



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS CORRENTE
CURSO TECNÓLOGO EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS

TAILANE DE FRANÇA VIEIRA

IDENTIFICAÇÃO DO SARS-COV-2 E PNEUMONIA VIRAL A PARTIR DE
IMAGENS DE RAIO-X DE PULMÕES COM TENSORFLOW, KERAS E DEEP
LEARNING

CORRENTE

2022

TAILANE DE FRANÇA VIEIRA

IDENTIFICAÇÃO DO SARS-COV-2 E PNEUMONIA VIRAL A PARTIR DE IMAGENS
DE RAIOS-X DE PULMÕES COM TENSORFLOW, KERAS E DEEP LEARNING

Trabalho de Conclusão de Curso apresentado como exigência parcial para obtenção do diploma do Curso de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Corrente.

Orientador: Prof.Me. Felipe Gonçalves dos Santos.

CORRENTE

2022

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Vieira, Tailane de França

V658i Identificação do Sars - Cov - 2 e pneumonia viral a partir de
imagens de Raio - X de Pulmões com Tensorflow, Keras e Deep
Learning / Tailane de França Vieira. - 2023.
24 p.: il. color.

Trabalho de Conclusão de Curso (Análise e Desenvolvimento
de Sistemas) - Instituto Federal de Educação, Ciência e
Tecnologia do Piauí, Campus Corrente, 2023.

Orientador : Prof Me. Felipe Gonçalves dos Santos.

1. Análise e Desenvolvimento de Sistemas - estudo e ensino. 2. covid-19.
3. Aprendizado de máquina. 4. Fluxo tensor. I. Título.

CDD – 004.21

Elaborado por Tefischer Huanderson Soares e Sousa CRB 3/1251

IDENTIFICAÇÃO DO SARS-COV-2 E PNEUMONIA VIRAL A PARTIR DE IMAGENS DE RAIO-X DE PULMÕES COM TENSORFLOW, KERAS E DEEP LEARNING

Tailane de França Vieira¹
Felipe Gonçalves dos Santos²

RESUMO

A pandemia causada pelo vírus SARS-CoV-2 resultou em mais de 555 milhões de casos confirmados e mais de 6,35 milhões de mortes em todo o mundo, desencadeando uma epidemia massiva. As pneumonias também são exemplo de doenças consideradas como principais causas de morte em muitos países, como por exemplo, a pneumonia viral que é um tipo de infecção que atinge os pulmões e que é provocada por vírus, geralmente os mesmos que causam gripes e resfriados, ou mesmo o SARS-CoV-2. Na primeira parte deste trabalho, foi discutido como o SARS-CoV-2 e a Pneumonia Viral podem ser detectadas em radiografias de tórax de pacientes, como foram revisados os conjuntos de dados e em seguida, foi abordado como treinar um modelo de aprendizado profundo usando o Tensorflow e Keras para prever o SARS-CoV-2 e Pneumonia Viral no conjunto de dados de imagens de raio-x de pacientes. O objetivo deste trabalho consistiu em desenvolver e treinar um modelo de aprendizado profundo personalizado, avaliando arquiteturas de redes neurais convolucionais, para determinar em qual das classes o pulmão do paciente se enquadra: covid, normal ou pneumonia viral em um conjunto de dados de imagens de raio-x, utilizando a linguagem de programação Python com Tensorflow, Keras e Deep Learning. O modelo de treinamento baseado na arquitetura VGG19, obteve melhor desempenho na identificação e classificação das imagens. Conclui-se que um modelo de treinamento com Tensorflow e Keras usando Deep Learning pode ser capaz de aprender e identificar padrões.

Palavras-chaves: covid-19; pneumonia viral; aprendizado profundo; aprendizado de máquina; fluxo tensor.

ABSTRACT

The pandemic caused by the SARS-CoV-2 virus has resulted in more than 555 million confirmed cases and more than 6.35 million deaths worldwide, triggering a massive epidemic. Pneumonia is also an example of diseases considered to be the main causes of death in many countries, such as viral pneumonia, which is a type of infection that affects the lungs and is caused by viruses, usually the same ones that cause colds and flu, or even SARS-CoV-2. In the first part of this work, it was discussed how SARS-CoV-2 and Viral Pneumonia can be detected in chest X-rays of patients, how the datasets were reviewed and then how to train a deep learning model using o TensorFlow and Keras to predict SARS-CoV-2 and Viral Pneumonia in patient x-ray image dataset. The objective of this work was to develop and train a personalized deep learning model, evaluating convolutional neural network architectures, to determine which of the classes the patient's lung falls into: covid, normal or viral pneumonia in a dataset of images of x-ray, using the Python programming language with Tensorflow, Keras and Deep Learning. The training model based on the VGG19 architecture achieved better performance in image identification and classification. It is concluded that a training model with tensorflow and keras using deep learning may be able to learn and identify patterns.

Keywords: covid-19; viral pneumonia; deep learning; machine learning; tensorflow.

¹ Graduanda em Análise e Desenvolvimento de Sistemas. Instituto Federal do Piauí. tailanefv@gmail.com

²Professor Orientador – Instituto Federal do Piauí. felipe.santos@ifpi.edu.br

LISTA DE ILUSTRAÇÕES

Figura 01 - Resumo do fluxo de problemas de classificação	15
Figura 02 - Funcionamento básico de uma CNN: camada de convolução.....	16
Figura 03 - Imagens de raio-x de pulmão com covid e pulmão normal	17
Figura 04 - Imagens de raio-x de pulmão com covid, pulmão normal e com pneumonia viral	17
Figura 05 - CNNs na classificação de imagens	18
Figura 06 - Acurácia de treino e teste nos modelos treinados	18
Figura 07 - Perda de treino e teste nos modelos treinados	19
Figura 08 - Matriz de Confusão dos modelos treinados	19
Figura 09 - Acurácia de treino e teste nos modelos treinados	20
Figura 10 - Perda de treino e teste nos modelos treinados	20
Figura 11 - Matriz de Confusão dos modelos treinados	20

LISTA DE TABELAS

Tabela 01- Acurácia, Precisão, Sensibilidade e Especificidade dos modelos aplicados nas diferentes arquiteturas	19
Tabela 02 - Resultados da Acurácia dos modelos aplicados nas diferentes arquiteturas	21

SUMÁRIO

1 INTRODUÇÃO	10
2 REFERENCIAL TEÓRICO	11
2.1 SARS-COV-2 (COVID-19) E PNEUMONIA VIRAL	11
2.2 COMO A COVID-19 E A PNEUMONIA VIRAL PODEM SER DETECTADAS EM IMAGENS DE RAIOS-X	11
2.3 MACHINE LEARNING E DEEP LEARNING	12
2.4 PYTHON, TENSORFLOW E KERAS	13
2.5 TRABALHOS RELACIONADOS	13
3 METODOLOGIA	14
3.1 FERRAMENTAS	15
3.1.1 GOOGLE COLABORATORY	15
3.2 DATASET	15
3.3 REDES NEURAIS CONVOLUCIONAIS	15
3.4 MODELO	16
3.5 TÉCNICAS E ARQUITETURAS UTILIZADAS	17
4 RESULTADOS	18
5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	21
REFERÊNCIAS	23
GLOSSÁRIO	25

1 INTRODUÇÃO

Na atualidade, devido às mais variadas informações, discute-se com frequência sobre as inteligentes máquinas que estão aptas a sobrelevar as habilidades humanas. De acordo com Da Silva Júnior et al. (2021), comumente, são utilizadas técnicas de Aprendizado de Máquina (AM) em bastante quantidade de dados para concluir deduções no auxílio à tomada de decisões, encontrar soluções para problemas de diferentes domínios e por fim apresentar bons resultados.

Em 1956 a Inteligência Artificial (IA) começou a ser identificada como uma ciência, onde a partir da proporção e da evolução do hardware e do software, aumentou-se a utilização de algoritmos inteligentes, como por exemplo, as redes neurais para problemas de reconhecimento facial e de classificação de imagens (FALCÃO et al., 2019) e ela pode ser muito útil na classificação e identificação de imagens médicas, pois possui uma grande capacidade e velocidade na manipulação dos dados, por meio da utilização Deep Learning e das várias técnicas para analisar e processar esses dados (DE MESQUITA et al., 2022). Os pulmões, nas imagens de raio-x de pacientes com coronavírus são normalmente os mais afetados e que existe uma necessidade muito grande de se detectar de forma ágil e eficaz o, sendo a inteligência artificial (IA) uma contribuinte nessa questão, através de modelos de aprendizagem profunda (DE MESQUITA et al., 2022).

A pandemia causada pelo vírus SARS-CoV-2 resultou em mais de 555 milhões de casos confirmados e mais de 6,35 milhões de mortes em todo o mundo, eclodindo uma epidemia massiva, com um efeito significativo na saúde e na vida de muitas pessoas em todo o mundo. De acordo com Celuppi (2021), a pandemia fez com que houvesse uma revolução no setor da tecnologia por conta do distanciamento social, demandando novas estratégias e adequação dos serviços para a atuação frente à realidade enfrentada. O diagnóstico de pessoas contaminadas com o coronavírus (COVID-19) é de grande importância, para que se dê início aos procedimentos necessários em relação ao tratamento, bem como o alastramento da doença, pois ela possui uma alta taxa de infecciosidade e mortalidade (SOUZA, 2020).

A diversa quantidade de aplicações de Deep Learning possibilita explorar diversos tipos de dados, que vão desde imagens comuns até imagens acústicas, sísmicas, de satélites, infravermelhas, magnéticas, etc (FALCÃO et al., 2019). Atualmente, embora estejamos vivendo em um mundo onde a tecnologia esteja cada vez mais presente e o diagnóstico por imagem tenha se expandido, muitos exames se tornam muito caros e trabalhosos quando administrados.

Segundo Trombetta et al. (2020), uma opção para a identificação da COVID-19 é o exame comum de radiografia, onde imagens de tórax que podem diagnosticar doenças, são realizadas e analisadas por radiologistas para pesquisar indicadores visuais relacionados à infecção viral por SARS-CoV-2. Outra doença que acomete os pulmões e que pode ser diagnosticada através do exame de radiografia é a pneumonia, que pode ser causada por diversos tipos de vírus, como por exemplo, a pneumonia viral que possui fácil transmissão, de pessoa para pessoa através de secreções que podem ficar em objetos, tosse, ar, etc. Apesar de todos os avanços nas técnicas no diagnóstico bem como no tratamento, as pneumonias ainda são uma das principais causas de morte em países desenvolvidos e a pneumonia viral apresenta um aumento considerável em relação ao número de casos que variam

entre leves e extremamente graves (DA SILVA MELO; DE FREITAS CARNAÚBA, 2021).

Com doenças como o SARS-CoV-2 e Pneumonia Viral, a velocidade do diagnóstico pode significar salvar vidas. Busca-se melhorar o diagnóstico por imagem por meio da tecnologia Deep Learning, facilitando a classificação e agindo de forma assertiva sobre a leitura de imagens.

Na primeira parte deste trabalho, foi discutido como o SARS-CoV-2 e a Pneumonia Viral podem ser detectadas em radiografias de tórax de pacientes, como foram revisados os conjuntos de dados e em seguida, foi abordado como treinar um modelo de aprendizado profundo usando o TensorFlow e Keras para prever o SARS-COV-2 e Pneumonia Viral no conjunto de dados de imagens de raio-x de pacientes. O objetivo deste trabalho consistiu em desenvolver e treinar um modelo de aprendizado profundo personalizado, avaliando arquiteturas de redes neurais convolucionais, para determinar em qual das classes o pulmão do paciente se enquadra: covid, normal ou pneumonia viral em um conjunto de dados de imagens de raio-x, utilizando a linguagem de programação Python com Tensorflow, Keras e Deep Learning.

2 REFERENCIAL TEÓRICO

2.1 SARS-COV-2 E PNEUMONIA VIRAL

A COVID-19 provou estar entre as mais perigosas doenças que representam uma grave ameaça para a civilização humana. Segundo a Organização Pan-Americana da Saúde (2022), A COVID-19, é uma doença causada pelo coronavírus SARS-CoV-2, tendo na lista dos principais sintomas: febre, tosse seca e cansaço. “O SARS-COV-2 apresenta um quadro clínico que varia de infecções assintomáticas a quadros respiratórios graves.” (DA SILVA DANTAS et al., 2020, p.166) e foi classificado pela Organização Mundial da Saúde (OMS) como pandemia.

A pneumonia viral é basicamente um tipo de infecção que atinge os pulmões e que é provocada por vírus, geralmente os mesmos que causam gripes e resfriados, ou mesmo o SARS-CoV-2. É uma doença que pode agredir a região dos alvéolos pulmonares (partes minúsculas que formam a menor unidade funcional do aparelho respiratório), levando a inflamação e resultando no surgimento dos sintomas, como: tosse, febre e falta de ar, que com o passar do tempo, tendem a piorar e que geralmente acomete mais as pessoas que têm um sistema imunológico fraco, como por exemplo idosos e crianças.

2.2 COMO A COVID-19 E A PNEUMONIA VIRAL PODEM SER DETECTADAS EM IMAGENS DE RAIOS-X

O surgimento da doença do coronavírus (COVID-19) causou um surto internacional de doenças respiratórias e em casos graves, a infecção pode causar pneumonia, dificuldade respiratória, falência de múltiplos órgãos e morte. Islam et al., (2021) explica que com a evolução da tecnologia moderna nas últimas décadas, soluções engenhosas foram criadas para facilitar o diagnóstico, a prevenção e o controle que alavancam ferramentas e instalações inteligentes de saúde.

Ainda de acordo Islam et al., (2021):

“A Inteligência Artificial (IA), tem se tornado muito popular em aplicações médicas, sendo uma tecnologia de software em evolução da tecnologia tem ajudado a combater o novo coronavírus cientificamente fornecendo resultados de diagnóstico de alta qualidade e dramaticamente reduzindo ou eliminando o poder do homem. ” (ISLAM et al., 2021, p. 30551, tradução nossa).

Pesquisadores descobriram que os pulmões de pacientes com sintomas de COVID-19 têm algumas marcas visuais, como opacidades em vidro fosco (padrão que é frequentemente observado em Tomografia do tórax), manchas escurecidas que podem diferenciar pacientes infectados com COVID-19 de não infectados com COVID-19.

Técnicas de aprendizado profundo são capazes de explicar problemas complexos aprendendo com representações simples. Ao usar redes multicamadas de Deep Learning, classificamos as imagens do tórax como positivas ou negativas para covid, pneumonia viral ou sem doença. “As técnicas de deep learning provaram ser uma ferramenta poderosa no arsenal utilizado pelos clínicos para o diagnóstico automático da COVID-19. ” (ISLAM et al., 2021, p.30551, tradução nossa). Um algoritmo inteligente tem como uma de suas principais características, a capacidade de aprender com a experiência e, depois de calibrado, ser capaz de classificar objetos do mundo real de forma automática e precisa (FALCÃO et al., 2019).

2.3 MACHINE LEARNING E DEEP LEARNING

O Machine learning (Aprendizado de Máquina), é um ramo da inteligência artificial (IA) e da ciência da computação que se atribui ao método em que os computadores aprendem, desenvolvem reconhecimento e identificação de padrões, fazem previsões com base em dados, bem como a tomada de decisões sem a intervenção humana, a partir de um conjunto de dados para execução de uma determinada tarefa.

Os computadores fazem abstração de padrões, exercendo assim suas próprias funções podendo realizar a predição ou classificação de determinado conjunto de dados (DA MATA RIBEIRO; QUIMARÃES, 2018). A aprendizagem de máquina se divide em categorias diferentes, e são citadas como as mais importantes à aprendizagem supervisionada, onde é advertido ao algoritmo qual é a resposta para determinado problema, e a aprendizagem não supervisionada, onde o algoritmo é o responsável por encontrar um padrão a ser seguido para adquirir uma resposta (ROSA et al., 2018).

O Deep learning (Aprendizado Profundo), por sua vez, trata-se de Redes Neurais Artificiais, busca simular computacionalmente de maneira mais natural, o cérebro enquanto máquina de aprendizado, a partir da configuração dos parâmetros básicos sobre os dados para que a máquina aprenda sozinha através do reconhecimento de padrões em diversas camadas de processamento e, suas principais características são a capacidade de aprender as representações exatas e os dados de maneira profunda, onde várias camadas são utilizadas sequencialmente. É um modelo de aprendizado de máquina que é capaz de concluir tarefas complexas, como por exemplo: previsões, identificação, classificando imagens (DAMACENO et al., 2018).

Com relação a Machine Learning e Deep Learning, Damaceno et al. (2018), diz que:

Estudos atuais na área de Inteligência Artificial, Machine Learning e Deep Learning andam de mãos dadas e podem ser categorizados em esferas. A relação entre Deep Learning e Machine Learning pode ser entendida com o Deep Learning, substituindo a intervenção humana, para prover dados de entrada para o Machine Learning. Isso torna expressamente claro que o conceito de Deep Learning é herdado do Machine Learning (DAMACENO et al., 2018).

Em geral, os sistemas baseados em aprendizado profundo são compostos por várias etapas, como: coleta de dados, preparação de dados, extração e classificação de recursos e avaliação de desempenho. A principal etapa do diagnóstico COVID-19 baseado em deep learning é a extração e classificação de recursos, etapa onde se extrai automaticamente o recurso realizando várias operações repetidamente e, por fim, a classificação é feita com base em rótulos de classe.

2.4 PYTHON, TENSORFLOW E KERAS

O Python é uma linguagem de programação de sintaxe simples, concisa e dinâmica que tem se expandido muito nos últimos anos. Contando com uma grande comunidade de colaboradores, é uma linguagem acessível para resolver diversos tipos de problemas em diferentes domínios, permitindo também trabalhar-se com vários paradigmas, oferecendo uma prototipagem rápida ideal para análise de dados e aprendizagem de máquina (DA SILVA; VIEIRA, 2022).

Ele se tornou uma das linguagens de programação mais conhecidas para a construção de sites, com vários frameworks, onde podem ser escritos programas ou scripts para automatização de tarefas de maneira rápida, que avançou uma grande comunidade de processamento científico e análise de dados, com processamento interativo, visualização de dados e construção de aplicações de dados (MCKINNEY, 2019).

O Tensorflow (TF) é uma plataforma de código aberto para machine learning, desenvolvida e mantida pela Google na linguagem python. A plataforma consegue trabalhar com CPU e GPU, permitindo operação com tensores de modo eficiente (DA SILVA; VIEIRA, 2022) e que vem facilitando a criação de modelos móveis de aprendizado de máquina tanto para iniciantes quanto para especialistas para desktop, dispositivos, Web e nuvem (TENSORFLOW, 2022). Segundo o autor Da Mata Ribeiro e Quimarães (2018), o TensorFlow vem crescendo bastante devido ao fato do seu desempenho por utilizar XLA, o que torna a execução mais rápida, e que ele pode ser aplicado em diversas situações, como reconhecimento de imagens e na incorporação de palavras, tendo como maior benefício à sua abstração.

O Keras é a API de alto nível do Tensorflow escrita em Python para criar e treinar modelos de aprendizado profundo com foco em possibilitar prototipagem rápida. É uma biblioteca de redes neurais de alto nível, desenvolvida com foco em permitir testes rápidos, tendo como sua estrutura de dados central um modelo, uma forma de organizar as camadas (KERAS, 2022). Possui uma interface simples e

otimizada para casos comuns, facilitando a criação de um modelo de redes neurais profundas de mais fácil entendimento (DA MATA RIBEIRO; QUIMARÃES, 2018).

2.5 TRABALHOS RELACIONADOS

O trabalho de Altmayer et al. (2020), sugere que quase 90% dos pacientes hospitalizados apresentam achados anormais na TC de tórax, com opacidades em vidro fosco (GGO) como uma das mais comuns resultados relatados em tomografias computadorizadas de pacientes com COVID-2019 e faz uma comparação, revisão e meta-análise dos achados da tomografia computadorizada (TC) do tórax de coronavírus e outras pneumonias virais para avaliar se algum recurso de imagem discriminatório pode ajudar a distinguir o COVID-19 de outras doenças respiratórias. Para o diagnóstico em radiologia e desenvolvimento das ferramentas com inteligência artificial baseado em máquina, os bancos de dados e os registros de imagens são primordiais.

De Souza Leão et al. (2020), discorre em seu trabalho sobre as diferentes formas que as redes de convolução são usadas para diferenciar Pneumonia causada por Covid de Pneumonia causada por outras doenças, a partir de imagens de raio-x. Dentre os tipos de radiografias que são comumente utilizados na medicina estão as imagens de tomografias computadorizadas e também o raio-x, sendo estas essenciais para o tipo de diagnóstico por meio de algoritmos de machine learning (DE SOUZA LEÃO et al., 2020). Para a abordagem do trabalho, os métodos investigados foram adquiridos a partir de CNNs com e sem transferência de aprendizado e os problemas de classificação em duas classes e três classes.

De Mesquita et al. (2022), apresenta em seu trabalho a análise comparativa de redes neurais convolucionais, a partir do uso de uma ferramenta de teste alternativo como identificador, utilizando-se de imagens de raio-x do tórax para que seja feita a classificação dos pacientes com COVID-19. De acordo com Trombetta et al. (2020), a descoberta de pneumonia a partir de radiografias de tórax, é uma tarefa que depende muito de radiologistas especializados, e seu trabalho sugere como objetivo, o desenvolvimento de um sistema que seja capaz de realizar o diagnóstico de imagem automático através da aplicação de Deep Learning, utilizando-se de redes neurais convolucionais.

Rossi et al. (2022), aponta em seu trabalho como são utilizadas as arquiteturas de redes neurais convolucionais e algoritmos de aprendizado profundo para detectar as doenças: Crestamento Bacteriano, Míldio, Oídio e Murcha de Sclerotium em recortes de imagens de folhas de soja, usando imagens coloridas de folhas para o treinamento e as técnicas de ajuste fino, Transfer Learning e a base de dados ImageNet para reconhecimento de objetos visuais nas arquiteturas: Vgg16, ResNet50, DenseNet121, InceptionV3 e EfficientNetB7.

3 METODOLOGIA

Para a realização deste estudo foram utilizadas as tecnologias de desenvolvimento de código aberto TensorFlow e Keras. Para a implementação, foi escolhida a linguagem de programação Python. As arquiteturas de redes neurais convolucionais utilizadas no presente trabalho foram: VGG16, RESNET50 e VGG19, onde o treinamento das mesmas foi executado em uma máquina virtual (VM) fornecida pelo Google Colaboratory (Colab).

Esta pesquisa foi classificada como exploratória e objetiva, onde a parte introdutória consistiu em obter-se maior conhecimento sobre o problema e a sua abordagem foi classificada como quantitativa. O trabalho teve como intuito, fazer o levantamento e revisão da literatura, fontes e autores que tratam sobre o tema, bem como a decisão dos métodos, estudo da linguagem para o desenvolvimento da aplicação, estudando e aplicando tecnologias relacionadas à inteligência artificial, aplicação do Deep Learning onde a partir da base de dados, foram utilizados algoritmos na criação e treinamento do modelo para assim ser possível a exploração da relação entre os dados, identificação de padrões e previsões para novos dados, utilizando-se da arquitetura de rede neural convolucional em suas diferentes arquiteturas para avaliação, aplicadas na classificação das imagens de raio-x dos pulmões de pacientes, podendo por fim, ser feita a partir do modelo treinado, a identificação e classificação no conjunto das imagens de cada uma das três classes (Covid, Normal e Pneumonia Viral) com base em qual probabilidade é maior.

3. 1 FERRAMENTAS


3.1.1 Google Colaboratory

Para realização do treinamento dos modelos, foi utilizado o ambiente Colaboratory ou “Colab” que é um produto do Google Research que concede que qualquer pessoa, seja ela um estudante, um pesquisador de IA, um cientista de dados, etc, escreva e execute seu código Python na conta do seu navegador, não havendo nenhuma configuração necessária para isso, o que pode dessa maneira estar facilitando o seu trabalho. É indicado principalmente para análise de dados, aprendizado de máquina, sendo um serviço de notebooks hospedados do Jupyter, oferecendo recursos como GPUS sem custo financeiro, permitindo também a combinação de código executável e rich text (texto rico) em um só documento, sendo estes guardados na conta do Google Drive (COLAB, 2022).

3.2 Dataset

A Figura 01 representa um resumo do fluxo de um problema de classificação, onde para se treinar um modelo de identificação e classificação de imagens é de suma importância possuir uma boa base de dados. O dataset na visão computacional são imagens selecionadas para que o sistema possa treinar, bem como testar a performance dos seus algoritmos de reconhecimento de objetos.

Figura 01 - Resumo do fluxo de problemas de classificação.



Fonte: Autoria Própria (2022).

Para a realização deste projeto foi utilizado um Dataset (conjunto de dados) disponíveis no Kaggle, plataforma de acesso público (<https://www.kaggle.com>), onde é possível encontrar mais de 50.000 datasets públicos, oferecendo suporte a vários formatos de publicação, desafios de concorrentes em estágios distintos na carreira do Machine Learning, tendo assim uma multiplicidade de resultados. O Kaggle permite que seus usuários acessem uma ampla variedade de conjuntos de dados em um ambiente baseado na web.


3.3 REDES NEURAIAS CONVOLUCIONAIS

Uma rede Neural é modelo preditivo, incentivado pela maneira pela qual o cérebro funciona, consistindo-se em neurônios artificiais que desenvolvem cálculos parecidos sobre as suas entradas, o que pode ajudar na resolução de problemas com aprendizado profundo, área bastante popular em data science (GRUS, 2019). As redes neurais são baseadas no processamento de dados visuais e geralmente são utilizadas em aplicações de identificação, análise e classificação de imagens e vídeos (CHAVES, 2019). “As Redes Neurais podem ser executadas em paralelo. A paralelização permite a aceleração de computação em massa de unidades de processamento gráfico.” (SHORTEN; KHOSHGOFTAAR; FURHT, 2021, p.10, tradução nossa), não sendo em si um algoritmo propriamente dito, mas sim uma estrutura onde diferentes algoritmos de machine learning reúnem entradas de dados, para trabalharem juntos e assim realizarem determinados processos (FALCÃO et al., 2019).

Redes convolucionais são modelos compostos por uma grande quantidade de parâmetros, relacionados das mais variadas formas e não possuem explicação natural para os resultados obtidos (SOUZA, 2020). Elas possuem uma grande quantidade de tipos de dados, podendo ser aplicadas em diferentes domínios: detecção de padrões, reconhecimento de objetos, padrões em áudio, tratamento de linguagem natural, etc (DA SILVA; VIEIRA, 2022). Estas redes vieram para facilitar a identificação de imagens em tarefas de visão computacional e hoje, com a propagação do coronavírus, há uma grande necessidade de maximizar os esforços no que diz respeito a testes precisos.

Entre as camadas convolucionais, são encaixadas as camadas de pooling que reduzem o tamanho das matrizes que contêm a informação que está sendo computada, fazendo com que o número de parâmetros que irão ser contados naquele ponto em diante reduza, ajuda na prevenção do overfitting (quando o modelo aprende demais), utilizando em cada camada do volume de saída da camada uma operação de sumarização (ROSSI et al., 2022).

Figura 02 - Funcionamento básico de uma CNN: camada de convolução.



Fonte: De Mesquita et al., (2022).


A Figura 02 representa o funcionamento de uma rede neural convolucional: imagem de entrada, 1ª camada de convolução onde há a extração das características da imagem, 1ª camada de pooling onde há a redução da dimensionalidade da imagem, 2ª camada de convolução onde há extração de mais características da imagem, 2ª camada de pooling onde há mais redução da dimensionalidade da imagem e em seguida tem-se a camada totalmente conectada que é onde começa o aprendizado da rede, havendo a conversão das características mapeadas a partir das informações coletadas pelas camadas anteriores e por fim a classificação da imagem com base em qual probabilidade é maior de ser de uma respectiva classe ou de outra.

3.4 MODELO

Para o treinamento do modelo, foram utilizadas imagens de radiografia de tórax de pacientes com covid-19, pneumonia viral e de pacientes saudáveis. Estas imagens foram obtidas em um conjunto de dados disponível no Kaggle.

O primeiro conjunto de imagens contém as seguintes classes de imagens: Covid e Normal. O dataset utilizado, foi selecionado com (2000) imagens pertencentes a duas classes: Classe 0) COVID: 1000 imagens; Classe 1) NORMAL: 1000 imagens, sendo 70% destas para treino e as outras 30% para teste.

Figura 03 - Imagens de raio-x de pulmão com covid e pulmão normal.




Fonte: Kaggle (2022).

A Figura 03 representa, à esquerda, exemplo de raio-x de pulmão comprometido com covid e a direita, um exemplo de raio-x de pulmão sem doença.

O segundo conjunto de imagens contém as seguintes classes de imagens: Covid, Normal e Pneumonia Viral. O dataset utilizado, foi selecionado com (3000) imagens pertencentes a três classes: Classe 0) COVID: 1000 imagens; Classe 1) NORMAL: 1000 imagens, Classe 2) PNEUMONIA: 1000 imagens, sendo 70% destas para treino e as outras 30% para teste.

Figura 04 - Imagens de raio-x de pulmão com covid, pulmão normal e com pneumonia viral.



Fonte: Kaggle (2022).


A Figura 04 representa, à esquerda, exemplo de raio-x de pulmão comprometido com covid, no meio raio-x de pulmão sem doença e a direita raio-x de pulmão comprometido com pneumonia viral.

3.5 TÉCNICAS E ARQUITETURAS UTILIZADAS

Para este estudo, foram utilizadas na avaliação do desempenho das redes neurais convolucionais para a classificação de doenças no conjunto de imagens, as seguintes arquiteturas as quais serviram como base na criação do modelo de treinamento: VGG16, RESTNET50 e VGG19.

A arquitetura da VGG utiliza-se de filtros menores, redes profundas e camadas que são densamente conectadas: VGG16 e VGG19 enquanto a RESNET50 faz um curto-circuito a cada duas convoluções onde: quanto mais camadas utilizadas, menor a chance de se ter erros.

Figura 05 - CNNs na classificação de imagens.



Fonte: Autoria própria (2022).


Para o treinamento do modelo nas diferentes arquiteturas, os hiperparâmetros utilizados se conservaram iguais, com exceção da quantidade de classes: `image_size = [150, 150]`, `epochs = 25`, `batch_size = 32`, `input_shape = (150,150,3)`, `random_state = 42` `alpha = 1e-5`, `classes = 2` (classificação binária) e 3 (classificação de múltiplas classes). Tratando-se de problemas de classificação binária e de múltiplas classes, foram selecionadas como camada de saída a função sigmoid e como função de custo binary crossentropy para os datasets com duas classes e para os datasets com três classes foram selecionadas como camada de saída a função softmax e como função de custo categorical crossentropy, ambas compiladas com o otimizador Adaptive Moment Estimation (ADAM).

Foram utilizados callbacks com a classe ModelCheckpoint para ajudar a salvar o modelo para cada época evitando que o progresso fosse perdido caso houvesse travamento da máquina, e a classe ReduceLROnPlateau para auxiliar na taxa de redução de aprendizado caso o modelo parasse de melhorar, Data augmentation (aumento da quantidade de dados), ImageDataGenerator aumentando as imagens em tempo real durante o treinamento do modelo e Tranfer Learning para a transferência de aprendizado entre as redes neurais, armazenando o que aprendeu para a aplicação em um problema relacionado.

4 RESULTADOS


De acordo com os resultados obtidos, serão apresentados a seguir, os gráficos de desempenho, de perda e as matrizes de confusão nas etapas de treinamento e teste dos modelos nas diferentes arquiteturas das CNNs. O primeiro conjunto de imagens contém as seguintes classes de imagens: Covid e Normal.

Figura 06 - Acurácia de treino e teste nos modelos treinados.




Fonte: Autoria própria (2022).

Figura 07 - Perda de treino e teste nos modelos treinados.



Fonte: Autoria própria (2022).

Figura 08 - Matriz de Confusão dos modelos treinados.



Fonte: Autoria própria (2022).

A Figura 08 mostra as matrizes de confusão das arquiteturas testadas onde são mostradas: na vertical as classes verdadeiras; na horizontal as classes previstas em classes de: verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP), ou falsos negativos (FN); na diagonal os acertos referentes aos testes feitos a partir do modelo treinado. Foram testadas 300 imagens em todas as pastas. O modelo com a arquitetura Vgg16 acertou 292 imagens de raio-x com SARS-CoV-2 e 297 imagens com raio-x normal. O modelo da ResNet acertou 293 imagens de raio-x com SARS-CoV-2 e 288 imagens com raio-x normal. Já o modelo da Vgg19 acertou 299 imagens de raio-x com SARS-CoV-2 e 296 imagens com raio-x normal.


Tabela 01 - Acurácia, Precisão, Sensibilidade e Especificidade dos modelos aplicados nas diferentes arquiteturas.

Arquitetura	Classes	Acurácia	Precisão	Sensibilidade	Especificidade
Vgg16	Covid Normal	98.17%	98.98%	97.33%	99.00%
ResNet50	Covid Normal	96.83%	96,06%	97.66%	96.00%
Vgg19	Covid Normal	99.17%	98.67%	99.66%	98.66%

Fonte: Autoria Própria (2022).


A Tabela 01 mostra que para as métricas de acurácia e de sensibilidade, o modelo da vgg19 obteve o melhor resultado, para as métricas de precisão e especificidade o modelo da vgg16 obteve o melhor resultado e quanto o modelo da ResNet50 este obteve resultados inferiores em todas as métricas avaliadas. A seguir, serão apresentados, os gráficos de desempenho, de perda e as matrizes de confusão nas etapas de treinamento e teste dos modelos nas diferentes arquiteturas das CNNs. O segundo conjunto de imagens contém as seguintes classes de imagens: Covid, Normal e Pneumonia.

Figura 09 - Acurácia de treino e teste nos modelos treinados.




Fonte: Autoria Própria (2022).

Figura 10 - Perda de treino e teste nos modelos treinados.



Fonte: Autoria Própria (2022).

Figura 11 - Matriz de Confusão dos modelos treinados.



Fonte: Autoria Própria (2022).

A Figura 11 mostra as matrizes de confusão das arquiteturas testadas onde são mostradas: na vertical as classes verdadeiras; na horizontal as classes preditas em classes de: verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP), ou falsos negativos (FN); na diagonal os acertos referentes aos testes feitos a partir do modelo treinado. Foram testadas 300 imagens em todas as pastas. O modelo com a arquitetura Vgg16 acertou 286 imagens de raio-x com SARS-CoV-2, 282 imagens de raio-x normal e 274 imagens de raio-x com pneumonia viral. O modelo da ResNet acertou 291 imagens de raio-x com SARS-CoV-2, 264 imagens com raio-x normal e 262 imagens de raio-x com pneumonia viral. Já o modelo da Vgg19 acertou 291 imagens de raio-x com SARS-CoV-2, 279 imagens de raio-x normal e 274 imagens de raio-x com pneumonia viral.

Tabela 02 - Resultados da Acurácia dos modelos aplicados nas diferentes arquiteturas.

Arquitetura	Classes	Total de Imagens Testadas	Número de Acertos	Número de Erros	Total de erros arquitetura	Acurácia
Vgg16	Covid	300	286	14	58	93.56%
	Normal	300	282	18		
	Pneumonia	300	274	26		
ResNet50	Covid	300	291	9	83	90.78%
	Normal	300	264	36		
	Pneumonia	300	262	38		
Vgg19	Covid	300	291	9	56	93.78%
	Normal	300	279	21		
	Pneumonia	300	274	26		

Fonte: Autoria Própria (2022).

A Tabela 02 mostra que para a métrica de acurácia o modelo da vgg19 obteve o melhor resultado, tendo o resultado do modelo da vgg16 como bem próximo e quanto o modelo da ResNet50, este obteve um resultado inferior em relação aos outros modelos já mencionados.

5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Com base nos resultados obtidos apresentados neste trabalho, conclui-se que um modelo de treinamento, com Tensorflow e Keras utilizando aprendizado profundo pode ser capaz de aprender e identificar padrões, demonstrando que é concebível o uso de redes neurais convolucionais na classificação de imagens. Avaliando de maneira geral, o modelo de treinamento com a arquitetura da VGG19 como base, possuindo 19 camadas de perspicácia, foi o que obteve o melhor desempenho na identificação e classificação de imagens de raio-x de pulmões com covid ou pneumonia viral no conjunto de imagens testadas, visto que em relação ao total de imagens testadas a sua taxa percentual de acerto foi superior e a sua taxa de erros foi inferior às das demais arquiteturas testadas.

A partir da análise desse estudo, opções viáveis podem ser estudadas e aplicadas em trabalhos futuros, como o desenvolvimento de um sistema web ou mobile para realização de testes tendo como base o modelo treinado para que a partir de um upload de uma imagem de raio-x de pulmão de um paciente o modelo gere um possível pré-diagnóstico, bem como novos testes em modelos utilizando da biblioteca scikit-learn para se trabalhar com classificação, mineração e análise de dados em aprendizado de máquina, já que a mesma apresenta uma grande diversidade em relação a algoritmos integrados.

REFERÊNCIAS

ALTMAYER, Stephan et al. Comparison of the computed tomography findings in COVID-19 and other viral pneumonia in immunocompetent adults: a systematic review and meta-analysis. **European radiology**, v. 30, n. 12, p. 6485-6496, 2020.

CELUPPI, Ianka Cristina et al. Uma análise sobre o desenvolvimento de tecnologias digitais em saúde para o enfrentamento da COVID-19 no Brasil e no mundo. **Cadernos de Saúde Pública**, v. 37, 2021.

CHAVES, Esdras de Lima. Detecção de câncer de mama por meio de imagens infravermelhas utilizando Redes Neurais Convolucionais. 2019.

COLAB, G. Google Colab. 2022. Disponível em: <<https://colab.research.google.com/>>.

DA MATA RIBEIRO, Maxwell; QUIMARÃES, Samuel Soares. Redes neurais utilizando tensorflow e keras. **RE3C-Revista Eletrônica Científica de Ciência da Computação**, v. 13, n. 1, 2018.

DA SILVA, Josenildo C.; VIEIRA, Raimundo Osvaldo. Introdução às Redes Neurais Profundas com Python. **Sociedade Brasileira de Computação**, 2022.

DA SILVA DANTAS, Dalyane Laís et al. COVID-19: conceito, etiologia e terapia nutricional. **Diálogos em Saúde**, v. 3, n. 1, 2020.

DA SILVA JUNIOR, Antonio Carlos et al. Geração de dados sintéticos para classificação de disléxicos por meio de aprendizado de máquina. **Journal of Health Informatics**, v. 13, n. 1, 2021.

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

DAMACENO, Siuari Santos et al. Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular. **Caderno de Graduação-Ciências Exatas e Tecnológicas-UNIT-SERGIPE**, v. 5, n. 1, p. 11-11, 2018.

DE MESQUITA, Iago Magalhães et al. Análise comparativa entre redes neurais convolucionais para classificação de pacientes com Covid-19 Comparative analysis between convolutional neural networks for classification of patients with Covid-19. **Brazilian Journal of Health Review**, v. 5, n. 2, p. 5165-5180, 2022.

DE SOUZA LEÃO, Pedro Paulo et al. Detecção de Covid-19 em Imagens de Raios-x Utilizando Redes Convolucionais. **Journal of Health Informatics**, v. 12, 2020.

FALCÃO, João Vitor Regis et al. Redes Neurais Deep Learning com Tensorflow. **RE3C-Revista Eletrônica Científica de Ciência da Computação**, v. 14, n. 1, 2019.

GRUS, Joel. **Data Science do zero: Primeiras regras com o Python**. Alta books, 2019.

ISLAM, Md Milon et al. A review on deep learning techniques for the diagnosis of novel coronavirus (COVID-19). **Ieee Access**, v. 9, p. 30551-30572, 2021.

KAGGLE. Kaggle. 2022. Disponível em: <<https://www.kaggle.com/>>. Acesso em: 23 de Julho de 2022.

KERAS. Keras. 2022. Disponível em: <<https://keras.io/>>. Acesso em: 15 de Novembro de 2022.

MCKINNEY, Wes. **Python para análise de dados: Tratamento de dados com Pandas, NumPy e IPython**. Novatec Editora, 2019.

OPAS - Organização Pan-Americana da Saúde. Folha informativa sobre COVID-19 Brasília (DF); 2022.

ROSA, Renan de Paula et al. Método de classificação de pragas por meio de rede neural convolucional profunda. 2018.

ROSSI, Rafael Zeferino et al. Análise de Redes Neurais Convolucionais para a classificação de doenças em folhas de soja Analysis of Convolutional Neural Networks for diseases classification in soybean leaves. **Brazilian Journal of Development**, v. 8, n. 6, p. 47914-47933, 2022.

SHORTEN, Connor; KHOSHGOFTAAR, Taghi M.; FURHT, Borko. Deep Learning applications for COVID-19. **Journal of big Data**, v. 8, n. 1, p. 1-54, 2021.

SOUZA, Matheus Paes de. Explicabilidade de modelos de visão computacional aplicados à detecção de COVID-19 em radiografias. 2020.

TENSORFLOW. TensorFlow. 2022. Disponível em: <<https://www.tensorflow.org/>>.

TROMBETTA, Giordano Brunno Wagner et al. Aplicação de Deep Learning para Diagnóstico de Pneumonia Causada por COVID-19 a partir de Imagens de Raio X. **Journal of Health Informatics**, v. 12, 2020.

GLOSSÁRIO

Acurácia: performance geral do modelo, no caso os acertos (positivos ou negativos) do modelo ao classificar as classes.

Alpha: taxa de aprendizado, indica a que ritmo os pesos são atualizados. Isso pode ser fixado ou alterado de modo adaptativo.

Batch_size: número de exemplos de treinamento usados em uma interação.

Callbacks: funções que auxiliam no treinamento de modelos usando o Keras.

Epochs: número de vezes que os dados da rede neural serão exibidos, esperando que o resultado apresente um conjunto de pesos bem ajustados.

Especificidade: equivale a porcentagem de amostras negativas apontadas corretamente pelo modelo sobre o total de amostras negativas.

Falso negativo (FN): o modelo prediz que a classe é negativa, mas a classe é positiva.

Falso positivo (FP): o modelo prediz que a classe é positiva, mas a classe é negativa.

Matriz de Confusão: tipo de tabela que representa o desempenho de um algoritmo de classificação.

Precisão: define, a partir dos testes classificados como positivos pelo modelo, quantos eram realmente verdadeiros.

Random_state: parâmetro usado para que os valores do treino fiquem aleatórios para aprender os métodos.

Sensibilidade: avaliação dos acertos nos resultados classificados como positivos.

Verdadeiro negativo (VN): o modelo prediz que a classe é negativa e a classe é realmente negativa.

Verdadeiro positivo (VP): o modelo prediz que a classe é positiva e a classe é realmente positiva.