

Uso de uma Rede Neural Convolutacional para análise de raios-x de pulmão com detecção de covid-19, pneumonia e tuberculose

Camila Munzlinger¹, Igor Yepes¹

¹Instituto Federal de Educação, Ciência e Tecnologia Farroupilha (IFFar)
Campus Frederico Westphalen
Caixa Postal 169 – 98.400-000 – Frederico Westphalen – RS – Brasil

camila.2019001356@aluno.iffar.edu.br,

igor.yepes@iffarroupilha.edu.br

Resumo. *Devido à grande demanda de diagnósticos e laudos requeridos, à sobrecarga de horas de trabalho e à falta de tempo para a realização de um atendimento coerente com as necessidades dos pacientes, o período de trabalho de um médico radiologista se mostra deveras árduo. Com isso em mente, este artigo visa apresentar um sistema baseado em IA (Inteligência Artificial) desenvolvido para auxiliar os profissionais radiólogos na sua rotina de trabalho, agilizando o diagnóstico e disponibilizando tempo ao radiologista para um atendimento mais humanizado. No estudo é desenvolvido um modelo de IA com capacidade de diagnosticar doenças pulmonares em imagens de raio-x, sendo elas covid-19, pneumonia e tuberculose. Para o desenvolvimento foram utilizadas a IDE do Google Colaboratory, a linguagem de programação Python, o modelo de redes neurais convolucionais e uma base de dados com imagens validadas para o treinamento da rede. Após o treinamento do modelo, este alcançou uma acurácia de 89% na realização do diagnóstico.*

1. Introdução

As doenças covid-19, pneumonia e tuberculose são infecções que afetam principalmente os pulmões. Estas doenças podem ser identificadas através de radiografia do tórax, para que dessa forma os médicos radiologistas possam analisar o exame radiológico e identificar se há a presença de alguma dessas infecções pulmonares no raio-x do paciente [DEZUBE 2021].

Com o surgimento da Covid-19, diversas instituições incentivam a pesquisa de algoritmos inteligentes para identificação de doenças através de raio-x. Na atualidade há a possibilidade de armazenar imagens de radiografias em bancos de dados *webservice*, possibilitando testar vários algoritmos diferentes com a mesma base de dados para obter resultados diferenciados.

Segundo [RICH 1988, WHITBY 2004] a Inteligência Artificial (IA) é o estudo realizado para que computadores executem tarefas que atualmente são realizadas por seres humanos, buscando uma forma de que o conhecimento e comportamento destes possa ser incorporado em qualquer tipo de artefato com uso da engenharia.

Cada vez mais vem sendo discutida e enfatizada a importância do computador na medicina e na saúde pública, sendo utilizado como um apoio à decisão médica, dessa

forma buscando maneiras de diminuir a dependência que os diagnósticos clínicos possuem dos exames complementares [LOBO 2017].

Na área da saúde encaixam-se os médicos radiologistas, foco deste estudo, que atuam com análise e interpretação das imagens de raios-X para poder diagnosticar e emitir laudos dos pacientes. Esses profissionais costumam lidar com picos de atendimentos que geram longas e desgastantes jornadas de trabalho, o que poderia ser reduzido com uma ferramenta de suporte ao processo decisório.

Nesse contexto, pesquisas para desenvolvimento de algoritmos de classificação de imagens vêm sendo aplicados na área da medicina no ramo da radiologia, para classificar doenças e proporcionar ao médico radiólogo um suporte para seus diagnósticos.

A realização deste trabalho visa desenvolver um sistema com Inteligência Artificial capaz de classificar dentro de uma faixa de 4 classes um raio-x do tórax, possibilitando o suporte aos radiologistas no momento de diagnosticar o raio-x do paciente, servindo como uma segunda opinião a ser considerada ao realizar a análise.

O restante deste artigo está organizado conforme descrito a seguir. A Seção 2 apresenta os objetivos para o desenvolvimento da pesquisa; na Seção 3 é realizada a contextualização do tema e dos problemas a serem solucionados; a Seção 4 apresenta a fundamentação teórica, apresentando o conceito de Inteligência Artificial e sua aplicação para a área de medicina, na radiologia. Ainda nessa seção, são descritos os trabalhos relacionados à mesma base de pesquisa; a Seção 5 traz as etapas metodológicas executadas neste trabalho; a Seção 6 apresenta o desenvolvimento do projeto juntamente com os resultados encontrados; por fim, a Seção 7 apresenta as considerações finais sobre o trabalho, sobre as ferramentas utilizadas e lista algumas possibilidades de trabalhos futuros.

2. Objetivos

2.1. Objetivo Geral

Utilizar os recursos disponíveis através de técnicas de Inteligência Artificial, para desenvolver um sistema capaz de diagnosticar doenças pulmonares (covid-19, pneumonia e tuberculose) em imagens de raio-x, dessa maneira, dando suporte aos profissionais radiólogos ao emitir seu diagnóstico.

2.2. Objetivos específicos

- Analisar bases de dados com imagens de raio-x para o treinamento da rede neural;
- Estudar o uso da inteligência artificial na detecção de imagens;
- Efetuar estudo sobre redes neurais convolucionais;
- Desenvolver o sistema para diagnóstico com base em imagens;
- Realizar o treinamento e os testes da rede neural;
- Verificar eficiência do sistema desenvolvido e a possibilidade de uso real.

3. Contextualização do tema/problema

Além da demora no tempo de resposta do resultado do raio-x, os profissionais radiólogos que possuem uma grande demanda na realização dos diagnósticos, também enfrentam a distração que o cansaço pode gerar após longos períodos de trabalho, acarretando

imprecisões em alguns laudos realizados ao final dessas jornadas [FONSECA 2021, FORTES 2020].

Por conta da grande demanda os radiologistas aceleram nos atendimentos apresentando o diagnóstico ao paciente e rapidamente passando para o próximo. A agilidade do tempo de resposta do sistema proposto pode liberar os profissionais para terem mais tempo para um atendimento humanizado, dessa maneira proporcionando ao médico tempo para uma conversa demonstrando interesse e preocupação com a questão emocional do seu paciente [PAGANO and CHIOCA 2018].

Com o uso de um sistema munido de Inteligência Artificial, que possa detectar com confiabilidade a presença da doença ainda em seu estado inicial, o médico radiologista pode dar início às medidas necessárias previamente a um estado avançado da doença. Isso também propicia a redução de consultas para o paciente, pois ao detectar precocemente a doença, reduz a exposição a exames adicionais de raio-x.

4. Fundamentação Teórica

Esta seção será subdividida em dois tópicos: saúde e computação. No primeiro tópico será apresentada uma breve descrição das doenças Covid-19, pneumonia e tuberculose, seus principais sintomas, como é efetuado o diagnóstico e a forma usual de tratamento. O segundo tópico abordará a parte computacional a ser utilizada no estudo, uma vez que a computação trouxe caminhos alternativos para a radiologia, como o uso de Inteligência Artificial para diagnosticar imagens de raio-x e tomografia computadorizada.

4.1. Saúde

4.1.1. Doenças

Doenças pulmonares podem ser ocasionadas por vários fatores. Segundo o ministério da saúde a Covid-19 é causada pelo novo coronavírus SARS-CoV-2, sendo uma infecção respiratória que atinge os pulmões. O SARS-CoV-2 é transmitido pelo contato com gotículas respiratórias contendo o vírus, expelidas por alguém que está próximo ou até partículas levadas pelo ar. O início dos sintomas varia de 1 a 14 dias após a contaminação. Os sintomas apresentados podem ser febre, cansaço, tosse seca, perda de paladar ou olfato, nariz entupido, conjuntivite, dor de garganta, dor de cabeça, dores nos músculos ou juntas, diferentes tipos de lesões na pele, náusea ou vômito, diarreia, calafrios ou tonturas, sendo que em quadros graves os infectados apresentam ainda a falta de ar, confusão mental, dor persistente ou pressão no peito e alta temperatura (acima de 38 °C) [CELUPPI et al. 2021].

Como apresentado pelo Ministério da saúde [BVS 2021] a Covid-19 tem a capacidade de gerar variantes, assim a vacinação é utilizada para diminuir os casos de hospitalizações, sendo fundamental tomar todas as doses da vacina.

Outra doença que produz uma infecção nos pulmões é a pneumonia. A Rede D'Or São Luiz afirma [REDE D'Or 2019] que a pneumonia inicia como uma simples gripe, e ao não ser tratada corretamente reduz as defesas do organismo, deixando-o vulnerável e permitindo a infiltração de bactérias, vírus e fungos que geram a inflamação da pneumonia.

De acordo com a biblioteca virtual em saúde os sintomas apresentados pela pneumonia são [VARELLA 2011] "... febre alta, tosse com catarro, dor no tórax, alterações da

pressão arterial, confusão mental, mal-estar generalizado, falta de ar, secreção de muco purulento de cor amarelada ou esverdeada, toxemia, prostração, cansaço e fadiga”.

Conforme a Agência Fiocruz [CAMPOS 2013], o diagnóstico da pneumonia é realizado a partir do histórico do paciente, de exames clínicos e de raios-x do tórax, e podem ser necessários outros exames complementares para identificar o agente causador da doença. Para realizar o tratamento das pneumonias é preciso o uso de antibióticos e o paciente geralmente melhora em três ou quatro dias. Algumas vezes é preciso ser realizada a internação hospitalar que pode ser necessária quando a pessoa é idosa, tem febre alta ou apresenta alterações clínicas resultantes da própria pneumonia, por exemplo, o comprometimento da função dos rins e da pressão arterial [VARELLA 2011].

Por último, a tuberculose é uma doença que afeta principalmente os pulmões; segundo a agência Fiocruz [ROLLA 2013] essa é uma doença infectocontagiosa transmitida pelas vias aéreas e é provocada geralmente pela bactéria *Mycobacterium tuberculosis*, ou também denominada bacilo de Koch. Os sintomas dessa doença são tosse forte e frequente, catarro às vezes com a presença de sangue, febre, dor no peito, falta de ar, cansaço e perda de apetite.

Para a realização do diagnóstico da tuberculose é efetuada a radiografia do tórax e exames laboratoriais de escarro do paciente (baciloscopia). O tratamento é feito à base de antibióticos e pode durar seis meses ou um ano [ROLLA 2013].

4.1.2. Radiologia

O médico radiologista é um especialista na área de radiologia. Conforme [MORSCH 2018] esse profissional, além de cursar medicina, precisa realizar residência médica em radiologia e diagnóstico por imagem. Ou seja, o médico capacitado possui conhecimentos em anatomia humana, tecnologias, formação e interpretação de imagens radiológicas, sendo também habilitado para efetuar a interpretação dos resultados de um exame radiológico.

A principal atuação de um médico radiologista é o diagnóstico por imagem. Segundo [MORSCH 2018], “Nessa área, o especialista realiza análise crítica de pedidos de exames radiológicos, indicações de técnicas e materiais utilizados, interpretação das imagens e conclusões, que são registradas no laudo médico.”. Os laudos emitidos são conclusões do médico através das informações da radiografia, juntamente com suspeitas do médico solicitante, dados clínicos e histórico do paciente.

As radiografias são realizadas por técnicos em radiologia. Para produzir uma imagem de raio-x, Flávio Pereira das Posses (coordenador da empresa médica Star) faz a seguinte explicação [POSSES 2020]:

Basicamente, o tubo de raio X emite um feixe de radiação que passa pelo corpo, sendo parcialmente absorvido de forma diferente por cada estrutura: os ossos absorvem mais, músculos e gordura absorvem menos, por exemplo. Os raios X não absorvidos atingem um receptor (o chassi radiográfico), gerando a imagem tal como ocorre com o filme em uma máquina fotográfica. A diferenciação dos tecidos se baseia nessa diferença de absorção do raio X.

Segundo [FONSECA 2021] “... um dos principais desafios enfrentados pelos profissionais de saúde é a necessidade de fluxos de trabalho mais seguros e estudos mais rápidos com sistemas mais inteligentes e personalizados que possam lidar com os picos de demanda.”. Ele também afirma que os softwares oferecidos para decisões clínicas fornecem para os médicos um fluxo de trabalho enxuto, rápido e otimizado.

Nesse sentido, um dos problemas mais comuns é a recorrência do atraso nas demandas. Segundo [FORTES 2020] atualmente existem filas para realização de exames radiográficos, o que acarreta o adiamento e atraso na emissão dos laudos. Esse problema surge quando a demanda de exames supera a capacidade de emissão de laudos dos médicos radiologistas gerando sobrecarga.

4.1.3. Tecnologias existentes

A [RadVid19 2020] apresenta a ação RadVid-19, realizada entre os radiologistas brasileiros apoiados pelo CBR, e tem como objetivo a coleta de exames de raio X e tomografia com confirmação ou suspeita de Covid-19. Relata que já houve a implementação de um algoritmo para realizar a análise de imagens de tomografias, gerando um relatório que pode ser acessado por um radiologista, com o intuito de auxiliar na tomada de decisão clínica, dando ênfase que a iniciativa será utilizada como suporte à decisão clínica, e não como substituição de um profissional. Assim como apontado também pela [IdeiaGov 2020], a RadVid-19 apoia o desenvolvimento de soluções tecnológicas e inovadoras para auxiliar o diagnóstico da Covid-19 através de imagens de exames de tomografia e raio-x.

Uma das opções para auxiliar a identificar a presença da Covid-19 é a utilização da radiografia do tórax, mas, assim como apontado por [SILVA et al. 2020] “...uma interpretação radiológica rápida de imagens nem sempre está disponível, particularmente nos locais com poucos recursos onde há uma alta taxa de mortalidade”. Por ser uma atividade complexa, o uso de técnicas de processamento de imagem combinadas a técnicas de aprendizado de máquina, traz aos médicos radiologistas um suporte para a identificação da presença de doenças nos raio-x.

Segundo [SILVA et al. 2020], atualmente existem várias pesquisas que utilizam a classificação de imagens para ajudar no diagnóstico precoce da tuberculose, da pneumonia, e na classificação de lesões através de radiografia torácica.

Conforme [BHARATI et al. 2020], atualmente há muitas pesquisas que propõem aprendizado de máquina para previsão de informações de diagnóstico de imagem de raios-x. Com o uso dos computadores e com a quantidade de dados de imagens disponíveis nos dias atuais, é o momento propício para reduzir custos médicos com a ampliação da informatização nos projetos de saúde e ciências médicas.

4.2. Computação

O sistema proposto neste trabalho inclui recursos e técnicas computacionais, classificados aqui como o conjunto de ferramentas para implementação, que engloba a linguagem de programação *Python* e o sistema colaborativo *Colab*; e técnicas de Inteligência Artificial, aqui representadas pelas Redes Neurais Convolucionais (ou *Convolutional Neural Network* - CNN).

4.2.1. Ferramentas para implementação

Python é uma linguagem de programação gratuita e capaz de ser utilizada em praticamente qualquer computador. As principais vantagens do *Python* são a legibilidade dos programas escritos, a baixa curva de aprendizagem e seu grande poder de programação, permitindo obter resultados efetivos em pouco tempo. Essa linguagem contém várias bibliotecas, o que permite que o programador se concentre em resolver o problema e utilize os recursos já disponíveis [MENEZES 2010].

Como apresentado por [CARNEIRO et al. 2018], o *Colab* é um serviço em nuvem disponibilizado pela *Google* gratuitamente, que tem como objetivo disseminar a educação e a pesquisa em aprendizado de máquina e Inteligência Artificial. Além de possuir uma GPU robusta, o seu tempo de execução é totalmente configurado e toda a execução acontece em nuvem. Não é necessário ter um computador com uma grande quantidade de memória pois é possível salvar todos os arquivos no drive e configurá-los facilmente [ALVES et al. 2020].

O *Colab* é um ambiente colaborativo que é utilizado para implementação de algoritmos de classificação em *Python*. Segundo [BALARAMAN 2020], o *Google Colaboratory* remove os obstáculos da configuração do ambiente para a implementação de algoritmos escritos em *Python*.

Para [TerraLAB 2020] "O *TensorFlow* é a principal biblioteca de código aberto para o desenvolvimento e criação de modelos de *Deep Learning (DL)*. Ele possui um ecossistema abrangente e flexível de ferramentas, bibliotecas, e uma comunidade grande e ativa.". E como apresentado por [RIBEIRO and GUIMARÃES 2018] esta é uma biblioteca de código aberto criada pela equipe do *Google Brain* para aprendizado de máquina e pesquisa de redes neurais profundas. Ela utiliza o XLA, um poderoso compilador de álgebra linear que torna a execução mais rápida, rodando em *CPUs*, *GPUs*, *TPUs* e outros.

4.2.2. Inteligência Artificial

A palavra inteligência pode se referir a inteligência natural (biológica) e a IA (sintética). Em [PEREIRA 1988] é realizada uma diferenciação, citando que a parte natural se refere ao cérebro, sendo este suscetível a diferentes regimes de trabalho podendo estar ébrio, alucinado, ou com sono, comprometendo seu regime de funcionamento. Já na Inteligência Artificial se refere aos computadores, que funcionam num único modo bem caracterizado, ou não funcionam de todo, quando não funcionam corretamente como esperado. Ele também afirma que foi iniciada recentemente a exploração de computadores com grandes capacidades de paralelismo, algo que o cérebro já possui de forma natural.

Segundo [RIBEIRO and GUIMARÃES 2018] a Inteligência Artificial é a capacidade dos computadores fazerem suas próprias funções, por meio de funções matemáticas e algoritmos complexos, abstraindo padrões de dados reais que servem para predição ou classificações.

O significado de artificial segundo [DAMACENO and VASCONCELOS 2018] é o que não é natural, aquilo que é feito para imitar a natureza, produzido de forma artística ou industrial. Para ele o conceito de inteligência está associado ao entendimento, ra-

ciocínio, interpretação e utilização do conhecimento adquirido para resolver situações e problemas propostos.

Conhecendo os significados individuais dessas duas palavras, tem-se como Inteligência Artificial a confecção de máquinas com capacidade de aprender sendo estas programadas previamente, fazendo uso de algoritmos bem elaborados e complexos que proporcionem a tomada de decisões, especulações e até interações baseadas nos dados fornecidos. [DAMACENO and VASCONCELOS 2018].

A IA pode ser subdividida em camadas sendo elas *Machine Learning* e *Deep Learning*. *Machine Learning*, assim como conceituado por [DAMACENO and VASCONCELOS 2018], é o processo de aprendizado contínuo de máquina, este método consiste em inserir dados de entrada para a máquina e ela aprender com esses dados e elaborar saídas que satisfaçam a situação problema. Já o método de *Deep Learning*, é um método mais aprofundado, ou seja, é um tipo de *Machine Learning* que tem a capacidade de realizar tarefas mais complexas, como reconhecimento de fala e identificação de imagens. “O *Deep Learning* estabelece parâmetros básicos sobre esses dados e treina o computador para aprender sozinho ao usar várias camadas de processamento no reconhecimento de padrões” [SAS 2022].

4.2.3. Redes Convolucionais

Uma Rede Neural Convolutiva é uma variação das redes de Perceptrons de Múltiplas Camadas, que teve como inspiração o processo biológico de processamentos de dados visuais. A *CNN* tem a capacidade de aplicar filtros em dados visuais, e dessa forma manter a relação de vizinhança entre os *pixels* da imagem durante o processamento da rede [VARGAS et al. 2016].

O reconhecimento de imagem para [ALVES 2018] “...é um clássico problema de classificação, e as Redes Neurais Convolucionais possuem um histórico de alta acurácia para esse problema.”. Alves também afirma que o foco de uma Rede Convolutiva está em filtrar linhas, curvas e bordas e em cada camada acrescida transformar essa filtragem em uma imagem mais complexa. Como explicado por [LARANJEIRAS 2020] a imagem é transformada a partir de cada camada da Rede Convolutiva, transformando-se em um mapa de características, também em três dimensões, e quanto mais profunda a rede, mais mapas de características a representação terá.

[LARANJEIRAS 2020] também aponta que as duas principais operações de uma *CNN*, são a convolução e o *pooling*. Durante o processamento a *CNN* fica alternando entre “transformação” e “subamostragem”. *Pooling* são as camadas usadas para fazer uma inferência, por exemplo uma classificação ou uma regressão.

O aprendizado da rede é feito de forma hierárquica, assim como apontado por [LARANJEIRAS 2020], isto significa que a rede aprende uma característica e nas próximas camadas vai adicionando mais características. Nas primeiras camadas aprendendo características de baixo nível, e nas últimas camadas a rede faz o aprendizado de características de alto nível, ou seja, mais complexas. Por exemplo, se a rede tem que aprender o que é um ganso, nas primeiras camadas ela aprenderia sobre retas, quinas e

blobs de cor, já na camada intermediária sobre o que é o olho, e nas últimas camadas reconheceria o que seria a cabeça e o pescoço do ganso. Nessas últimas camadas é que ocorre a classificação ou a regressão baseando-se nas características de alto nível.

5. Metodologia

O primeiro procedimento metodológico para o desenvolvimento deste trabalho envolveu a análise do uso atual da Inteligência Artificial, em especial das *CNNs*, em diagnósticos de raio-x. Com essa análise foi realizada a pesquisa de doenças que podem ser descobertas nos raio-x envolvendo o pulmão e selecionadas a covid-19, a pneumonia e a tuberculose para o estudo.

Em seguida foi realizada a codificação do sistema de Inteligência Artificial com uma Rede Neural Convolucional que foi treinada com a base de dados selecionada - base de dados disponível no site *Kaggle* [JTIPT 2021], a qual já possui a separação das imagens para treinamento e teste. Nesta base de dados há as classificações de pneumonia, Covid-19, tuberculose e nenhuma das anteriores (p.ex. pulmões saudáveis).

Posteriormente foram realizados treinamentos da rede neural e testes com a base de dados, modificando os parâmetros necessários buscando obter uma taxa de acurácia satisfatória. Acima de 90% é uma acurácia que apresenta resultados de alta precisão e baixo risco, considerada válida para que o médico radiologista trabalhe considerando os resultados da Inteligência Artificial [GONZÁLES 2019].

Para finalizar o projeto foi desenvolvida uma interface gráfica na qual pode ser efetuado o *upload* de uma imagem (extensões: *.jpg*; *.png*; *.jpeg*) do computador e submetê-la ao algoritmo que fará a análise e apresentará um possível diagnóstico. Dessa forma, o sistema servirá como um suporte para a avaliação do radiologista em relação ao raio-x, o qual dará o parecer final sobre o diagnóstico realizado pelo sistema.

A seguir é apresentada uma lista dos materiais utilizados para o desenvolvimento do sistema:

- Computador com um processador Ryzen 5,12G de memória RAM, e HD de 1TB, com S.O. Windows 10 Pro;
- Google Colab ou Collaboratory (navegador google);
- Python versão 3.7.13;
- Bibliotecas do Python: Tensorflow (versão 2.8.0), tensorflow.keras.preprocessing.image, matplotlib.pyplot, seaborn, zipfile, numpy;
- Armazenamento das imagens em nuvem no google drive;
- IDE Pycharm.

6. Análise e interpretação dos resultados

Tomando como base o código inicial de uma *CNN* disponibilizado em [GRANATYR 2021] que apresenta o treinamento de Redes Neurais Convolucionais, foram acrescentadas e alteradas as definições das saídas catalogadas como covid, normal, pneumonia e tuberculose. Foram modificadas funções como a de treinamento para a função *keras.fit()* da biblioteca *Tensorflow*, pois a biblioteca teve diversas atualizações nos últimos anos.

Utilizou-se o serviço *Google Drive* para salvar a base de dados com um total de 7.097 imagens, sendo separadas em 6.326 para treinamento e em 771 para testes. Essa base de dados de imagens proporciona uma grande variação para o treinamento, disponibilizando à *CNN* um vasto conteúdo para coletar dados e encontrar padrões mais claros ao realizar o treinamento, auxiliando a alcançar uma acurácia satisfatória para este estudo (próxima ou superior a 90%).

A *CNN* utilizada possui 179 camadas, com as 175 primeiras camadas com as configurações da biblioteca *Tensorflow* e as 4 últimas com novas configurações criadas. Durante todo o treinamento com as imagens do *Kaggle*, são modificados os pesos de cada camada, sendo a última com 4 saídas de valores. Ao dividir dessa forma toda a rede, é possível utilizar de recursos já desenvolvidos anteriormente pela biblioteca *Tensorflow* para buscas de padrões nas imagens, como também adicionar o tipo de imagem de raio-x do tórax para criar um novo modelo. Esse modelo possui a capacidade de retornar 4 tipos de saídas diferentes, sendo elas, covid, normal, pneumonia e tuberculose.

Na imagem seguinte (Figura 1), é possível analisar o *loss* da rede neural (*Neural Network - NN*) ao longo de todo o treinamento. Quanto mais próximo de 0 significa que o valor do erro vai diminuindo à medida que a rede vai sendo treinada adequadamente. Pode ser observado que, com o passar dos treinamentos, o erro foi diminuindo e deixando a rede em um patamar muito próximo do desejável.

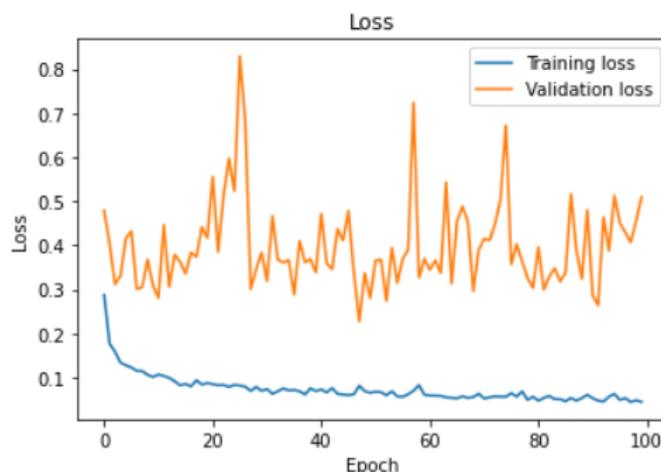


Figura 1. Gráfico do valor do loss ao longo dos 100 ciclos.

Ao identificar o valor da sucesso no treinamento da rede, encontrou-se uma acurácia de 89% após o processamento de 100 ciclos. Um resultado que chega muito perto do esperado para utilizar a rede em situação real. Quanto mais próximo a acurácia chega de 1, melhor a performace que está tendo a rede. A imagem à seguir (Figura 2) retrata a porcentagem da acurácia de acordo com cada ciclo executado na *NN*.

Foram utilizados 100 ciclos para realizar o treinamento da Rede Neural Convulcional, principalmente porque foi utilizada a versão *free* do *Google Colab*, sendo esse um valor próximo ao máximo do uso de memória e *CPU* disponibilizada nesta versão. Ao analisar os gráficos nota-se que, caso houvesse a possibilidade da geração de mais ciclos, a redução do erro provavelmente seria maior, com o conseqüente aumento dos acertos, tornando a rede mais eficiente.

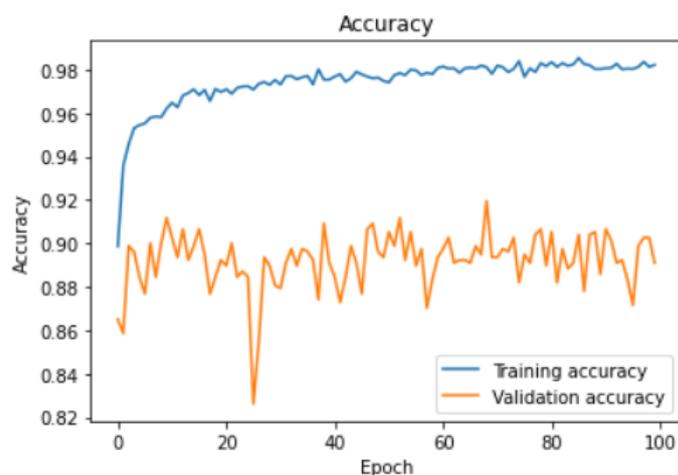


Figura 2. Gráfico do valor da acurácia ao longo dos 100 ciclos.

A seguir, a Figura 3 representa o cruzamento de dados das saídas encontradas com a pasta de testes, a qual possuía 771 imagens. Esse tipo de gráfico é conhecido como matriz confusão e traz, na diagonal, os números de verdadeiros positivos, ou seja, o quadrante é o cruzamento de pares como $\{(0,0), (1,1), (2,2), (3,3)\}$. Já o restante dos quadrados apresentam a quantidade de falhas que a rede trouxe naquela classe, chamados de falsos positivos, isto é, quando cruzado o par $(1,0)$ [representação da linha 1 e coluna 0] é possível ver que a rede classificou 2 imagens como classe 0, quando deveriam ter sido classificadas como classe 1. Com isso pode-se observar que, na diagonal, há um número elevado em relação ao restante da matriz, trazendo a ideia dos 89% de acurácia, pois apresenta uma alta taxa de acertos que estão devidamente classificados, sendo 84 imagens classificadas de forma errada e 687 classificadas corretamente.

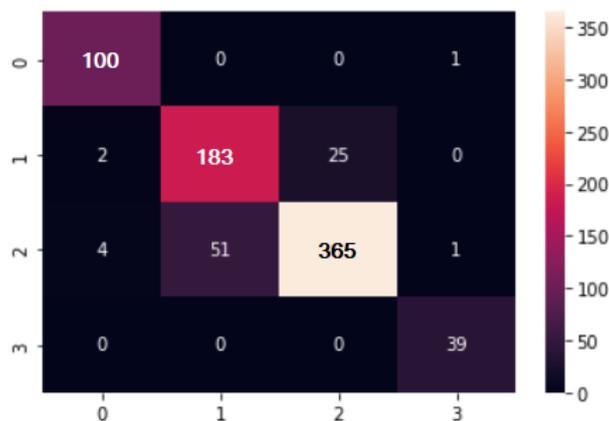


Figura 3. Registro de aprendizagem com cores.

Foi realizado o *download* do modelo treinado no *Google Colab* assim podendo armazenar no computador um arquivo contendo as informações do modelo com todos os pesos definidos no treinamento. Posteriormente, esse modelo pode ser importado pelo programa desenvolvido, dispensando um novo treinamento a cada reinicialização do sistema. Foi desenvolvida uma tela simples para o uso da rede através de uma interface

gráfica. Nessa tela foi incluído um botão que, ao ser clicado, abre o *Explorer* com os arquivos do computador para que o usuário possa buscar uma imagem de raio-x para submeter ao sistema. Segue uma imagem (Figura 4) da tela inicial da interface:

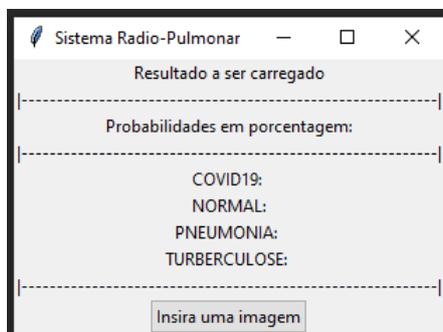


Figura 4. Tela inicial da interface.

Ao selecionar a imagem desejada a rede neural retorna um vetor de 4 posições com um número em cada, que vai de 0 a 1. A posição com o valor mais próximo de 1 será rotulada pela rede como sendo o diagnóstico detectado, assim a posição 0 representa a 'COVID19', a posição 1 representa um pulmão 'NORMAL', a posição 2 seria 'PNEUMONIA' e a posição 3 representaria a 'TURBERCULOSE'. Na imagem a seguir (Figura 5) é possível visualizar uma imagem de raio-x que, ao passar pela análise do sistema, foi classificada com a possibilidade de ser 99% tuberculose, pois o sistema faz a conversão para % para facilitar a leitura pelo usuário.

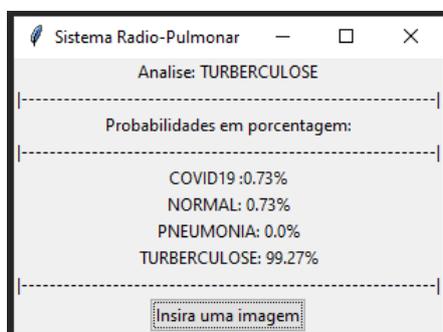


Figura 5. Tela após uma consulta de imagem.

7. Considerações Finais

Através dos resultados obtidos com o treinamento da Rede Neural Convolutiva, compreende-se que o desenvolvimento de um sistema como apresentado neste estudo é viável, pois entende-se que se fosse possível realizar mais interações (ciclos) no *Google Colab*, provavelmente a acurácia da rede gerada seria superior a 90%, obtendo-se um sistema de alta precisão e baixo risco para utilização.

Ao utilizar a *CNN* já desenvolvida para o sistema através da biblioteca *Tensorflow* é possível concluir que foram atingidos resultados satisfatórios, pois esta é capaz de ajudar nos treinamentos e na estruturação da arquitetura da rede neural, sendo um item relevante para trazer uma alta taxa de acurácia do modelo treinado.

O uso do *Google Colab* é interessante, pois é possível utilizar todo o processamento dentro dos servidores da *Google* para realizar o treinamento da *CNN*, também sendo possível armazenar o banco de dados coletado, para que o desenvolvedor possa apenas realizar o *download* dos parâmetros da *CNN* pronta e treinada, para então utilizar em uma versão final do sistema, dispensando novos treinamentos a cada reinício.

Ao adicionar uma interface para o modelo esta pode ser utilizada por um usuário que não precisa necessariamente conhecer sobre programação. Ele pode apenas selecionar a imagem desejada e verificar o resultado que o sistema traz, facilitando a utilização pelo usuário final.

Para realização de trabalhos futuros podem ser analisados itens como desenvolver uma interface mais elaborada e criar um sistema de forma mais intuitiva para transmitir ao usuário uma melhor sensação ao utilizar o sistema. Com isso poderia ser validado o sistema em um hospital buscando entender melhor a aplicabilidade em um cenário real junto a um médico radiologista. Todavia, pode-se também desenvolver um módulo que seja capaz de apresentar o quão avançada pode estar a doença. Pode ser desenvolvido um banco de dados capaz de ir armazenando as imagens que são consultadas, e em determinado intervalo de tempo efetuar novo treinamento da rede e atualizar os pesos do modelo para, dessa forma, ir acompanhando modificações que possam existir nas evoluções das doenças. Por fim, pode também ser desenvolvido um módulo para emissão de um laudo detalhado, facilitando ainda mais o trabalho do radiologista.

Referências

- ALVES, F. R. V., VIEIRA, R. P. M., and CATARINO, P. M. M. C. (2020). Visualizing the newtons fractal from the recurring linear sequence with google colab: An example of brazil x portugal research. *International Electronic Journal of Mathematics Education, London*, V.15(N.3).
- ALVES, G. (2018). Entendendo redes convolucionais (cnns). Disponível em: <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184> Acesso em: 01 de janeiro 2022. Neuronio BR.
- BALARAMAN, S. (2020). Comparison of classification models for breast cancer identification using google colab. *Preprints*. doi: 10.20944/preprints202005.0328.v1., V.1.
- BHARATI, S., PODDER, P., and MONDAL, R. H. (2020). Hybrid deep learning for detecting lung diseases from x-ray images. *Informatics in Medicine Unlocked*, 20, 100391. <https://doi.org/10.1016/j.imu.2020.100391>.
- BVS (2021). Covid 19. Disponível em: <https://bvsms.saude.gov.br/covid-19-2/>. Acesso em: 25 de fevereiro 2022. Biblioteca virtual em saúde ministério da saúde.
- CAMPOS, H. d. S. (2013). Pneumonia. Disponível em: <https://agencia.fiocruz.br/pneumonia> Acesso em: 03 de fevereiro 2022. Agência Fiocruz de notícias.
- CARNEIRO, T., NÓBREGA, R. V. M. D., NEPOMUCENO, T., BIAN, G.-B., ALBUQUERQUE, V. H. C. D., and FILHO, P. P. R. (2018). Performance analysis of google

- colaboratory as a tool for accelerating deep learning applications. *IEEE Access*, 6, 18508634. doi: 10.1109/ACCESS.2018.2874767.
- CELUPPI, I. C., LIMA, G. d. S., WAZLAWICK, E. R. S., and DALMARCO, E. M. (2021). 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, Rio de Janeiro*, 37(3), 20212021. <https://doi.org/10.1590/0102-311X00243220>.
- DAMACENO, S. S. and VASCONCELOS, R. O. (2018). Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular. *Caderno de Graduação - Ciências Exatas e Tecnológicas - UNIT - SERGIPE*, 5(1).
- DEZUBE, R. (2021). Diagnóstico por imagem do tórax. *Manual MSD Versão para Profissionais da Saúde*.
- FONSECA, R. M. d. C. (2021). Desafios e tendências da radiologia na américa latina para o segundo semestre de 2021. Disponível em: <https://www.carestream.com/blog/2021/04/26/desafios-e-tendencias-da-radiologia-na-america-latina-para-o-segundo-semester-de-2021/> Acesso em: 10 de abril 2022.
- FORTES, N. (2020). Radiologia digitalizada: 5 problemas que a tecnologia pode resolver. Disponível em: <https://teleimagem.com.br/radiologia-digitalizada-5-problemas-que-a-tecnologia-pode-resolver/> Acesso em: 06 de março 2022. TI Teleimagem.
- GONZÁLES, M. (2019). O que é acurácia? entenda o conceito e sua importância. Disponível em: <https://blog.idwall.co/o-que-e-acuracia/#:~:text=valer%20a%20pena.-,N%3%ADvel%20de%20acur%3%Alcia%20entre%2090%25%20e%20100%25,prefer%3%AAncia%20na%20busca%20por%20solu%3%A7%3%B5es.> Acesso em: 13 de abril 2022. IDblog.
- GRANATYR, J. (2021). Machine learning para competições kaggle - especial covid-19. Disponível em: <https://www.udemy.com/course/machine-learning-competicoes-kaggle-covid-19-coronavirus/> Acesso em: 14 de fevereiro 2022. Udemy: IA Expert Academy.
- IdeiaGov (2020). Uso de inteligência artificial em exames de imagem. Disponível em: <https://ideiagov.sp.gov.br/desafios/diagnostico-atraves-de-imagens-de-tomografia-computadorizada-e-raio-x-de-torax/> Acesso em: 21 de maio 2022. IdeiaGov.
- JTIPT (2021). Chest x-ray (pneumonia,covid-19,tuberculosis). Disponível em: <https://www.kaggle.com/datasets/jtiptj/chest-xray-pneumoniacovid19tuberculosis> Acesso em: 23 de fevereiro 2022. Kaggle.
- LARANJEIRAS, C. (2020). Redes neurais convolucionais: Deep learning com pytorch. Disponível em: https://www.alura.com.br/conteudo/cnn-redes-neurais-convolucionais-deep-learning-pytorch?gclid=Cj0KCQjw2NyFBhDoARIsAMtHtZ4HA37pFiqLwvVeZRHlH_

- v9mL3a9Tl044Ws24tNq0tM1oDvPfb7PpIaAvc8EALw_wcB Acesso em: 27 de fevereiro 2022. Alura.
- LOBO, L. C. (2017). Inteligência artificial e medicina. *Revista Brasileira de Educação Médica*, 41 (2). doi: <https://doi.org/10.1590/1981-52712015v41n2esp>.
- MENEZES, N. N. C. (2010). *Introdução à Programação com Python*. São Paulo: Novatec.
- MORSCH, J. A. (2018). O que é radiologia médica e qual a sua função? Disponível em: <https://telemedicinamorsch.com.br/blog/radiologia-medica> Acesso em: 09 de maio 2022.
- PAGANO, A. L. and CHIOCA, L. R. (2018). Os desafios encontrados pelos profissionais da área de radiologia na implementação do tratamento humanizado. *Fac. Sant'Ana em Revista, Ponta Grossa*, 3(1):31–40.
- PEREIRA, L. (1988). Inteligência artificial mito e ciência. *Revista Colóquio-Ciências*, v. 3, p. 1-13.
- POSSES, F. P. d. (2020). Raio x: o que é e como funciona o exame de radiografia. Disponível em: <https://star.med.br/raio-x-o-que-e/> Acesso em: 14 de março 2022. Star of the radiology.
- RadVid19 (2020). A radiologia brasileira contra a covid-19. Disponível em: <https://www.conass.org.br/radvid19-a-radiologia-brasileira-contr-a-covid-19/> Acesso em: 22 de abril 2022. CONASS.
- REDE D'Or, S. L. (2019). Pneumonia. Disponível em: <https://www.rededorsaoluiz.com.br/doencas/pneumonia> Acesso em: 02 de maio 2022.
- RIBEIRO, M. M. and GUIMARÃES, S. S. (2018). Redes neurais utilizando tensorflow e keras como facilitar o desenvolvimento de redes neurais com frameworks. *RE3C - Revista Eletrônica Científica de Ciência da Computação*, 13(1).
- RICH, E. (1988). *Inteligência Artificial*. São Paulo: McGraw-Hill.
- ROLLA, V. (2013). Tuberculose. Disponível em: <https://agencia.fiocruz.br/glossario-tuberculose> Acesso em: 28 de março 2022. Agência Fiocruz de notícias.
- SAS, S. S. d. A. (2022). Deep learning, o que é e sua importância. Disponível em: https://www.sas.com/pt_br/insights/analytics/deep-learning.html Acesso em: 17 de janeiro 2022. SAS Institute Inc.
- SILVA, L., FERREIRA, V., ARAÚJO, L., and SANTOS, A. (2020). Aplicação de deep learning no pré-diagnóstico da covid-19 através de imagens de raio-x. *UNIFESSPA*.
- TerraLAB (2020). Convertendo um modelo de inteligência artificial para web com tensorflow js. Disponível em: <http://www2.decom.ufop.br/terralab/convertendo-um-modelo-de-inteligencia-artificial-para-web-com-tensorflow-js> Acesso em: 05 de janeiro 2022. TerraLAB.

- VARELLA, D. (2011). Pneumonia. Disponível em: <https://bvsms.saude.gov.br/pneumonia-5/> Acesso em: 19 de março 2022. Biblioteca virtual em saúde ministério da saúde.
- VARGAS, A. C. G., CARVALHO, A. M. P., and VASCONCELOS, C. N. (2016). Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. *Instituto de Computação Universidade Federal Fluminense, Niterói, Brasil.*
- WHITBY, B. (2004). *Inteligência artificial: um guia para iniciantes*. São Paulo: Madras.