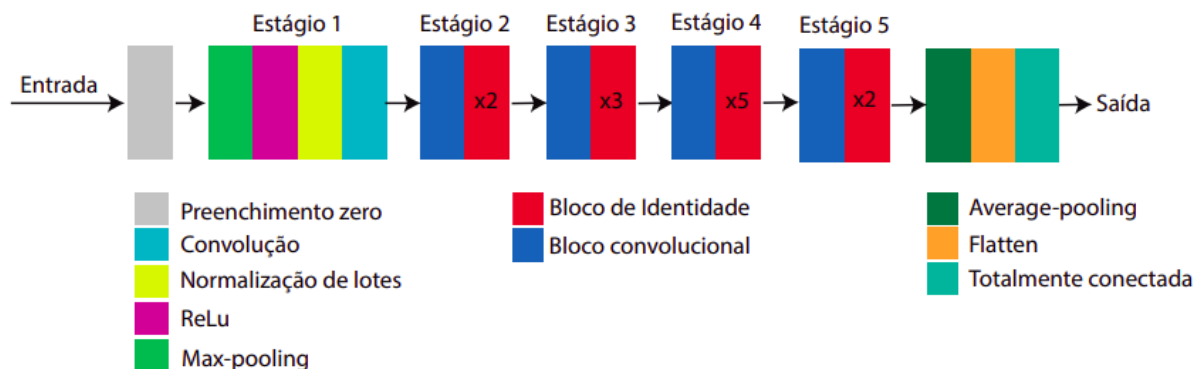
As redes residuais são uma família de redes de mesma arquitetura que diferem basicamente na quantidade de camadas que possuem. Também chamada de ResNet (HE et al., 2016) (abreviatura para *Residual Network*), a rede residual apresenta uma nova camada denominada unidade de aprendizagem residual, que visa mitigar a degradação da aprendizagem em redes profundas (NGUYEN et al., 2018). As unidades residuais, ou blocos residuais, são conexões de atalho que conectam a saída de uma camada com a entrada de uma outra realizando "saltos" sobre uma ou mais camadas (HE et al., 2016). O uso de blocos residuais pode resultar na melhora da precisão da classificação sem aumentar a complexidade do modelo, se livrando da degradação no aprendizado e aumentando a velocidade no treinamento (HE et al., 2016; SZEGEDY et al., 2017). A figura 3 ilustra o funcionamento do bloco residual.

Figura 3 – Bloco residual da ResNet.



Esta arquitetura propõe que as camadas continuem a receber os valores resultantes da função de ativação *Rectified Linear Unit* (ReLU - Uma função simples não linear que retorna zero se o valor de entrada é negativo e mantém o valor de entrada caso seja maior ou igual a zero), da camada anterior, mas também recebam os valores de entrada x dessas funções, como pode ser observado na Figura 3.

Figura 4 – Arquitetura da ResNet.



Fonte: (RIZWAN, 2018)

De forma simplificada, a ideia dos atalhos em ResNets é evitar que a rede, muito profunda, se deteriore por esvanecimento de gradientes através do empilhamento de mapeamentos de identidades que, do ponto de vista matemático, estão simplesmente empilhando camadas que não fazem nada. Com isso, como mostra a Figura 3, a ResNet utiliza, num determinado ponto, um sinal que é a soma do sinal produzido pelas duas camadas convolucionais anteriores somado ao sinal transmitido diretamente do ponto anterior a estas camadas, juntando um sinal processado com um sinal de uma etapa anterior no processamento (HE et al., 2016; RIZWAN, 2018). A arquitetura básica de uma ResNet é descrita na Figura 4.

Para este trabalho, foram selecionadas as redes: ResNet-50, ResNet-101 e ResNet-152.

A rede ResNet-50 é uma rede da família das redes residuais que possui 50 camadas, sendo destas 48 de convolução e 2 camadas de *pooling*, possuindo também camadas residuais, totalmente conectadas e a camada *softmax*. A ResNet50 possui o formato de entrada $224 \times 224 \times 3$ (HE et al., 2015).

A rede ResNet-101 é uma rede com 101 camadas, sendo destas, também, 2 camadas de *pooling* e uma totalmente conectada, além de suas camadas residuais e de *softmax*. É uma rede promissora para reconhecimento de pneumonias virais e até mesmo os efeitos do COVID-19. Assim como a ResNet-50, o formato de entrada da ResNet-101 é $224 \times 224 \times 3$ (VINOD et al., 2021; HE et al., 2015).

A rede ResNet-152, assim como as anteriormente citadas, também possui uma entrada no formato $224 \times 224 \times 3$, e, apesar de suas 152 camadas, sendo também 2 de *pooling* e uma totalmente conectada, além de suas inúmeras camadas residuais, e a de *softmax*, possui uma complexidade menor do que algumas redes já consolidadas, como as VGG-16 e VGG-19. Esta mesma rede conseguiu, em 2015, vencer o ILSVRC (ImageNet Large Scale

Visual Recognition Challenge). (HE et al., 2015).

2.5 Transfer learning

O *Transfer learning* é o processo onde ocorre a melhoria da aprendizagem em uma nova tarefa por meio da transferência de aprendizado originado a partir de uma tarefa relacionada que já foi aprendida. Enquanto a maioria dos algoritmos de aprendizado de máquina são projetados para lidar com tarefas específicas, o desenvolvimento de algoritmos que facilitam a aprendizagem por transferência é um tópico de interesse contínuo na comunidade de aprendizado de máquina (TORREY; SHAVLIK, 2010).

Em termos de *deep learning*, o aprendizado por transferência é uma técnica onde uma rede neural é pré-treinada em um problema semelhante ao que está em questão. Uma ou mais camadas do modelo pré-treinado são então reutilizadas em um novo modelo treinado para solucionar o problema de interesse. Em outras palavras, quando a entrada é a mesma, mas o alvo é de uma natureza diferente, é promissor reutilizar um modelo pré-treinado para alcançar um bom desempenho na classificação (GOODFELLOW; BENGIO; COURVILLE, 2017).

Os pesos nas camadas que foram reutilizadas podem ser usados como ponto de partida para o processo de treinamento e adaptados para o novo problema. Esse uso trata o aprendizado por transferência como um tipo de esquema de inicialização de peso. Isso pode ser útil quando o primeiro problema relacionado tem muito mais dados rotulados do que o problema de interesse e a semelhança na estrutura do problema pode ser útil em ambos os contextos. O objetivo da técnica é aproveitar os dados da primeira configuração para extrair informações que podem ser úteis no aprendizado ou mesmo ao fazer previsões diretamente na segunda configuração (GOODFELLOW; BENGIO; COURVILLE, 2017).

A existência de modelos pré-treinados é desejável por vários motivos, dentre eles:

1. Recursos úteis aprendidos: os modelos aprenderam a detectar características genéricas de imagens, uma vez que foram treinados em mais de 1.000.000 de imagens para 1.000 categorias;
2. Alto desempenho: os modelos alcançaram desempenho de ponta e permanecem eficazes na tarefa específica de reconhecimento de imagem para a qual foram designados.
3. Facilmente acessível: os pesos dos modelos são fornecidos como arquivos gratuitos para download e muitas bibliotecas oferecem APIs convenientes para baixar e usar os modelos diretamente.

Os pesos do modelo podem ser baixados e usados na mesma arquitetura de modelo usando uma variedade de bibliotecas de aprendizado profundo, incluindo Keras. Os modelos pré-treinados utilizados neste trabalho foram as redes residuais profundas da Microsoft, também conhecidas por: ResNet-50, ResNet-101 e ResNet-152 (HE et al., 2015).

2.6 Data augmentation

A classificação de imagens é um campo relevante de aplicação do Aprendizado de Máquina, a variação de amostras rotuladas disponíveis e as resoluções estão relacionados, quanto maior a quantidade de exemplos, maior a capacidade de predição dos classificadores gerados. Entretanto, nem sempre existem facilidades para possuir bases de dados com uma grande quantidade de amostras rotuladas (CLARO et al., 2020). Desse modo, podemos utilizar abordagens de *Data augmentation* (DA), que é um conceito fundado por técnicas computacionais com o objetivo de aumentar a quantidade de exemplos rotulados em um conjunto de dados e assim, melhorar os resultados obtidos (TAYLOR; NITSCHKE, 2018).

Existem diversas formas de lidar com complicações relacionadas a dados limitados no aprendizado de máquina. *Data augmentation* é uma técnica relevante no desenvolvimento de redes neurais convolucionais que são capazes de aumentar o tamanho do conjunto de treinamento sem adquirir novas imagens. Neste caso, será preciso duplicar as imagens com algum tipo de variação para que o modelo possa aprender com mais exemplos. Se pode aumentar a imagem de maneira a conservar os recursos essenciais para fazer previsões, mas reorganiza os pixels o suficiente para adicionar algum ruído. O aumento será contraprodutivo se produzir imagens muito diferentes do modelo que será utilizado para testes, logo, esse processo deve ser executado cuidadosamente (CLARO et al., 2020).

A limitação de dados é um obstáculo relevante para a aplicação de modelos de aprendizagem profunda. Constantemente, classes desequilibradas são uma objeção adicional, embora essas possam obter dados necessários para algumas classes relevantes, classes abaixo da amostra serão afetadas com a baixa precisão específica. Esse fenômeno é intuitivo. Se o modelo assimilar alguns exemplos de uma determinada classe, é menos provável prever a invalidação e os aplicativos de teste (SHORTEN; KHOSHGOFTAAR, 2019). As primeiras constatações que mostram a eficiência das técnicas de *Data augmentation* vêm de simples transformações (CLARO et al., 2020). Neste trabalho, foram utilizadas técnicas de Data Augmentation que consistem em inversão de imagem ou *flipping*, rotação e translação.

2.6.1 Flipping

Consiste em uma técnica de inversão da imagem original, na qual pode ser realizada tanto na vertical quanto na horizontal. É mais comum inverter o eixo horizontal do que

inverter o eixo vertical (CLARO et al., 2020). As Figuras 5 e 6 são exemplos de utilização dessa técnica.

Figura 5 – Exemplo de utilização da técnica *flipping* na horizontal.




Figura 6 – Exemplo de utilização da técnica *flipping* na vertical.



2.6.2 Rotação

Essa técnica é feita a partir de um giro na imagem selecionada para a esquerda ou direita em um eixo entre 1° e 359° . A segurança dos aumentos de rotação é determinada pelo parâmetro do grau de rotação (CLARO et al., 2020). A Figura 7 demonstra exemplo de rotação em imagens quadradas rotacionadas em ângulo reto.

Figura 7 – Da esquerda para à direita as imagens são rotacionadas 90 graus no sentido horário em relação à anterior.



2.6.3 Translação

Uma forma de se obter uma transformação útil é mudar as imagens para a esquerda, direita, para cima ou para baixo, podendo evitar distorções posicionais nos dados. Exemplificando, se todas as imagens em um conjunto de dados estiverem centralizadas, isso demandaria que o modelo também fosse testado em imagens impecavelmente centralizadas (CLARO et al., 2020). Como a imagem original é traduzida em uma direção, o espaço restante pode ser completado com um valor constante, como 0 ou 255, ou pode ser preenchido com ruído aleatório ou gaussiano. Esse preenchimento mantém as dimensões espaciais da imagem pós-aumento (SHORTEN; KHOSHGOFTAAR, 2019). Essa técnica é bastante útil, visto que os objetos podem ser localizados em praticamente qualquer

lugar da imagem. Isso força a rede neural convolucional a procurar em todos os lugares da imagem, como ilustra a Figura 8.

Figura 8 – Exemplos de imagens com translação a partir da original.



2.7 Métricas de desempenho

Para que o método oferecido seja avaliado como validado, métricas aceitas na literatura e área de imagens foram utilizadas, sendo elas: acurácia, precisão, sensibilidade e F1- score (DUDA; HART, 1973; FAWCETT, 2006). Este tópico tem como objetivo classificar, por meio de uma análise de estatísticas e resultados, o desempenho do método proposto.

Para que seja realizado o cálculo dessas métricas, se baseou na matriz de confusão, de acordo com 4 variáveis: (1) Verdadeiro Positivo (VP) para casos realmente positivos detectados; (2) Falso Positivo (FP) para casos negativos erroneamente detectados como positivos; (3) Verdadeiro Negativo (VN) para os casos negativos verdadeiramente detectados; e (4) Falso Negativo (FN) para casos positivos detectados erroneamente como negativos.

A métrica acurácia é realizada pela razão entre o número de casos corretamente classificados pelo número total de casos da amostra em estudo. A acurácia é definida na Equação 2.1.

$$Acc = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.1)$$

A sensibilidade ou *Recall* é uma métrica que possui a competência de encontrar todas as instâncias relevantes (verdadeiros positivos) na amostra em uma pesquisa, isto é, demonstra a proporção dos pontos de dados que o modelo diz serem pertinentes e realmente são. A sensibilidade é determinada na Equação 2.2.

$$Sen = \frac{VP}{VP + FN} \quad (2.2)$$

A métrica de precisão é estabelecida como o número de casos positivos dividido pelo número de casos positivos adicionando o número de falsos positivos. Ou seja, trata-se

de uma porcentagem de instâncias classificadas na classe positiva que está assertiva. A Equação 2.3 define esta métrica.

$$Pre = \frac{VP}{VP + FP} \quad (2.3)$$

A métrica F1-score (F1) combina precisão e recall indicando a qualidade geral do modelo, além de trabalhar bem com conjuntos de dados que possuem desequilíbrio entre as classes. Ela faz uma média harmônica entre precisão (Pre) e sensibilidade (Sen). A F1-score é definida na Equação 2.4:

$$F1 = 2 * \frac{Pre * Sen}{Pre + Sen} \quad (2.4)$$

3 Trabalhos Relacionados

Na literatura há vários exemplos de pesquisas relacionadas à temática deste trabalho, mecanismos criados para a facilitação do diagnóstico de infectados pelo COVID-19 por intermédio de imagens de Raio-x do tórax. Algumas dessas pesquisas relacionadas serão resumidas a seguir.

Técnicas baseadas em aprendizado de máquina têm se revelado promissoras e bastante eficazes no diagnóstico de doenças. Com o crescente aumento de casos de COVID-19 ao redor do mundo, se tornou necessário o desenvolvimento e o uso de sistemas automatizados para realizar o diagnóstico de doenças através de determinadas técnicas. Um destes procedimentos é o uso de modelos de rede neural convolucional (Convolutional Neural Network - CNN). [Zhang et al. \(2020b\)](#) e [Hemdan, Shouman e Karar \(2020\)](#) mostraram resultados relevantes na constatação de pacientes infectados utilizando imagens de Raio-x do tórax. Foram empregadas, em ambas as pesquisas, diversas amostras de rede neural convolucional (Convolutional Neural Network - CNN) para constatar a performance da detecção do SARS-CoV-2 em humanos. [Zhang et al. \(2020b\)](#) apresentaram uma acurácia de 96% para os casos de COVID-19 e 70,65% para os casos normais em seus estudos. Nas pesquisas de [Hemdan, Shouman e Karar \(2020\)](#), alcançou-se a acurácia de 90% para os casos normais e COVID-19.

[Ozturk et al. \(2020\)](#) criaram um modelo de detecção inspirado no sistema de detecção de objetos conhecido como “You Only Look Once.” Trata-se de um modelo para classificação binária e multiclasse chamado de DarkCovidNet. O modelo alcançou uma acurácia de 98,08% para a classe binária e 87,02% para a abordagem multiclasse. Para diferenciar casos de pneumonia provocados pelo novo coronavírus daqueles ocasionados por alguma outra infecção e pulmões não afetados, [Pereira et al. \(2020\)](#) utilizaram imagens de Raio-x do tórax juntamente a um modelo CNN pré-treinado e descritores de textura para extrair características. Deste modo obtiveram um F1-score de 65% utilizando uma abordagem multiclasse e um F1-score de 89% para classificação de COVID-19.

[Abbas, Abdelsamea e Gaber \(2021\)](#) Também fizeram o uso de CNNs para o reconhecimento e classificação de imagens de Raio-x do tórax para identificar casos de COVID-19 ou normais. Os autores utilizaram um método denominado DeTraC (*decompose, transfer and compose*) para a melhoria das imagens utilizadas devido a eficiência da própria abordagem que garante lidar com qualquer irregularidade no conjunto de imagens. Em sua pesquisa, obtiveram acurácia de 93,1% diante uma sensibilidade de 100%.

[Rahimzadeh e Attar \(2020\)](#) usaram a combinação das redes Xception e ResNet50V2 para detectar casos de COVID-19. Obtiveram uma acurácia de 99,50%, sensibilidade

de 80,53% e uma precisão de 35,27% ao detectar a COVID-19. [Chen et al. \(2021\)](#) utilizaram uma arquitetura ResNet50 juntamente à técnica de *deep features* em três camadas conectadas realizando uma fusão entre 9 patches usados nos estudos, utilizando imagens originais sem etapas de pré-processamento. Como resultado, obtiveram a acurácia balanceada de 90,67%. Por melhor que sejam os resultados dos estudos citados acima, é preciso que melhorias sejam feitas para a maior eficácia. Uma ampla variedade de técnicas ainda podem ser aplicadas para a melhora do desempenho dos métodos mencionados, dessa forma, auxiliar no combate a pandemia de COVID-19 e avanços na área da medicina diagnóstica.

Tabela 1 – Trabalhos relacionados.

Trabalho	Técnica	Base de imagens	Acc(%)	F1(%)
(OZTURK et al., 2020)	DarkCovidNet	Covid Chest X-ray e ChestX-ray8	98,08	-
(HEMDAN; SHOUMAN; KARAR, 2020)	VGG19 e DenseNet201	Covid Chest X-ray e Chest X-Ray Images (Pneumonia)	90	91
(ZHANG et al., 2020b)	ResNet	Covid Chest X-ray e ChestX-ray8	96	-
(PEREIRA et al., 2020)	Inception-v3 e Descritores de textura	RYDLS-20	-	89
(ABBAS; ABDELSAMEA; GABER, 2021)	CNN + DeTraC	Covid Chest X-ray	93,1	-
(RAHIMZADEH; ATTAR, 2020)	Xception e ResNet50V2	Covid chest X-ray e Rsna pneumonia detection	99,50	-
(CHEN et al., 2021)	ResNet50	COVID-19 Chest X-ray, COVID-19 Image Data Collection	90,67	-

Os trabalhos apresentados neste capítulo são de extrema importância, pois apresentaram resultados muito significativos na classificação do COVID-19. A Tabela 1, que apresenta um resumo comparando os trabalhos mencionados, mostra as técnicas utilizadas, bases de imagens e as métricas de avaliação - acurácia (Acc) e *F1-score* (Seção 2.7) - que foram obtidas.

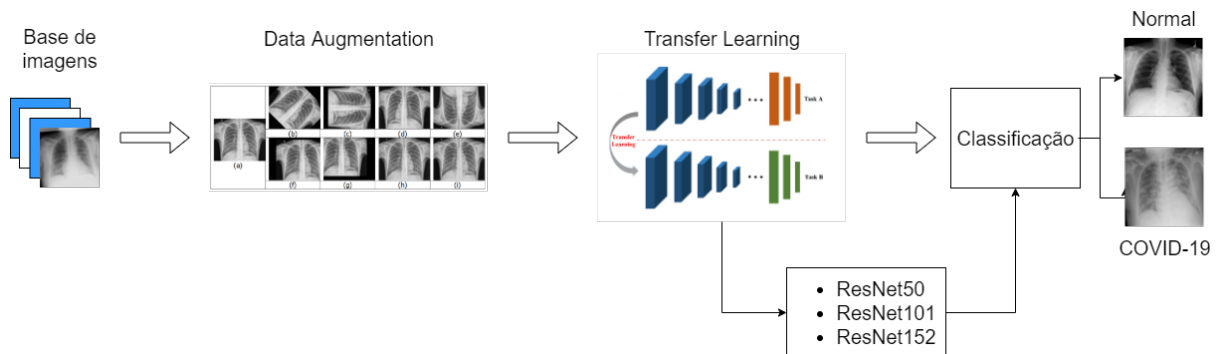
Como pode-se observar, os trabalhos relacionados utilizam técnicas de *Deep Learning* que são extremamente eficazes em sua tarefa de diagnóstico de COVID-19. Porém, mesmo com resultados promissores, algumas dessas abordagens foram extremamente custosas em termos de recursos computacionais e velocidade de treinamento, além de apresentarem alto nível de complexidade (como combinação entre redes diferentes), ou mesmo apresentaram outras métricas (como precisão e sensibilidade) não tão altas. O

presente trabalho busca apresentar um método simples, que utiliza redes residuais como sua grande base, que são redes consolidadas na comunidade de *Deep Learning* pela sua performance no treinamento (mesmo possuindo alto número de camadas) e também na classificação de imagens, juntamente a transferência de aprendizado e técnicas de *Data augmentation* para aumentar a variedade de dados utilizados no treinamento e validação.

4 Metodologia

Este capítulo apresenta a metodologia proposta para classificar os pacientes que apresentam condições de COVID-19 e condições saudáveis, em quatro etapas que estão detalhadas nas próximas seções. Na primeira etapa (Seção 4.1), são descritas as imagens utilizadas, adquiridas do conjunto de dados de Raios-x do tórax. Na segunda etapa (Seção 4.2), é descrito o processo de Pré-processamento, onde não houve a alteração na estrutura das imagens, mas sim o aumento na diversidade de dados disponíveis para o treinamento dos modelos. Na terceira etapa (Seção 4.3), é descrito o processo de Transfer Learning utilizado para reutilização de um modelo pré-treinado. Por fim, na quarta etapa (Seção 4.4), é apresentado um classificador totalmente treinado utilizado para realizar os experimentos. O diagrama do fluxo do conjunto de etapas aplicado neste estudo está sumarizado na Figura 9.

Figura 9 – Fluxograma da metodologia proposta.




4.1 Base de dados

A classificação de imagens de raio-x de tórax para diversos tipos de patologias foi bem estudada na literatura (KELES; KELES; KELES, 2021), e com o aumento exponencial do número de casos de COVID-19 no ano de 2020, várias bases de imagens foram disponibilizadas para análise e experimentos (RAHMAN et al., 2021). Para este trabalho, foi pesquisada uma base que contém várias amostras de pacientes normais, para que pudesse ser simulada a realidade clínica. Todos os experimentos neste estudo foram realizados em uma base de imagens pública, que contém uma coleção de diversas fontes, dentre elas a base de dados de COVID-19 da Sociedade Italiana de Radiologia Médica e Intervencionista (SIRM) e o conjunto de dados do novo Corona Vírus 2019 (COHEN; MORRISON; DAO, 2020), além de imagens extraídas de diversas outras publicações.


A base de imagens, inicialmente, consistia em 21.165 imagens, contendo outros tipos de patologia, como pneumonia viral e opacidade pulmonar. O presente trabalho considerou apenas 13.808 imagens, sendo destas 3.316 casos positivos exclusivamente de COVID-19 e 10.192 imagens de casos normais.

Neste estudo, os experimentos foram realizados com o objetivo de classificar as imagens em casos de COVID-19 e não COVID-19 (casos normais). A Figura 10 (a) exemplifica o casos de pacientes em condições normais, e a Figura 10 (b) mostra casos diagnosticados com COVID-19.

Figura 10 – Exemplos da base de imagens: (a) Casos de pacientes em condições normais. (b) Casos de pacientes diagnosticados com COVID-19.



(a) Casos Normais



(b) Casos diagnosticados com COVID-19

4.2 Pré-processamento

Neste trabalho, as imagens da base escolhida já estavam em condições aceitáveis e padronizadas de dimensão e escala de cores (escala de cinza), logo, não foi necessário alterar a estrutura das imagens. Porém, três importantes técnicas de *Image Augmentation* foram aplicadas para gerar novas instâncias para o treinamento nos experimentos realizados: Deslocamento (vertical e horizontal) da imagem, rotação e giro (horizontal). A operação de deslocamento utilizada foi feita deslocando a imagem em 10% de seu tamanho verticalmente e horizontalmente. A rotação foi realizada rotacionando as imagens em 10 graus, nas direções anti-horária e horária. O giro foi feito invertendo a imagem horizontalmente. A Figura 11 demonstra alguns exemplos das técnicas utilizadas mencionadas anteriormente.


Neste estudo, a base de dados inteira (i.e., 3.616 imagens em condições de COVID-

19 e 10.192 imagens em condições normais) foi utilizada, separando 70% para treino (i.e., 2.531 imagens em condições de COVID-19 e 7.134 imagens em condições normais), sendo 20% destas dedicadas a validação (i.e., 482 imagens em condições de COVID-19 e 1.451 imagens em condições normais), e 30% para teste (i.e., 1.085 imagens em condições de COVID-19 e 3.058 imagens em condições normais).

Figura 11 – Exemplos da base de imagens: (a) Imagem original. (b) Imagem com deslocamento. (c) Imagem com rotação. (d) Imagem invertida horizontalmente.



(a) Original



(b) Deslocamento horizontal



(c) Rotação em direção anti-horária



(d) Giro horizontal

4.3 Transfer learning

Nesta etapa, pretende-se, a partir de redes pré-treinadas (RAHMAN et al., 2021), obter um modelo eficiente na classificação de imagens como COVID-19 ou não COVID-19 (condições normais). A técnica de *Transfer learning* utilizada tem por objetivo reutilizar um modelo já treinado para uma tarefa em outra relacionada (BROWNLEE, 2017) (Seção 2.5). Para isso, foram realizados experimentos utilizando três redes (ResNet50, ResNet101, ResNet152), com pesos pré-treinados aplicados na base de imagens ImageNet (DENG et al., 2009), que é comumente utilizada na literatura. O processo de *Transfer learning* utilizado consiste em três partes:

- Seleção de modelo: nesta etapa, ocorre a escolha de um modelo pré-treinado para utilização nos experimentos. Foram escolhidas as redes *ResNet*, por apresentarem um excelente desempenho na literatura, além de coincidirem com o *input size* das imagens (299x299).

- Reuso de modelo: neste ponto, usa-se o modelo pré-treinado como ponto de partida para um modelo na nova tarefa designada.
- *Tuning*: neste ponto, ocorre a adaptação do modelo obtido até então, o modelo é reutilizado para um retreinamento após um descongelamento de suas camadas, para que pudesse ser completamente reajustado e então é feita uma análise de seu desempenho.

4.4 Classificação de diagnóstico utilizando redes residuais

A partir dos modelos obtidos através da técnica de *Transfer learning*, precisa-se classificar as imagens como condição de COVID-19 ou não COVID-19. Para isso, as redes escolhidas e retreinadas durante a etapa anterior (ResNet50, ResNet101, ResNet152) foram utilizadas para classificação. As redes residuais foram escolhidas por apresentarem uma excelente performance mesmo com um número alto de camadas (até 8 vezes maior que as redes VGG, mantendo um baixo grau de complexidade) (HE et al., 2016). Para avaliar o desempenho dos modelos, foram utilizadas. Então, é necessário validar e discutir os resultados obtidos através dos experimentos. Este processo é executado usando métricas comumente usadas em sistemas CAD/CADx. As métricas utilizadas foram: acurácia, precisão, *recall* e *F1-score* (Seção 2.7). A etapa de validação de resultados tem por objetivo levantar os pontos positivos e negativos da abordagem escolhida e também melhorias para possíveis trabalhos futuros.

5 Resultados

Neste capítulo, são apresentados e discutidos os resultados dos experimentos realizados pela abordagem proposta para a classificação de COVID-19 em imagens de Raio-x do tórax de pacientes. As etapas para a análise de resultados foram definidas da seguinte maneira: Configuração Experimental (Seção 5.1); Divisão e preparação da base (Seção 5.2); Treinamento das redes utilizando a técnica de *transfer learning* (Seção 5.3); Classificação das imagens (Seção 5.4) e Discussão dos resultados (Seção 5.5).

5.1 Configuração Experimental

O presente trabalho apresenta um método que utiliza a linguagem Python 3.7 para o desenvolvimento. A biblioteca de Deep Learning Keras (CHOLLET et al., 2015) foi utilizada e, como back-end, o TensorFlow-GPU que fornece uma interface para expressão de algoritmos de *Machine Learning* e sua implementação para executá-los em GPU (ABADI et al., 2015). Para tornar o trabalho independente de uma máquina física, foi utilizado o Google Colab (BISONG, 2019), que fornece um ambiente de desenvolvimento *serverless* do Jupyter notebook para desenvolvimento interativo. As especificações da máquina utilizada nos experimentos são: Placa de vídeo Nvidia K80 com 12 GB de memória de vídeo, 12 GB de memória RAM, com um espaço em disco disponibilizado de 358 GB para desenvolvimento.

5.2 Divisão e preparação da base

Conforme explicado na Seção 4.1, a base de imagens de radiografias de COVID-19 contém um total de 13.808 imagens de raios-x de tórax. Dessas imagens, 10.192 eram imagens rotuladas como Normal e 3.616 como COVID-19. Sendo assim, a base foi dividida aleatoriamente em 3 partes: treino, validação e teste com, respectivamente, 7.732, 1.933 e 4.143 imagens. A Tabela 2 apresenta a relação entre as imagens utilizadas no treinamento, validação e teste.

Tabela 2 – Relação entre imagens usadas para treinamento, validação e teste

Base	Normal	COVID-19	Total	Representação (%)
Treino	5.683	2.049	7.732	56%
Validação	1.451	482	1.933	14%
Teste	3.058	1.085	4.143	30%

Como mencionado na seção 4.2, para aumentar o número de amostras disponíveis, foi utilizada a técnica de *Image Augmentation* com diferentes rotações e deslocamentos nos eixos x e y.

5.3 Treinamento

De acordo com a Seção 4.3, as redes utilizadas para o treinamento foram as de arquitetura ResNet presentes na biblioteca Keras: ResNet50, ResNet101 e ResNet152. O treinamento de cada rede foi realizado em 2 etapas: 1) ajuste do topo e 2) ajuste da rede base.

5.3.1 Ajuste do Classificador

Nesta etapa do treinamento é inicializada uma instância de cada rede com os pesos pré treinados ImageNet. A camada de classificação de cada rede é retirada, uma nova com pesos aleatórios é adicionada manualmente e as camadas anteriores pré-treinadas são congeladas para que o treinamento seja realizado primeiramente apenas na nova camada de classificação.

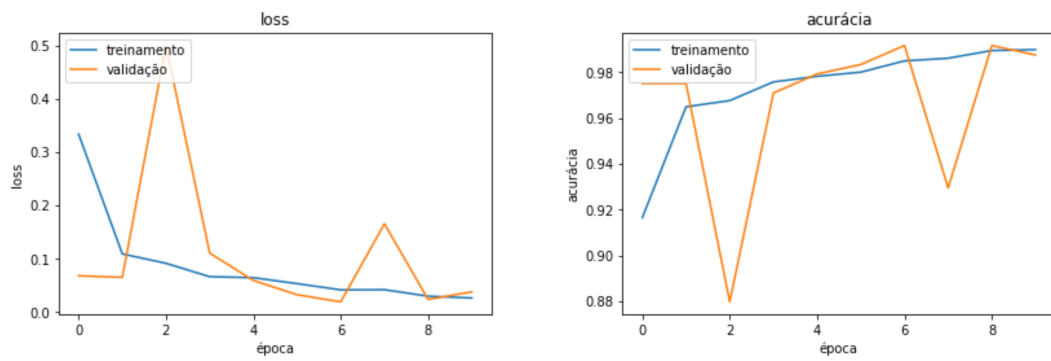
Após essa configuração inicial são apresentadas, em batches de tamanho 8, as imagens de raio-x do conjunto de treinamento para as redes durante 5 épocas. Em seguida as redes são apresentadas ao conjunto de imagens de validação para se avaliar o desempenho de classificação com os pesos pré-treinados. A Tabela 3 apresenta os resultados obtidos com as redes utilizadas.

Tabela 3 – Classificação utilizando apenas o topo ajustado


Rede	Acurácia	Precisão	Sensibilidade	F1-Score
ResNet50	90%	91%	82%	85%
ResNet101	89%	91%	80,5%	84%
ResNet152	91%	90%	87%	88%

5.3.2 Ajuste da Rede Base (tunning)

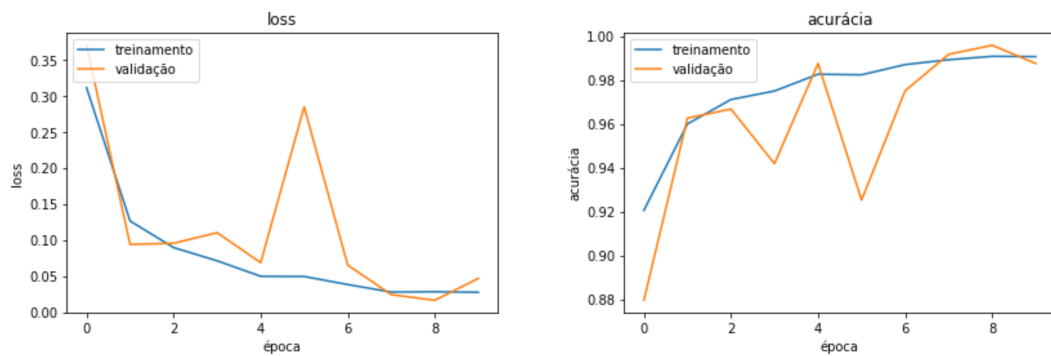
Com o topo da rede ajustado, as camadas restantes da rede são descongeladas para que possam aprender as características do conjunto de imagens de tomografia computadorizada. Após o descongelamento das camadas, são apresentadas para as redes as imagens do conjunto de treinamento em batches de tamanho 8 durante 10 épocas. A Figura 12 apresenta a evolução da *loss* e da acurácia das redes ResNet50, ResNet101 e ResNet152.



(a) ResNet50



(b) ResNet101



(c) ResNet152

Figura 12 – Evolução da acurácia e *loss* durante o ajuste da rede base.

5.4 Classificação

Nesta etapa, são apresentadas as imagens do conjunto de imagens de teste para as redes ResNet50, ResNet101 e ResNet152 a fim de que elas realizem a predição para o conjunto e a partir disso sejam avaliadas as métricas de desempenho (Seção 2.7) das redes. Após a predição das imagens do conjunto de teste, foi aplicado um limiar de 0,5 sobre o

vetor de predições de cada rede, transformando em 0 todos os valores abaixo do limiar e em 1 caso contrário.

As métricas utilizadas para avaliar o desempenho de classificação das redes foram: acurácia, precisão, sensibilidade e *F1-score*. A Tabela 4 apresenta as métricas de classificação obtidas pelas redes.

Tabela 4 – Classificação utilizando as redes completamente ajustadas

Classe	Acurácia	Precisão	Sensibilidade	F1-Score
ResNet50	99%	98,5%	98%	98%
ResNet101	98%	98%	96%	96,5%
ResNet152	98%	98%	98,5%	98%

5.5 Discussão dos resultados

A pandemia causada pelo COVID-19 levou muitos cientistas e pesquisadores a procurarem novos métodos de auxílio ao diagnóstico e tratamento da doença. Muitos dos métodos de diagnóstico foram desenvolvidos utilizando reconhecimento de padrões nas imagens de raios-X do tórax. Uma comparação desses trabalhos com o desenvolvido nesta pesquisa é apresentada na tabela 5.

Tabela 5 – Comparação com trabalhos relacionados.

Trabalho	Técnica	Acc(%)	Pre(%)	Sen(%)	F1(%)
(OZTURK et al., 2020)	DarkCovidNet	98	-	-	-
(HEMDAN; SHOUMAN; KARAR, 2020)	VGG19 e DenseNet201	90	-	-	91
(ZHANG et al., 2020b)	ResNet	96	-	-	-
(PEREIRA et al., 2020)	Inception-v3 e Descritores de textura	-	-	-	89
(ABBAS; ABDELSAMEA; GABER, 2021)	CNN + DeTraC	93,1	-	-	-
(RAHIMZADEH; ATTAR, 2020)	Xception e ResNet50V2	99,5	35,3	80,5	-
(CHEN et al., 2021)	ResNet50	90,7	-	-	-
MÉTODO PROPOSTO	ResNet50	99	98,5	98	98
	ResNet101	98	98	96	96,5
	ResNet152	98	98	98,5	98

Pode-se observar que muitos dos métodos comparados também utilizaram Deep Learning, já que consistem em métodos consolidados e extremamente promissores, como se pode ver em [Ozturk et al. \(2020\)](#) e [Zhang et al. \(2020b\)](#) que superaram os 95% de acurácia utilizando modelos baseados em redes convolucionais. [Hemdan, Shouman e Karar \(2020\)](#) utilizando uma rede VGG e uma DenseNet conseguiu atingir os 91% de *F1-score*, o que já pode ser considerado um valor expressivo. Os ditos trabalhos exploraram as redes neurais, trazendo abordagens significativas para o diagnóstico de COVID-19 por meio da análise de imagens de raios-X, porém esses resultados ainda não foram tão expressivos como os da abordagem apresentada neste trabalho. O método proposto por [Rahimzadeh e Attar \(2020\)](#) conseguiu atingir impressionantes 99,5% de acurácia com sua abordagem baseada em redes Xception e ResNet50V2. Porém sua sensibilidade permaneceu estagnada em 80% e sua precisão em 35,27% para detecção de COVID-19 (31 casos de COVID-19). Isso porque seu método era mais focado na classificação de pacientes normais/pneumonia (4.420 casos de pneumonia e 6.851 casos normais, tornando desbalanceada a base para a detecção de COVID-19), o que não é o foco deste trabalho.

Embora todos os resultados anteriores apresentassem significativas e promissoras métricas de desempenho, o presente trabalho, utilizando bases semelhantes, conseguiu manter-se estável e com alto nível de desempenho alcançando 99% de acurácia com a ResNet50 e 98,5% de sensibilidade com a ResNet152. A ResNet101, mesmo sendo a menos promissora entre as 3, ainda conseguiu ser melhor ou pelo menos se equiparar à maioria dos demais resultados apresentados, perdendo apenas para a acurácia do trabalho do [Rahimzadeh e Attar \(2020\)](#), porém ainda possuindo uma sensibilidade e uma precisão muito superior.

6 Conclusão

A pandemia causada pelo COVID-19 resultou em impactos que se estendem pelo mundo todo. Portanto, vários métodos foram propostos para auxiliar os profissionais da área da saúde. Este trabalho propôs um método completamente automatizado e eficiente, utilizando redes neurais residuais e *transfer learning* para a classificação de imagens de raios-x de tórax como em condições de COVID-19 ou saudáveis.

Embora o COVID-19 seja um problema relativamente novo, muitos trabalhos já foram realizados a respeito, sendo necessária a utilização de bases de dados públicas para a execução do método proposto. Assim, este estudo utilizou o conjunto de imagens de raios-x do tórax, que contempla uma variedade de fontes e patologias, entretanto, apenas as condições normais e COVID-19 foram exploradas neste presente trabalho.

Para aumentar a quantidade de instâncias no conjunto de dados utilizados, uma etapa de *image augmentation* foi realizada, gerando assim, novas imagens em configurações diferentes de rotação e deslocamento ao longo dos eixos x e y, como bem explicado nas seções 4.1 e 4.2.

Em seguida, foi realizada a técnica de *transfer learning* para reaproveitar os pesos de uma rede pré-treinada, juntamente à técnica *Fine tuning* para ajuste das diversas camadas das redes. Foram utilizadas as redes residuais (ResNet50, ResNet101 e ResNet152) para classificação das imagens, visto que as mesmas já apresentavam ótima performance em trabalhos semelhantes (HE et al., 2016) e neste trabalho todas as redes residuais estudadas e testadas apresentaram no final resultados muito promissores. A ResNet50, após os processos acima citados, conseguiu alcançar 99% de acurácia, uma precisão média de 98,5%, sensibilidade média de 98% e *F1-score* médio de 98%. Logo, percebe-se que os resultados obtidos são bem promissores, assim como o método, que já é validado e capaz de classificar com eficiência pacientes acometidos pelo COVID-19.

Como direção de pesquisa futura, destaca-se o uso de outras arquiteturas ou o desenvolvimento de novas para o problema específico. O método não propôs uma nova abordagem para o ajuste da rede pré-treinada, apenas utilizou abordagens já existentes, como o reajuste total da rede. Acredita-se que outras abordagens semelhantes possam ser ainda mais eficazes, e que outros tipos de redes possam obter resultados promissores, como os das redes residuais experimentadas neste trabalho.

Além disso, o método proposto identifica se imagens de raios-x apresentam condições de COVID-19 ou não. Adicionar uma etapa de segmentação para identificar as regiões afetadas poderia ajudar bastante os profissionais da saúde. Outro possível ponto de melhora é estender o método para também classificar as imagens em outros tipos de patologias

com o envolvimento pulmonar, como opacidade pulmonar e pneumonia, por exemplo. Acredita-se que essas mudanças possam agregar ainda mais valor ao método proposto.

Referências

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANÉ, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIÉGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>. Citado na página 35.
- ABBAS, A.; ABDELSAMEA, M. M.; GABER, M. M. Classification of covid-19 in chest x-ray images using detrac deep convolutional neural network. *Applied Intelligence*, Springer, v. 51, n. 2, p. 854–864, 2021. Citado 3 vezes nas páginas 28, 29 e 38.
- AQUINO, E. M.; SILVEIRA, I. H.; PESCARINI, J. M.; AQUINO, R.; SOUZA-FILHO, J. A. d.; ROCHA, A. d. S.; FERREIRA, A.; VICTOR, A.; TEIXEIRA, C.; MACHADO, D. B. et al. Medidas de distanciamento social no controle da pandemia de covid-19: potenciais impactos e desafios no brasil. *Ciência & Saúde Coletiva*, SciELO Public Health, v. 25, p. 2423–2446, 2020. Citado na página 14.
- BEECHING, N.; FLETCHER, T.; ROBERT, F.; PETRI, W.; ZHANG, X.; NIR-PAZ, R. *BMJ Best Pract*, 2020. Disponível em: <<https://bestpractice.bmj.com/topics/en-gb/3000201>>. Citado na página 18.
- BISONG, E. Google colaboyatory. In: _____. [S.l.: s.n.], 2019. p. 59–64. ISBN 978-1-4842-4469-2. Citado na página 35.
- BOCCIA, S.; RICCIARDI, W.; IOANNIDIS, J. P. What other countries can learn from italy during the covid-19 pandemic. *JAMA internal medicine*, American Medical Association, v. 180, n. 7, p. 927–928, 2020. Citado na página 14.
- BROWNLEE, J. *A Gentle Introduction to Transfer Learning for Deep Learning*. 2017. Disponível em: <<https://machinelearningmastery.com/transfer-learning-for-deep-learning/>>. Citado na página 33.
- CHEN, T. D.; OLIVEIRA, G. B. de; DIAS, Z.; TÉCNICO-IC-PFG, R.; GRADUAÇÃO, P. F. de. Diagnóstico de covid-19 usando redes neurais profundas. 2021. Citado 2 vezes nas páginas 29 e 38.
- CHOLLET, F. et al. *Keras*. GitHub, 2015. Disponível em: <<https://github.com/fchollet/keras>>. Citado na página 35.
- CLARO, M.; VOGADO, L.; SANTOS, J.; VERAS, R. Utilização de técnicas de data augmentation em imagens: Teoria e prática. *Sociedade Brasileira de Computação*, 2020. Citado 2 vezes nas páginas 24 e 25.

COHEN, J. P.; MORRISON, P.; DAO, L. Covid-19 image data collection. *arXiv 2003.11597*, 2020. Disponível em: <<https://github.com/ieee8023/covid-chestxray-dataset>>. Citado na página 31.

COLLINS, J.; STERN, E. *Chest Radiology: The Essentials*. Wolters Kluwer Health/Lippincott Williams & Wilkins, 2008. (LWW Doody's all reviewed collection). ISBN 9780781763141. Disponível em: <<https://books.google.com.br/books?id=RZBT7KGMEb4C>>. Citado na página 18.

DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2009. p. 248–255. Citado na página 33.

DOI, K. Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Computerized Medical Imaging and Graphics*, v. 31, n. 4, p. 198–211, 2007. ISSN 0895-6111. Computer-aided Diagnosis (CAD) and Image-guided Decision Support. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0895611107000262>>. Citado na página 15.

DOREMALEN, N. V.; BUSHMAKER, T.; MORRIS, D. H.; HOLBROOK, M. G.; GAMBLE, A.; WILLIAMSON, B. N.; TAMIN, A.; HARCOURT, J. L.; THORNBURG, N. J.; GERBER, S. I. et al. Aerosol and surface stability of sars-cov-2 as compared with sars-cov-1. *New England journal of medicine*, Mass Medical Soc, v. 382, n. 16, p. 1564–1567, 2020. Citado na página 14.

DUDA, R.; HART, P. *Pattern Classification and Scene Analysis*. Wiley, 1973. ISBN 9780471223610. Disponível em: <<https://books.google.com.br/books?id=POMGRAAAACAAJ>>. Citado na página 26.

FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006. ISSN 0167-8655. ROC Analysis in Pattern Recognition. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016786550500303X>>. Citado na página 26.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning (adaptive computation and machine learning series). *Cambridge Massachusetts*, p. 321–359, 2017. Citado na página 23.

HART, P. E.; STORK, D. G.; DUDA, R. O. *Pattern classification*. [S.l.]: Wiley Hoboken, 2000. Citado na página 20.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. *arXiv preprint arXiv:1512.03385*, 2015. Citado 4 vezes nas páginas 21, 22, 23 e 24.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun 2016. Disponível em: <<http://dx.doi.org/10.1109/cvpr.2016.90>>. Citado 4 vezes nas páginas 21, 22, 34 e 40.

HEMDAN, E. E.-D.; SHOUMAN, M. A.; KARAR, M. E. Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. *arXiv preprint arXiv:2003.11055*, 2020. Citado 5 vezes nas páginas 14, 28, 29, 38 e 39.

- INFO, R. *X-ray (Radiography) - Chest*. 2020. Acessado em 22 de Outubro de 2020. Disponível em: <<https://www.radiologyinfo.org/en/info.cfm?pg=chestrad>>. Citado na página 19.
- JIANG, F. e. a. Review of the clinical characteristics of coronavirus disease 2019 (covid-19). *Journal of general internal medicine*, 2020. Citado 2 vezes nas páginas 17 e 18.
- KELES, A.; KELES, M. B.; KELES, A. Cov19-cnnet and cov19-resnet: Diagnostic inference engines for early detection of covid-19. *Cognitive Computation*, Jan 2021. ISSN 1866-9964. Disponível em: <<https://doi.org/10.1007/s12559-020-09795-5>>. Citado na página 31.
- KIM, Y.-I.; KIM, S.-G.; KIM, S.-M.; KIM, E.-H.; PARK, S.-J.; YU, K.-M.; CHANG, J.-H.; KIM, E. J.; LEE, S.; CASEL, M. A. B. et al. Infection and rapid transmission of sars-cov-2 in ferrets. *Cell host & microbe*, Elsevier, v. 27, n. 5, p. 704-709, 2020. Citado na página 17.
- LI, X.; LUK, H. K.; LAU, S. K.; WOO, P. C. Human coronaviruses: General features. In: *Reference Module in Biomedical Sciences*. Elsevier, 2019. ISBN 978-0-12-801238-3. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128012383957040>>. Citado na página 17.
- LOONEY, C. G. *Pattern recognition using neural networks: theory and algorithms for engineers and scientists*. [S.l.]: Oxford University Press, Inc., 1997. Citado na página 20.
- MAHASE, E. *Coronavirus: covid-19 has killed more people than SARS and MERS combined, despite lower case fatality rate*. [S.l.]: British Medical Journal Publishing Group, 2020. Citado na página 14.
- NGUYEN, L. D.; LIN, D.; LIN, Z.; CAO, J. Deep cnns for microscopic image classification by exploiting transfer learning and feature concatenation. In: *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*. [S.l.: s.n.], 2018. p. 1-5. Citado na página 21.
- ORGANIZATION, W. H. *Unity Studies: Early Investigation Protocols*. World Health Organization, 2020. Disponível em: <<https://www.who.int/emergencies/diseases/novel-coronavirus-2019/technical-guidance/early-investigations>>. Citado na página 14.
- OZTURK, T.; TALO, M.; YILDIRIM, E. A.; BALOGLU, U. B.; YILDIRIM, O.; ACHARYA, U. R. Automated detection of covid-19 cases using deep neural networks with x-ray images. *Computers in biology and medicine*, Elsevier, v. 121, p. 103792, 2020. Citado 4 vezes nas páginas 28, 29, 38 e 39.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de imagens digitais: princípios, algoritmos e aplicações*. [S.l.]: Cengage Learning, 2008. Citado na página 21.
- PEREIRA, R. M.; BERTOLINI, D.; TEIXEIRA, L. O.; JR, C. N. S.; COSTA, Y. M. Covid-19 identification in chest x-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 194, p. 105532, 2020. Citado 3 vezes nas páginas 28, 29 e 38.
- PFENNINGER, J.; FOWLER, G. *Pfenninger and Fowler's Procedures for Primary Care E-Book: Expert Consult*. Elsevier Health Sciences, 2010. ISBN 9781455700929. Disponível em: <<https://books.google.com.br/books?id=loI3ZhC4UN4C>>. Citado na página 19.

- RAHIMZADEH, M.; ATTAR, A. A modified deep convolutional neural network for detecting covid-19 and pneumonia from chest x-ray images based on the concatenation of inception and resnet50v2. *Informatics in Medicine Unlocked*, Elsevier, v. 19, p. 100360, 2020. Citado 4 vezes nas páginas 28, 29, 38 e 39.
- RAHMAN, T.; KHANDAKAR, A.; QIBLAWEY, Y.; TAHIR, A.; KIRANYAZ, S.; Abul Kashem, S. B.; ISLAM, M. T.; Al Maadeed, S.; ZUGHAIER, S. M.; KHAN, M. S.; CHOWDHURY, M. E. 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. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001048252100113X>>. Citado 2 vezes nas páginas 31 e 33.
- RIZWAN, M. *Residual Networks (ResNets)*. [S.l.]: engMRK, 2018. Citado na página 22.
- ROSA, G. L.; BONADONNA, L.; LUCENTINI, L.; KENMOE, S.; SUFFREDINI, E. Coronavirus in water environments: Occurrence, persistence and concentration methods-a scoping review. *Water research*, Elsevier, v. 179, p. 115899, 2020. Citado 2 vezes nas páginas 17 e 18.
- ROTHAN, H. A.; BYRAREDDY, S. N. The epidemiology and pathogenesis of coronavirus disease (covid-19) outbreak. *Journal of autoimmunity*, Elsevier, v. 109, p. 102433, 2020. Citado na página 14.
- SAÚDE, M. da. *Sobre a doença COVID-19*. 2020. 02.11.2021. Disponível em: <[Https://coronavirus.saude.gov.br/sobre-a-doenca](https://coronavirus.saude.gov.br/sobre-a-doenca)>. Citado na página 18.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of Big Data*, Springer, v. 6, n. 1, p. 1–48, 2019. Citado 2 vezes nas páginas 24 e 25.
- SINGHAL, T. A review of coronavirus disease-2019 (covid-19). *The indian journal of pediatrics*, Springer, v. 87, n. 4, p. 281–286, 2020. Citado na página 18.
- SOARES, F.; LOPES, H. *Equipamento Radiográfico e Processamento de Filme*. Bookman Editora, 2015. (Tekne). ISBN 9788582603543. Disponível em: <<https://books.google.com.br/books?id=SFhICgAAQBAJ>>. Citado 2 vezes nas páginas 19 e 20.
- SUN, D.; LI, H.; LU, X.-X.; XIAO, H.; REN, J.; ZHANG, F.-R.; LIU, Z.-S. Clinical features of severe pediatric patients with coronavirus disease 2019 in wuhan: a single center's observational study. *World Journal of Pediatrics*, Nature Publishing Group, p. 1, 2020. Citado na página 18.
- SZEGEDY, C.; IOFFE, S.; VANHOUCKE, V.; ALEMI, A. A. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *Thirty-first AAAI conference on artificial intelligence*. [S.l.: s.n.], 2017. Citado na página 21.
- TAYLOR, L.; NITSCHKE, G. Improving deep learning with generic data augmentation. In: IEEE. *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*. [S.l.], 2018. p. 1542–1547. Citado na página 24.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern recognition, edition*. [S.l.]: Academic Press, fourth edition Edition, 2009. Citado na página 20.

TORREY, L.; SHAVLIK, J. Transfer learning. In: *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*. [S.l.]: IGI global, 2010. p. 242–264. Citado na página 23.

VINOD, D. N.; JEYAVADHANAM, B. R.; ZUNGERU, A. M.; PRABAHARAN, S. Fully automated unified prognosis of covid-19 chest x-ray/ct scan images using deep covix-net model. *Computers in Biology and Medicine*, v. 136, p. 104729, 2021. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482521005230>>. Citado na página 22.

WANG, W.; XU, Y.; GAO, R.; LU, R.; HAN, K.; WU, G.; TAN, W. Detection of sars-cov-2 in different types of clinical specimens. *Jama*, American Medical Association, v. 323, n. 18, p. 1843–1844, 2020. Citado na página 14.

ZHANG, H.-W.; YU, J.; XU, H.-J.; LEI, Y.; PU, Z.-H.; DAI, W.-C.; LIN, F.; WANG, Y.-L.; WU, X.-L.; LIU, L.-H. et al. Corona virus international public health emergencies: implications for radiology management. *Academic radiology*, Elsevier, v. 27, n. 4, p. 463–467, 2020. Citado na página 14.

ZHANG, J.; XIE, Y.; LI, Y.; SHEN, C.; XIA, Y. Covid-19 screening on chest x-ray images using deep learning based anomaly detection. *arXiv preprint arXiv:2003.12338*, v. 27, 2020. Citado 4 vezes nas páginas 28, 29, 38 e 39.

ZHOU, F.; YU, T.; DU, R.; FAN, G.; LIU, Y.; LIU, Z.; XIANG, J.; WANG, Y.; SONG, B.; GU, X. et al. Clinical course and risk factors for mortality of adult inpatients with covid-19 in wuhan, china: a retrospective cohort study. *The lancet*, Elsevier, v. 395, n. 10229, p. 1054–1062, 2020. Citado na página 14.