

**UNIVERSIDADE DO VALE DO RIO DOS SINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

GIORDANO BRUNNO WAGNER TROMBETTA

**DETECÇÃO AUTOMÁTICA DE CASOS DE PNEUMONIA POR COVID-19 A
PARTIR DE IMAGENS DE RAIOS X DO TÓRAX E ABORDAGENS DE DEEP
LEARNING**

São Leopoldo
2020

GIORDANO BRUNNO WAGNER TROMBETTA

**DETECÇÃO AUTOMÁTICA DE CASOS DE PNEUMONIA POR COVID-19 A
PARTIR DE IMAGENS DE RAIOS X DO TÓRAX E ABORDAGENS DE DEEP
LEARNING**

Artigo apresentado como requisito parcial para
obtenção do título de Bacharel em Ciência da
Computação, pelo Curso de Ciência da Compu-
tação da Universidade do Vale do Rio dos Sinos
(UNISINOS)

Orientador(a): Prof. Dr Sandro José Rigo

São Leopoldo
2020

DETECÇÃO AUTOMÁTICA DE CASOS DE PNEUMONIA POR COVID-19 A PARTIR DE IMAGENS DE RAIOS X DO TÓRAX E ABORDAGENS DE DEEP LEARNING

Giordano Brunno Wagner Trombetta¹

Sandro José Rigo²

Resumo: A Covid-19 apresenta alta taxa de transmissão e contágio, sendo que a identificação precoce de novos casos auxilia a evitar a transmissão do vírus. Isso se torna um desafio, pois os testes aplicados geralmente são feitos de forma manual e demorada. Em estudos iniciais foram encontrados casos de pacientes que apresentam anormalidades nas radiografias de tórax indicando a ocorrência desta doença. Com o estudo dessas imagens existe a possibilidade de criar modelos com recursos de aprendizagem de máquina para identificar automaticamente casos de COVID-19. Neste estudo são realizadas experimentações com arquiteturas de redes neurais convolucionais para identificar e avaliar um modelo de detecção de casos de COVID-19 com alta precisão de maneira rápida e automática. Através das experimentações realizadas é possível afirmar que o diagnóstico por imagem de casos de síndrome respiratória aguda grave com base em exames de raio X é possível, tendo sido observados resultados nos quais o modelo atinge 96% de acurácia ao analisar raio X torácico com três possíveis diagnósticos nos experimentos realizados. O diferencial deste trabalho em relação à literatura é a identificação de múltiplas categorias no diagnóstico, o que não é observado nos trabalhos estudados.

Palavras-chave: COVID-19. Redes Neurais Convolucionais. Deep Learning. Machine Learning

Abstract: Covid-19 has a high rate of transmission and contagion, and the early identification of new cases helps to prevent the transmission of the virus. This becomes a challenge, as the tests applied are usually done manually and take time. Initial studies have found cases of patients who have abnormalities on chest X-rays indicating the occurrence of this disease. With the study of these images, it is possible to create models with machine learning resources to automatically identify cases of COVID-19. In this study, experiments are carried out with convolutional neural network architectures to identify and evaluate a model of COVID-19 case detection with high precision in a fast and automatic way. Through the experiments carried out it is possible to affirm that the diagnosis by image of cases of severe acute respiratory syndrome based on X-ray exams is possible, having been observed results in which the model reaches 96 % accuracy when analyzing chest X-ray with three possible diagnoses in the experiments performed. The differential of this work in relation to the literature is the identification of multiple categories in the diagnosis, which is not observed in the studies studied.

Keywords: COVID-19. Convolutional Neural Networks. Deep Learning. Machine Learning

¹Graduando em de Ciência da Computação pela Unisinos. Email: giordano.trombetta@gmail.com

²Orientador, professor da Unisinos. Email: rigo@unisinos.br

1 INTRODUÇÃO

Em dezembro de 2019, foi extraído de amostras de vias aéreas inferiores de vários pacientes em Wuhan, China, um novo tipo de coronavírus chamado COVID-19. Esses pacientes apresentaram sintomas de pneumonia grave, incluindo febre, fadiga, tosse seca e dificuldade respiratória. Acredita-se que tenha se originado em um mercado de frutos do mar em Wuhan. A disseminação deste vírus gerou um contexto que foi classificado como pandemia pela Organização Mundial da Saúde (OMS). O período de incubação é estimado em 5.2 dias, o que permitiu viajantes por transporte aéreo espalharem a doença globalmente. As evidências mostram que a transmissão do vírus pode ocorrer durante o período de incubação em pacientes assintomáticos. (KOORAKI et al., 2020). O vírus é capaz de ser transmitido de pessoa a pessoa por gotículas originárias de nariz e boca de pacientes infectados ou por contato com superfícies contaminadas (NETTO; CORRÊA, 2020).

Até a escrita deste texto, mais de 6 milhões de casos confirmados de COVID-19 foram identificados em todo o mundo e vários relatos de casos indicaram que o COVID-19 tem potencial para ser transmitido antes do início da doença (SLIFKA; MESSER; AMANNA, 2020). Estudos também mostraram que o vírus infeccioso pode ser encontrado em casos de COVID-19 pré-sintomáticos (ARONS et al.,) e, embora não se saiba qual o nível de vírus infeccioso necessário para executar uma transmissão eficiente, a detecção de vírus infeccioso extraído de amostras de vias aéreas superiores indica que a transmissão pré-sintomática do COVID-19 é possível.

Em resposta ao crescimento da transmissão, muitos líderes municipais, estaduais e federais solicitaram o aumento de testes de Reação em Cadeia da Polimerase com Transcrição Reversa em tempo real que verifica a presença de material genético do vírus RT-PCR (*Reverse Transcription - Polymerase Chain Reaction*) e ensaios sorológicos para identificar casos assintomáticos e potenciais espalhadores (SLIFKA; MESSER; AMANNA, 2020).

No Brasil as recomendações atuais do Ministério da Saúde para testagem incluem apenas pessoas com sintomas graves da doença. A quantidade disponível de testes atualmente é insuficiente para a população brasileira. Há relatos de pacientes que receberam o diagnóstico após sete dias. No estado do Rio de Janeiro, por exemplo, a cada 100 pacientes, apenas 14 são identificados (NETTO; CORRÊA, 2020).

1.1 Motivação e Justificativa

O principal método para identificar casos de COVID-19 é o teste de Reação em Cadeia da Polimerase com Transcrição Reversa em tempo real (RT-PCR), que pode detectar o RNA SARS-CoV-2 das vias respiratórias que foram obtidas como amostras. Embora o teste de RT-PCR seja o recomendado, pois é altamente específico, o teste é feito em um processo manual, demorado, trabalhoso e complicado (WANG; WONG, 2020). Além disso, a limitação exis-

tente de testes para serem aplicados na população em alguns países, como no Brasil, faz com que eleve a importância de utilizar métodos auxiliares para conseguir identificar casos positivos de COVID-19. Uma maneira alternativa de identificação do COVID-19 é o exame de radiografia, onde as imagens de radiografia de tórax (por exemplo, radiografia de tórax (CXR) ou tomografia computadorizada (TC)) são realizadas e analisadas por radiologistas para procurar indicadores visuais associados à infecção viral por SARS-CoV-2 (ZHONG, 2020). Em estudos iniciais foram encontrados casos de pacientes que apresentam anormalidades nas radiografias de tórax, características das pessoas infectadas com COVID-19, sugerindo que o exame radiográfico poderia ser usado como uma ferramenta primária para o rastreamento do COVID-19 em áreas epidêmicas (AI et al., 2020). Porém a detecção de pneumonia nas radiografias de tórax é uma tarefa desafiadora para ser feita por humanos, depende da disponibilidade de radiologistas especializados, é feita de forma manual e demorada. Neste ponto nasce o incentivo para o trabalho em questão, que busca apresentar um modelo para detectar automaticamente pneumonia por COVID-19 a partir de radiografias de tórax, que é uma tarefa simples para o modelo, que consegue detectar automaticamente com um alto percentual de precisão. É uma ferramenta que pode ser utilizada ao lado de testes mais conclusivos de forma complementar.

1.2 Objetivos

Aprendizado de máquina já vem sendo usado como recurso de identificação de doenças e de cuidados da saúde como uma ferramenta complementar para auxiliar inúmeros desafios encontrados no dia a dia da saúde. O aprimoramento de técnicas de *deep learning* e o grande volume de informações existentes para serem trabalhadas, auxiliaram algoritmos a superarem em determinadas tarefas específicas de imagens a eficiência de equipes médicas, tarefas como a identificação de pneumonia (RAJPURKAR et al., 2017), da classificação de câncer de pele (ESTEVA et al., 2017), identificação de hemorragia (GREWAL et al., 2018) e detecção de arritmia (PRANAV et al., 2017). Os diagnósticos automatizados que são possibilitados de serem executados por imagens extraídas de exames de pacientes, trazem experimentações interessantes que podem ser feitas.

O objetivo deste trabalho é de avaliar arquiteturas de redes neurais convolucionais, através de experimentações para obter um modelo preditivo de alta precisão, que consiga identificar automaticamente, a partir de radiografias do tórax, se uma pessoa apresenta efeitos da COVID-19 evidentes nos pulmões.

1.3 Metodologia

O presente trabalho busca avaliar a possibilidade da utilização de arquiteturas de redes neurais convolucionais para obter um modelo preditivo de alta precisão na identificação da presença de COVID-19 em imagens de radiografia de pacientes, busca também realizar uma comparação

dos resultados obtidos dadas as experimentações realizadas. Para atingir o objetivo do trabalho, inicialmente foi realizada uma revisão bibliográfica geral sobre redes neurais convolucionais e sua aplicabilidade em imagens de radiografia, no âmbito da saúde. Esse estudo foi de extrema importância para auxiliar na delimitação do escopo do trabalho. Também foi feita uma análise mais detalhada de uma série de estudos e artigos que serviram como base fundamental para a definição da proposta apresentada no mesmo.

A execução deste trabalho foi guiada utilizando o seguinte método: a) revisão bibliográfica; b) estudo de conceitos relacionados a imagem de radiografias, pneumonia viral e redes convolucionais; c) delimitação de técnicas utilizadas para experimentações; d) estudo e análise de trabalhos relacionados no assunto que tange o presente artigo; e) definição da arquitetura; f) implementação; g) avaliação dos resultados.

1.4 Estrutura do texto

Este trabalho está estruturado da seguinte maneira: a próxima seção aborda uma breve fundamentação teórica dos conceitos utilizados como base neste trabalho (seção 2). A seção seguinte apresenta uma revisão e discussão dos trabalhos relacionados mais significativos para a pesquisa atual. Na seção 4 é descrita a abordagem proposta, seguida dos resultados do estudo (seção 5) e posteriormente temos a seção contendo as conclusões obtidas com o estudo realizado.

2 FUNDAMENTAÇÃO TEÓRICA


Nesta seção serão apresentados os principais conceitos abordados neste trabalho. Inicialmente será descrita a possibilidade de identificar casos de COVID-19 utilizando imagens de raio X do tórax de pacientes. Na sequência falamos sobre aprendizado de máquina, *deep learning* e redes neurais convolucionais, que são a base do estudo do presente trabalho. Por fim, é abordado o tema referente à arquitetura VGG-19 que tem sua principal aplicabilidade no contexto de reconhecimentos de padrões em imagens possuindo um modelo pré-treinado.

2.1 Identificação da COVID-19 a partir de imagens radiografia

Exames de radiografia vêm sendo utilizados como um método alternativo de identificação de COVID-19. As imagens do tórax são realizadas e analisadas por radiologistas para encontrar indicadores visuais associados à infecção viral por SARS-Cov-2 que é o vírus causador do COVID-19.

Foram feitos estudos iniciais em pacientes que apresentaram anormalidades nas imagens de radiografia de tórax, com características das pessoas infectadas com COVID-19. Alguns estudos sugerem que o exame radiográfico poderia ser usado como uma ferramenta primária para a identificação de casos de COVID-19 em áreas epidêmicas (WANG; WONG, 2020).

Figura 1 – Exemplo de imagem de Raio x do tórax de: (A) infecção não-COVID19 e (B) infecção viral por COVID-19.



Fonte: WANG; WONG,(2020)

Imagens de raio X do tórax são frequentemente utilizadas como parte do procedimento padrão para pacientes com queixas respiratórias (NAIR et al., 2020). Indica-se que à medida que ocorra o avanço do COVID-19, existirá uma dependência maior por radiografia torácica portátil devido às vantagens mencionadas (JACOBI et al., 2020).

2.2 Aprendizado de máquina

Como Arthur Samuel definiu (SAMUEL, 1959), aprendizado de máquina é o “campo de estudo que dá aos computadores a habilidade de aprender sem serem explicitamente programados”. Na busca de conhecimento, o aprendizado de máquina é mais comumente usado para significar a aplicação de indução de algoritmos, que é uma etapa do processo de descoberta de conhecimento (PROVOST; KOHAVI, 1998).

A indução é o processo de criação de um modelo geral, a partir de um conjunto de dados. A indução pode ser associada com a dedução, contudo a indução assume uma coleção de fatos e cria uma regra ou um modelo geral (FAWCETT; PROVOST, 2018). O aprendizado indutivo é efetuado a partir de raciocínio sobre exemplos fornecidos por um processo externo ao sistema de aprendizado (MONARD; BARANAUSKAS, 2003).

O processo de aprendizado indutivo pode ser dividido em duas partes: o processo de aprendizado supervisionado e o processo não-supervisionado. No processo de aprendizado supervisionado é fornecido ao indutor um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido. De maneira geral a estrutura de cada exemplo é composta por um vetor de valores de características e o rótulo da classe associada. A ideia é utilizar essas informações no algoritmo de indução para construir um classificador que tem a capacidade de identificar corretamente a classe de novos exemplos ainda não rotulados.

No processo de aprendizado não-supervisionado, o trabalho funciona da seguinte forma: A partir dos exemplos fornecidos o indutor tenta determinar se alguns deles podem ser agrupados de alguma maneira. Após a construção desses grupos, normalmente é necessária uma análise para identificar o contexto de cada grupo dentro da situação que está sendo tratada (MONARD; BARANAUSKAS, 2003).

O aprendizado de máquina está em um estágio anterior do processo de descoberta de conhecimento. *Machine Learning* é o campo do estudo científico que se concentra em algoritmos de indução e em outros algoritmos que se pode dizer que tem a capacidade de aprender (PROVOST; KOHAVI, 1998). *Machine learning* representa uma evolução das técnicas de reconhecimento de padrões e da teoria do aprendizado computacional em inteligência artificial. Investiga meios para que máquinas sejam capazes de realizar tarefas que seriam executadas por seres humanos, porém é formada por regras previamente aprendidas que possibilitam computadores tomar decisões baseando-se em uma massa de dados existente (WITTEK, 2014).

2.3 Deep Learning

Na grande maioria das vezes em *machine learning*, os modelos são treinados para executar tarefas úteis tendo como base recursos manualmente refinados a partir de dados brutos. Ou seja, é necessário que os recursos utilizados passem por um processo de engenharia de características (*feature engineering*) para que seja possível realizar a classificação ou utilizar recursos que fo-

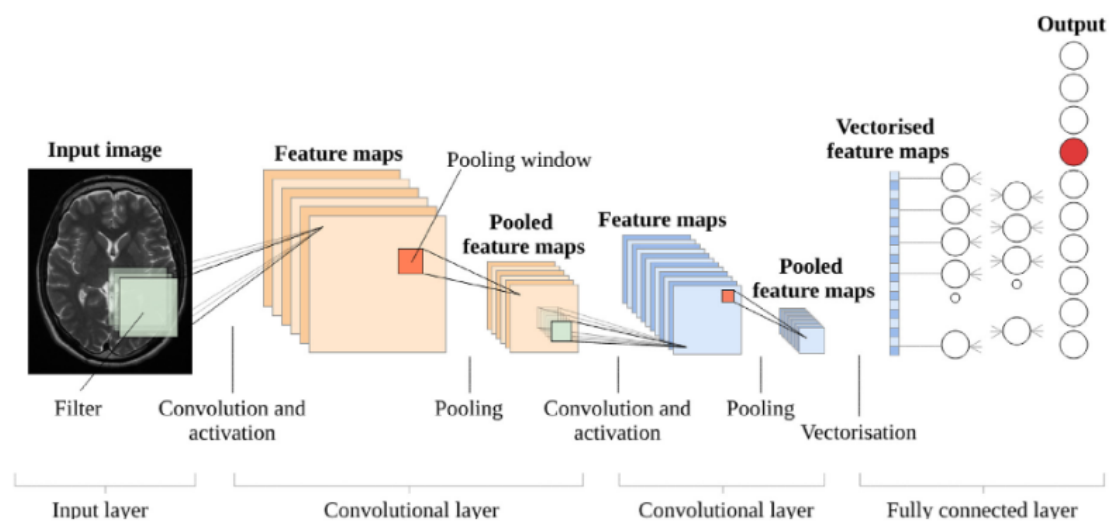
ram previamente aprendidos por outro modelo. Em *deep learning*, os computadores possuem a capacidade de identificar os recursos úteis para o modelo automaticamente, diretamente dos dados brutos, ignorando a difícil etapa de refinamento manual de informações. A principal característica do método de *deep learning* é o foco em aprender automaticamente as representações de dados. Essa é a principal diferença entre as abordagens de *deep learning* e de aprendizado de máquina tradicional. A descoberta de recursos e a execução de uma tarefa são mescladas em um problema e aprimoradas durante o mesmo processo de treinamento (LUNDERVOLD; LUNDERVOLD, 2019).

2.4 Redes Neurais Convolucionais

Em imagens médicas, o interesse em *deep learning* é despertado pelo estudo e utilização de redes neurais convolucionais. A Rede Neural Convolucional é um tipo particular de rede neural artificial capaz de preservar relações espaciais nos dados, com poucas conexões entre as camadas. A entrada dos dados na rede convolucional é organizada em uma estrutura de grade e, em seguida, é alimentada através de camadas que preservam essas relações (LUNDERVOLD; LUNDERVOLD, 2019). Cada operação de camada opera em uma pequena região da camada anterior como mostra na figura 2 o fluxo de uma rede convolucional tradicional.

Estas redes possibilitam uma utilização altamente eficiente dos dados de entrada e são muito eficazes em tarefas orientadas a imagens. Na arquitetura de uma CNN existem diversas camadas de ativação e operações de conversão que são intercaladas. O seu processo de treinamento é feito usando retropropagação e descida de gradiente (LUNDERVOLD; LUNDERVOLD, 2019).

Figura 2 – Blocos de construção de uma CNN tradicional.



Fonte: LUNDERVOLD; LUNDERVOLD, (2019)

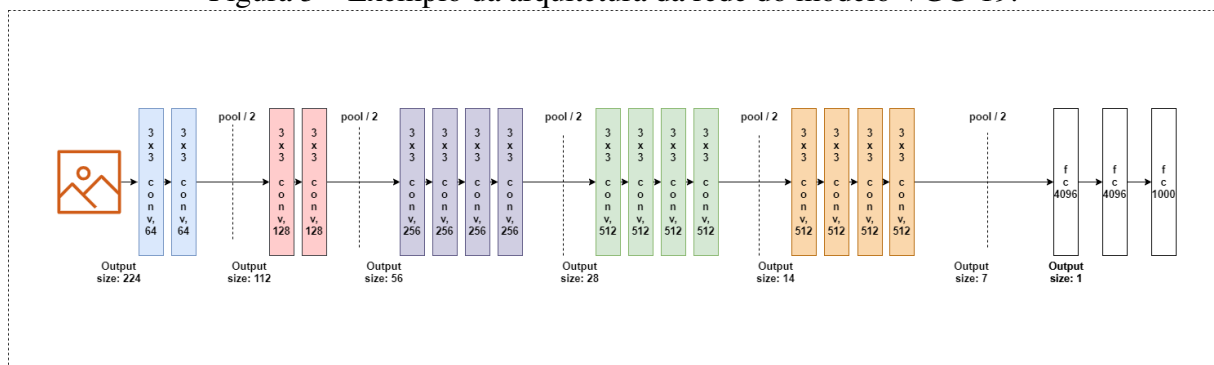
2.5 VGG-19

Construir uma rede neural convolucional CNN do zero tem suas vantagens e desvantagens, mas acima de tudo é necessário uma base de dados gigantesca para essa construção. Uma abordagem favorável é utilizar modelos pré-treinados que utilizaram para o treinamento grande conjunto de dados como Resnet, VGG-16, VGG-19, entre outros.

Existem várias técnicas e estratégias de *transfer learning* utilizando o mesmo modelo para extrair features de novas imagens (JAWOREK-KORJAKOWSKA; KLECZEK; GORGON, 2019). É relatado que a arquitetura de rede do modelo VGG-19 alcança alta precisão no processamento de imagens de grandes conjuntos de dados, como o ImageNet.

O modelo VGG-19 possui aproximadamente 143 milhões de parâmetros, em que os parâmetros são aprendidos utilizando o grande conjunto de dados oferecido pelo ImageNet que contém 1,2 milhão de imagens gerais com mais de 1.000 categorias diferentes para treinamento. O VGG-19 contém 19 camadas treináveis, incluindo camadas convolucionais e totalmente conectadas, além de max pooling e dropout (JAWOREK-KORJAKOWSKA; KLECZEK; GORGON, 2019). A arquitetura da CNN VGG-19 é exibida na Figura 3.

Figura 3 – Exemplo da arquitetura da rede do modelo VGG-19.



Fonte: Elaborado pelo autor

3 TRABALHOS RELACIONADOS

Para atingir a ideia proposta no trabalho, preliminarmente foram feitas pesquisas e estudos de maneira exploratória sobre arquiteturas de rede neural artificial aplicadas em análises e processamentos de imagens digitais. Tendo como origem esse estudo inicial, foi possível escolher a arquitetura mais adequada para iniciar experimentações em cima do objetivo deste trabalho, que é a identificação de COVID-19 a partir de imagens digitais de raio X do tórax de pacientes.

Após pesquisas realizadas no Google Scholar e outras bases de trabalhos acadêmicos e científicos, utilizando-se os filtros “*deep learning*”, “*health care*” e “*pneumonia detection*” no período dos últimos cinco anos, foram encontrados os trabalhos que serão apresentados a seguir. Estes trabalhos serviram como base para as experimentações desenvolvidas.

Em (RAJPURKAR et al., 2017) os autores descrevem a construção de um modelo capaz de identificar pneumonia automaticamente a partir de imagens de radiografias do tórax de pacientes. Denominaram seu modelo de CHeXNet, criado utilizando redes neurais convolucionais de 121 camadas. O conjunto de dados utilizado no treinamento desse modelo foi obtido através do ChestX-ray14. Este *dataset* possui uma quantidade significativa de imagens de raio X do tórax disponível ao público, com mais de 100.00 imagens frontais de raio-x com 14 doenças. Uma particularidade interessante do CHeXNet é que no conjunto de saída além da probabilidade de pneumonia ele gera um mapa de calor, localizando áreas da imagem mais propensas a indicar pneumonia. Os dados utilizados para o treinamento do modelo foram de 30,805 pacientes distintos contendo 112,120 imagens frontais de raio X do tórax. O conjunto de dados foi rotulado nas imagens com positivo para pneumonia ou saudável. Para a tarefa de detecção de pneumonia, foi feita uma divisão de maneira aleatória do conjunto de dados, divididos em conjuntos de treinamento (28744 pacientes, 98637 imagens), de validação (1672 pacientes, 6351 imagens) e de teste (389 pacientes, 420 imagens) (RAJPURKAR et al., 2017). Quanto aos resultados, o ChestX-ray14 atingiu uma precisão de 95% na identificação de pneumonia.

O estudo denominado COVID-Net (WANG; WONG, 2020) apresenta um projeto utilizando rede neural profunda convolucional, realizando adaptações para a detecção de casos de COVID-19 em pacientes a partir de imagens de raio X do tórax. O conjunto de dados utilizado no treinamento do modelo foi criado pelos autores e foi denominado de COVIDx, é um conjunto de imagens contendo 13.975 imagens de raio x frontais do tórax de 13.870 pacientes. Esse conjunto de imagens foi criado obtendo imagens de cinco repositórios de dados de acesso aberto distintos contendo imagens de raio X do tórax (WANG; WONG, 2020). Os rótulos existentes nesse conjunto de dados são de casos de pacientes saudáveis e pacientes apresentando sinais positivos para COVID-19. O modelo treinado faz uma identificação binária capaz apenas de diferenciar casos positivos de COVID-19 ou casos saudáveis.

O protótipo COVID-Net inicial foi construído e avaliado usando a biblioteca de aprendizado profundo Keras com um back-end *TensorFlow*. A arquitetura COVID-Net proposta foi construída usando síntese generativa, que é baseada em uma interação complexa entre um par

Tabela 1 – Comparativo do trabalhos relacionados

Trabalho	Objetivo	Resultado	Arquitetura
CHeXNet	Pneumonia	Precisão de 95%	CNN
COVID-Net	COVID-19	Precisão de 93,3%	CNN

Fonte: Elaborado pelo autor.

gerador-inquisidor que trabalha em conjunto para obter insights e aprender a gerar arquiteturas de redes neurais profundas que melhor atendem aos requisitos de projeto especificados por humanos. A arquitetura de rede COVID-Net é composta por uma mistura heterogênea de camadas de convolução com uma diversidade de kernel com tamanhos variando de 7 X 7 a 1 X 1. Em se tratando dos resultados que o modelo se propõe a detectar, a COVID-Net atinge uma precisão de 93,3% nos testes realizados (WANG; WONG, 2020).

Os trabalhos que foram encontrados e apresentados anteriormente apresentam uma boa precisão na detecção dos rótulos propostos. No caso do CHeXnet se propõe a identificar casos de pneumonia ou casos saudáveis em paciente. No projeto COVID-Net buscam identificar caso positivo de COVID-19 ou saudável. Ambos os estudos fazem uma detecção binária, sendo a organização de seu conjunto de dados feita dessa forma, rotulando de forma binária seus dados de treinamento.

A tabela 1 demonstra uma visualização clara entre os objetivos e resultados dos trabalhos relacionados. Existem oportunidades a serem exploradas, como identificar o tipo de pneumonia que está sendo detectada, como pneumonia bacteriana, COVID-19 ou outras pneumonias virais e até mesmo aumentar a precisão do modelo.

4 MATERIAIS E MÉTODOS

Esta seção apresenta o conjunto de dados escolhido para a tarefa de identificação de COVID-19 e a metodologia proposta. O treinamento do modelo utilizou imagens do raio X do tórax de pacientes com COVID-19, pneumonia bacteriana e saudáveis obtidas a partir de dois *datasets* distintos disponíveis no repositório Kaggle: ‘Chest X-Ray Images (Pneumonia)’ e ‘COVID-19 chest xray’.

O conjunto de dados foi agrupado em três categorias: “COVID-19”, “Bacteriana” e “Saudável”. Além de identificar COVID-19 o modelo se propõe a identificar a presença de pneumonia bacteriana. O método utilizado propõe o uso da rede neural convolucional VGG-19, que utiliza como base no treinamento o *dataset* criado contendo as três categorias descritas acima.

Um dos principais objetivos do trabalho é identificar uma arquitetura de rede neural capaz de identificar COVID-19 com um alto percentual de precisão. Além disso, pretende-se com o trabalho preencher uma lacuna da literatura, que consiste, em identificar a presença de COVID-19, de pneumonia bacteriana ou então um estado saudável.

Durante a criação do modelo foram realizados dois treinamentos utilizando o conjunto de dados, porém com volumes diferentes, que serão descritos nesta seção.

4.1 Conjunto de dados

Foram criados dois *datasets* para serem utilizados como conjunto de base de dados para os treinamentos. Os conjuntos foram criados utilizando duas fontes distintas de imagens de raio x do tórax de pacientes, onde determinado *dataset* x possui imagens de pneumonia viral, pneumonia bacteriana e saudável e o *dataset* y possui imagens de COVID-19. O *dataset* x com se denomina Chest X-Ray Images (Pneumonia) e o *dataset* y COVID-19 chest xray, estão disponíveis no kaggle. O kaggle é uma comunidade de cientistas de dados que possui diversos *datasets* disponíveis para estudos, como os utilizados neste trabalho. Os *datasets* criados a partir dessas origens distintas possuem três categorias rotuladas como “Covid-19”, “Pneumonia-Bacteriana” e “normal” na quantidade exibida nas tabelas 2 e 3. O que difere do Conjunto de dados I para o Conjunto de dados II é apenas o volume de imagens contido em cada um.

Tabela 2 – Conjunto de dados I

Rótulos	Quantidade de imagens
Covid-19	266
Pneumonia-Bacteriana	266
Normal	266

Fonte: Elaborado pelo autor.

Tabela 3 – Conjunto de dados II

Rótulos	Quantidade de imagens
Covid-19	288
Pneumonia-Bacteriana	288
Normal	288


Fonte: Elaborado pelo autor.

Durante a seleção das imagens foram realizados testes, com o objetivo de verificar imagens que iriam reduzir a performance.

Durante a seleção das imagens foram realizados testes com o objetivo de selecionar imagens com maior qualidade para atingir melhores resultados durante o treinamento. Foram identificadas imagens que diminuíam a performance do modelo. Dentro do conjunto de dados disponibilizado no Kaggle existem imagens com ruídos, ruídos esses que influenciaram durante os testes negativamente na acurácia. A seleção foi realizada de modo a descartar imagens que não fossem frontais do tórax de pacientes e descartar também imagens com outros ruídos, tais como imagens que continham marcas d’água e setas digitais.

A figura 4 exemplifica imagens que foram descartadas durante o processo de seleção de imagens para compor o conjunto de dados.

Figura 4 – Exemplo de imagens descartadas no processo de seleção por conter ruídos.



Fonte: Elaborado pelo autor.

4.1.1 Tratamento das imagens e Augmentation

As imagens que foram selecionadas são carregadas para uma lista em memória onde elas são convertidas para formato "RGB" utilizando a lib pillow do python e redimensionadas para uma nova dimensão de 150x150 pixels. As imagens são todas rotuladas com suas respectivas categorias.

Foram empregados vários métodos de *data augmentation* para aumentar artificialmente o tamanho e a qualidade do conjunto de dados. O processo de *data augmentation* ajuda a resolver problemas de sobreajuste e aprimora a capacidade de generalização do modelo durante o treinamento (STEPHEN et al., 2019). *Data Augmentation* é uma técnica de manipulação de dados que gera novas instâncias de dados sem remover a essência ou o núcleo dos dados originais (HIDAYATULLAH; VIOLINA,). As configurações que foram utilizadas no aumento da quantidade de imagens são detalhadas na Tabela 4.

Tabela 4 – Data Augmentation

Método	Configuração
Faixa de rotação	20
Faixa de zoom	0.15

Fonte: Elaborado pelo autor.

O intervalo de rotação indica o intervalo em que as imagens foram rotacionadas aleatoriamente durante o treinamento, ou seja, 20 graus. O alcance do zoom amplia aleatoriamente as imagens na proporção de 15%.

Foi utilizado na construção deste trabalho o tratamento de dados de imagem com o objeto *ImageDataGenerator*³ do Keras. O *ImageDataGenerator* permite de maneira simples pré-processar e aumentar o conjunto de dados de imagem artificialmente em tempo real durante o treinamento. Neste trabalho foram utilizadas apenas as técnicas de *data augmentation* que o *ImageDataGenerator* fornece. Isso é muito útil, especialmente quando o conjunto de dados é muito pequeno. As técnicas de rotação e zoom utilizadas neste trabalho produzem efetivamente mais dados para o treinamento.

Durante o treinamento todas as imagens originais são transformadas com o passar das épocas do treinamento com a configuração definida nos parâmetros de criação do *ImageDataGenerator*. Em cada época o número de imagens é o mesmo que foi inserido originalmente no conjunto de dados de treinamento, porém vai sofrendo transformações em tempo real no decorrer do treinamento. Ao executar este procedimento são criados novos dados artificialmente para o treinamento.

Todos os experimentos realizados neste trabalho foram treinados utilizando 100 épocas como parâmetro. É possível dizer que durante os treinamentos foram utilizadas 100 versões diferentes de cada imagem original. As imagens geradas não são totalmente diferentes das originais, mas possuem uma faixa de alteração com rotação e zoom. Desta forma, o modelo aprendido pode ser mais robusto e preciso, pois é treinado em diferentes variações da mesma imagem.

4.1.2 Segregação das imagens

A segregação das imagens para treinamento e testes é realizada de forma aleatória, onde 80% da quantidade total do conjunto de dados das imagens de raio X do tórax são destinados para treinamento do modelo e os 20% restantes são utilizados para o seu teste.

³<https://keras.io/api/preprocessing/image/>

4.2 Arquitetura de Rede Neural

Foi criado o modelo para realizar a identificação do problema proposto tendo a VGG19 como base, que é uma arquitetura de rede neural convolucional com filtros de convolução muito pequenos (3x3) e com 19 camadas no modelo base, com os pesos calibrados pela configuração imagenet.

4.2.1 Funções de callback

Foi adicionado a função *ReduceLROnPlateau* no modelo, que é uma função de callback que auxilia a reduzir a taxa de aprendizado pelo fator, caso não ocorra mudanças na perda. A configuração feita para essa função foi de monitorar o valor de acurácia dado um tempo X que é configurável. No experimento realizado, esse tempo configurado foi de 2. Se atingir esse tempo sem sofrer alteração no valor de acurácia, será aplicado o *ReduceLROnPlateau* dado o fator configurado y. No experimento o fator configurado para a função foi de 0.3.

4.2.2 Hiperparâmetros

Os hiperparâmetros são usados para configurar vários aspectos do algoritmo de aprendizado durante o treinamento e podem causar efeitos variados no modelo resultante e em seu desempenho (CLAESEN; MOOR, 2015). A tabela 5 mostra os hiperparâmetros utilizados no modelo experimentado neste trabalho.

Tabela 5 – Hiperparâmetros

Parâmetro	Configuração
Batch Size	34
Input Shape	(150, 150, 3)
Random State	42
Alpha	1e-5
Epoch	100

Fonte: Elaborado pelo autor.

O parâmetro *Batch size* configura a quantidade de imagens por lote no processamento. O valor do parâmetro *input shape* serve para configurar a forma de entrada. O parâmetro *random state* serve para reproduzir a experiência dado o valor configurado. *Alpha* é o parâmetro que determina a taxa de aprendizado e finalmente o parâmetro *Epoch* configura a quantidade de vezes que será treinado o modelo.

4.2.3 Camadas do modelo

A presente seção descreve a construção de fato do modelo, detalhando as camadas que foram adicionadas. Primeiramente foi criado o modelo sequencial adicionando o modelo VGG-19 como base.

O *pooling* configurado para o modelo foi feito a partir de uma resolução pela média global de duas dimensões. Adicionado também no processo o *BatchNormalization*, que aumenta a estabilidade da rede neural, aplicando normalizações no meio do treinamento. Outra camada adicionada na configuração foi a configuração *Flatten*, que serializa a imagem para a camada densa. Foi adicionada também na construção do modelo uma camada densa, adicionando 64 neurônios com ativação RELU. Foi utilizado na configuração do modelo um *dropout* com 0.4 de valor, o dropout serve para melhorar a generalidade da rede. A última camada adicionada foi uma camada densa com 3 neurônios com ativação softmax.

4.2.4 Compilação do modelo

Os parâmetros utilizados no momento de compilar o modelo estão exibidos na Tabela 6.

Tabela 6 – Parâmetros de compilação

Parâmetro	Configuração
Optimizer	adam
Loss	binary_crossentropy
Metrics	acc

Fonte: Elaborado pelo autor.

A otimização *Adam* é uma configuração de otimização para descida de gradiente estocástico, baseada na estimativa adaptativa de momentos de primeira e segunda ordem. O objetivo das funções de perda *loss* é calcular a quantidade que um modelo deve procurar minimizar durante o treinamento, a configuração do parâmetro escolhido foi *binary_crossentropy* que calcula a perda de entropia cruzada entre rótulos verdadeiros e rótulos previstos. A métrica é uma função usada para julgar o desempenho do seu modelo e nesse caso está se baseando pela acurácia ("*acc*") do modelo que mede a frequência das previsões que são iguais aos rótulos.

5 EXPERIMENTOS E AVALIAÇÃO DE RESULTADOS

Nesta seção são descritos os experimentos realizados e analisados os seus resultados. O primeiro experimento foi realizado utilizando o "Conjunto de dados I" com o total de 798 imagens para treinamento. O segundo experimento foi executado utilizando o segundo *dataset* para treinamento "Conjunto de dados II" com o total de 864 imagens. O que diferencia os dois experimentos é apenas a quantidade de dados oferecidos para o treinamento do modelo.

As métricas utilizadas para demonstrar os resultados dos dois experimentos foram: Gráfico de curva de precisão do modelo, que demonstra a performance de acurácia do treinamento do modelo no passar das épocas; Matriz de confusão, a matriz de confusão demonstra a precisão completa de classificação do modelo; Curva Característica de Operação do Receptor (ROC) e Curva AUC: Para o caso de classificação a curva ROC demonstra a performance do modelo em distinguir caso positivo e negativo. A curva AUC é derivada da curva ROC, ("area under the ROC curve") e se chega ao resultado calculando a "área sob a curva" o seu valor varia de 0,0 até 1,0. Quanto maior o AUC melhor a performance do modelo.

5.1 Primeiro experimento

Na tarefa de identificar automaticamente COVID-19, Pneumonia Bacteriana ou caso saudável através de imagens do raio X do tórax de pacientes o modelo proposto em seu primeiro experimento utilizando para o treinamento um conjunto de dados com o total de 798 imagens, sendo 266 imagens de raio X de tórax de pacientes saudáveis, 266 imagens de COVID-19 e 266 imagens de pneumonia bacteriana.

Foi aplicada a estratégia de *data augmentation* em tempo real e no decorrer do treinamento o modelo alcançou um resultado de 0.9608 de acurácia. Para demonstrar a performance durante o treinamento das épocas foi gerado também o modelo de acurácia (Figura 5).


Para demonstrar os resultados dos testes foi gerada uma matriz de confusão (Figura 6) na qual o índice zero significa pneumonia bacteriana, o índice 1 significa COVID-19 e o índice 2 indica uma situação normal. Por último, para demonstrar o desempenho do primeiro experimento, é exibida na figura 7 a métrica de curva ROC.

5.2 Segundo experimento

O segundo experimento utilizou para o treinamento um conjunto de dados com o total de 864 imagens, sendo 288 imagens de raio X de tórax de pacientes saudáveis, 288 imagens de COVID-19 e 288 imagens de pneumonia bacteriana. Foi aplicada a estratégia de *data augmentation* em tempo real. No decorrer do treinamento o modelo alcançou um resultado de 0.9686 de acurácia.

Para demonstrar a performance durante o treinamento das épocas foi gerado o modelo de acurácia (Figura 8). Para demonstrar os resultados dos testes foi gerada uma matriz de confusão

Figura 5 – Acurácia do Modelo - Primeiro experimento.



Fonte: Elaborado pelo autor

(Figura 9) onde o índice zero significa pneumonia bacteriana, índice 1 significa COVID-19 e 2 normal. Por último, para demonstrar o desempenho do segundo experimento é exibida na figura 10 a métrica de curva ROC.


5.3 Análise de resultados

Na tarefa de identificar automaticamente COVID-19, Pneumonia Bacteriana ou caso saudável através de imagens do raio X foi construído um modelo com a configuração descrita neste trabalho. O modelo pode ser submetido a treinamentos utilizando como origem de dados *datasets* com diferentes volumetrias. Este foi o foco avaliado no experimento do estudo atual.

O modelo foi submetido a treinamentos utilizando dois conjuntos de dados com diferentes volumetrias. Utilizou-se o conjunto de dados I com uma volumetria inferior ao Conjunto de dados II para identificar a capacidade do modelo em aprimorar sua acurácia quando submetido a treinamentos com conjunto de dados maiores.

O primeiro experimento utilizando o Conjunto de dados I gerou um resultado de acurácia de 0.9608, já no segundo experimento utilizando o Conjunto de dados II apresentou um resultado de acurácia de 0.9686. A tabela 7 foi criada com o intuito de oferecer uma visualização melhor na comparação dos resultados entre os experimentos.

Figura 6 – Matriz de confusão - Primeiro experimento.




Fonte: Elaborado pelo autor

Tabela 7 – Resultados entre experimentos

Experimento	Resultado (Acurácia)
Treinamento - Conjunto de dados I	0.9608
Treinamento - Conjunto de dados II	0.9686


Fonte: Elaborado pelo autor.

Figura 7 – Curva Característica de Operação do Receptor (ROC) - Primeiro experimento.



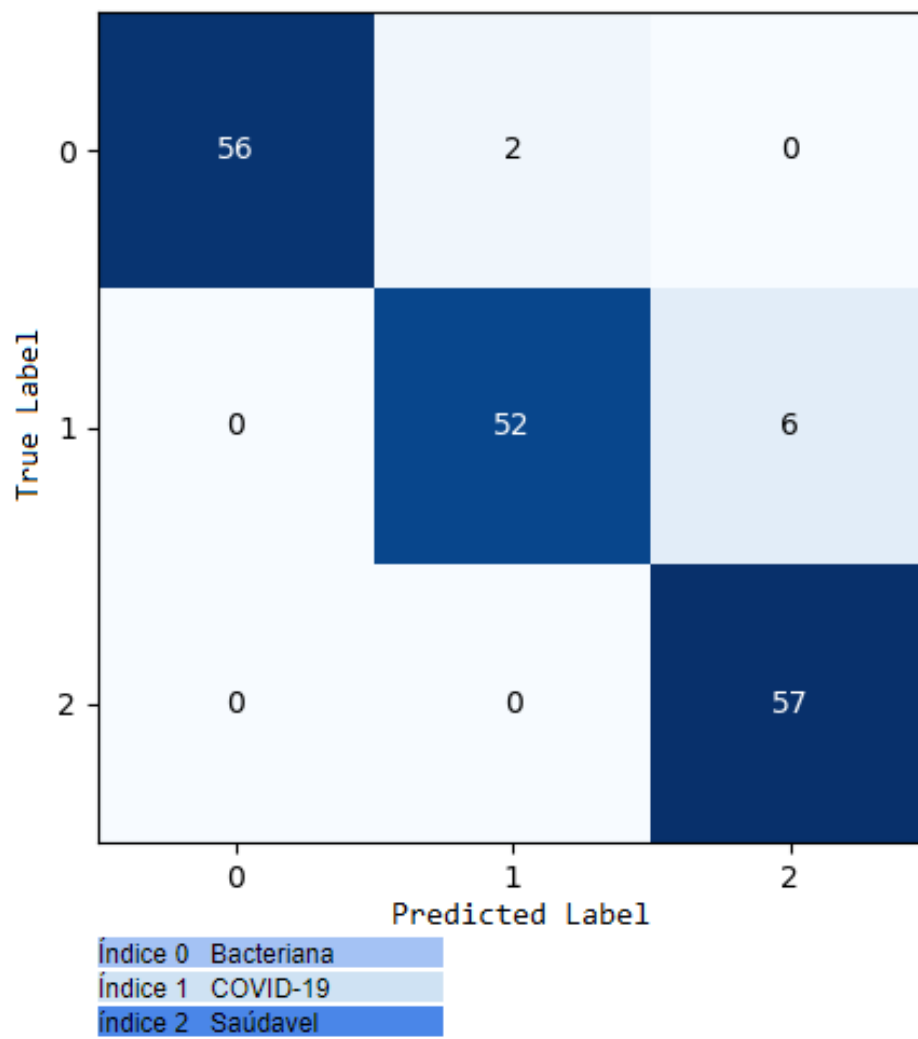
Fonte: Elaborado pelo autor

Figura 8 – Acurácia do Modelo - Segundo experimento.




Fonte: Elaborado pelo autor

Figura 9 – Matriz de confusão - Segundo experimento.



Fonte: Elaborado pelo autor

Figura 10 – Curva Característica de Operação do Receptor (ROC) - Segundo experimento.



Fonte: Elaborado pelo autor

6 CONCLUSÃO

Tendo como objetivo desenvolver alternativas para o diagnóstico de COVID-19, que se mostrou um problema de saúde pública em nível mundial e buscar abordagens que viabilizaram esse diagnóstico com o uso de *deep learning*, o presente trabalho analisou diversos artigos como forma de avaliar a viabilidade de desenvolvimento do projeto proposto. Após minuciosa análise, é possível afirmar que o diagnóstico por imagem de casos de síndrome respiratória aguda grave com base em exames de raio X, não apenas é possível, assim como há a possibilidade de se diferenciar de uma pneumonia bacteriana.

Os resultados obtidos durante o desenvolvimento do modelo não apenas se mostraram viáveis, assim como apresentaram ótimos resultados, com acurácia de aproximadamente 96% ao analisar raio X torácico com três possíveis diagnósticos nos dois experimentos realizados.

Este trabalho atua de forma diferente dos trabalhos relacionados que foram estudados durante o experimento desenvolvido. Estes trabalhos conseguem executar uma classificação binária entre duas categorias. Um exemplo é o COVID-Net, que conseguia identificar caso positivo de COVID-19 ou saudável com uma precisão de 93,3%. Outro exemplo é o CHeXNet, que consegue identificar casos de pneumonia ou situação saudável em paciente com uma precisão de 95%. O estudo atual, através das experimentações, se provou eficiente em detectar maior variedade de categorias e com um percentual de precisão ainda mais elevado do que os trabalhos citados.

Como trabalhos futuros, o objetivo é realizar mais experimentos, para validar de forma mais extensiva o modelo elaborado e também investigar a possibilidade de identificar outros tipos de pneumonias virais, para estender a capacidade de diagnóstico do modelo.

Será interessante também buscar um conjunto de dados com uma volumetria maior para os treinamentos, uma vez que a doença é recente mas já está disponível um conjunto de dados notável. Porém com o passar do tempo a tendência é de se ter cada vez mais dados para se trabalhar em estudos. Também serão implementadas outras arquiteturas de redes neurais artificiais, como forma de avaliar possibilidades de melhorias, ou ainda, o desenvolvimento de um sistema de contraprova, para possibilitar o diagnóstico mais seguro.

Referências

- AI, T. et al. Correlation of chest ct and rt-pcr testing in coronavirus disease 2019 (covid-19) in china: a report of 1014 cases. **Radiology**, Radiological Society of North America, p. 200642, 2020.
- ARONS, M. et al. Presymptomatic sars-cov-2 infections and transmission in a skilled nursing facility [published online ahead of print april 24, 2020]. **N Engl J Med**. doi, v. 10.
- CLAESEN, M.; MOOR, B. D. Hyperparameter search in machine learning. **arXiv preprint arXiv:1502.02127**, 2015.
- ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. **Nature**, Nature Publishing Group, v. 542, n. 7639, p. 115–118, 2017.
- FAWCETT, T.; PROVOST, F. **Data Science para Negócios: O que você precisa saber sobre mineração de dados e pensamento analítico de dados**. [S.l.]: Alta Books Editora, 2018.
- GREWAL, M. et al. Radnet: Radiologist level accuracy using deep learning for hemorrhage detection in ct scans. In: IEEE. **2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)**. [S.l.], 2018. p. 281–284.
- HIDAYATULLAH, R. C.; VIOLINA, S. Convolutional neural network architecture and data augmentation for pneumonia classification from chest x-rays images.
- JACOBI, A. et al. Portable chest x-ray in coronavirus disease-19 (covid-19): A pictorial review. **Clinical Imaging**, Elsevier, 2020.
- JAWOREK-KORJAKOWSKA, J.; KLECZEK, P.; GORGON, M. Melanoma thickness prediction based on convolutional neural network with vgg-19 model transfer learning. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops**. [S.l.: s.n.], 2019. p. 0–0.
- KOORAKI, S. et al. Coronavirus (covid-19) outbreak: what the department of radiology should know. **Journal of the American college of radiology**, Elsevier, 2020.
- LUNDERVOLD, A. S.; LUNDERVOLD, A. An overview of deep learning in medical imaging focusing on mri. **Zeitschrift für Medizinische Physik**, Elsevier, v. 29, n. 2, p. 102–127, 2019.
- MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, Manole Ltda, v. 1, n. 1, p. 32, 2003.
- NAIR, A. et al. A british society of thoracic imaging statement: considerations in designing local imaging diagnostic algorithms for the covid-19 pandemic. **Clinical Radiology**, Elsevier, v. 75, n. 5, p. 329–334, 2020.
- NETTO, R. G. F.; CORRÊA, J. W. do N. Epidemiologia do surto de doença por coronavírus (covid-19). **DESAFIOS-Revista Interdisciplinar da Universidade Federal do Tocantins**, v. 7, n. Especial-3, p. 18–25, 2020.
- PRANAV, R. et al. Cardiologist-level arrhythmia detection with convolutional neural networks. **Computing Research Repository (CoRR)**, abs/1707.01836, 2017.

PROVOST, F.; KOHAVI, R. Glossary of terms. **Journal of Machine Learning**, v. 30, n. 2-3, p. 271–274, 1998.

RAJPURKAR, P. et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. **arXiv preprint arXiv:1711.05225**, 2017.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of research and development**, IBM, v. 3, n. 3, p. 210–229, 1959.

SLIFKA, M. K.; MESSER, W. B.; AMANNA, I. J. Analysis of covid-19 transmission: Low risk of presymptomatic spread? **Archives of Pathology & Laboratory Medicine**, the College of American Pathologists, 2020.

STEPHEN, O. et al. An efficient deep learning approach to pneumonia classification in healthcare. **Journal of healthcare engineering**, Hindawi, v. 2019, 2019.

WANG, L.; WONG, A. Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. **arXiv preprint arXiv:2003.09871**, 2020.

WITTEK, P. **Quantum machine learning: what quantum computing means to data mining**. [S.l.]: Academic Press, 2014.

ZHONG, N. **Clinical Characteristics of Coronavirus Disease 2019 in China**. [S.l.]: New, 2020.