

DESENVOLVIMENTO DE REDES NEURAIS CONVOLUCIONAIS E INTERFACE WEB PARA ANÁLISE DE IMAGENS RADIOLÓGICAS TORÁCICAS

DEVELOPMENT OF CONVOLUTIONAL NEURAL NETWORKS AND WEB INTERFACE FOR THORACIC RADIOGRAPHIC IMAGE ANALYSIS

Alexandra Miguel Raibolt da Silva, Thales Coelho de Azevedo, Conrado Duarte do Amaral, Carlos Eduardo Freitas da Silva, Leticia Lindbergh da Costa, Gabriel Silva Medina

RESUMO

As doenças respiratórias são uma preocupação global devido ao seu impacto na saúde e na mortalidade. O diagnóstico rápido e preciso dessas enfermidades é fundamental para um tratamento eficaz, especialmente nos casos em que a doença progride e se torna grave. Este trabalho tem como objetivo apresentar a viabilidade da utilização de Redes Neurais Convolucionais Profundas na classificação de doenças respiratórias pulmonares por meio de radiografias torácicas através do desenvolvimento Front-End de uma plataforma web de apoio ao diagnóstico radiológico torácico. Sendo assim, adotamos como metodologia a execução de etapas básicas ao se trabalhar com modelos de Aprendizado de Máquina, etapas estas que consistem no treinamento de uma Rede Neural Convolucional Profunda e posteriormente sua validação. Os primeiros resultados apresentaram acurácia de 34% ao avaliar 7 classes de achados radiológicos. Para melhorar a acurácia do modelo, futuras melhorias podem ser propostas, como o aumento do número de imagens disponíveis para treinamento, a avaliação de outros modelos de Redes Neurais Convolucionais Profundas e a otimização de hiperparâmetros do modelo. Além disso, uma melhoria significativa consiste na integração entre a plataforma web para proporcionar uma experiência intuitiva e eficiente para os profissionais da saúde ao utilizarem a plataforma desenvolvida.

Palavras-chave: Diagnóstico Radiológico Torácico; Plataforma Web; Rede Neural Convolucional.

ABSTRACT

Respiratory diseases are a global concern due to their impact on health and mortality. The rapid and accurate diagnosis of these ailments is crucial for effective treatment, especially as diseases progress and become severe. This study aims to demonstrate the feasibility of using Deep Convolutional Neural Networks in classifying pulmonary respiratory diseases through chest radiographs via the Front-End development of a web-based platform supporting thoracic radiological diagnosis. The methodology involves basic steps in working with Machine Learning models, including training a Deep Convolutional Neural Network and subsequently validating it. Initial results showed an accuracy of 34% when assessing 7 classes of radiological findings. To enhance the model's accuracy, future improvements could include increasing the number of available training images, evaluating other models of Deep Convolutional Neural Networks, and optimizing model hyperparameters. Additionally, significant enhancement lies in integrating the web platform to provide an intuitive and efficient experience for healthcare professionals using the developed platform.

Keywords: Thoracic Radiological Diagnosis; Web Platform; Convolutional Neural Network.

1 INTRODUÇÃO

As doenças respiratórias são comuns em todo mundo e nos últimos 2 séculos houve mais de 10 epidemias e pandemias relacionadas a essas enfermidades. Segundo a Organização Mundial da Saúde, conhecida com OMS (em inglês, *World Health Organization* — WHO)¹, em 2017, foi estimado que 650 mil pessoas morrem por ano por doenças ligadas à gripe. Em 2003, a epidemia de SARS-CoV que se disseminou por 12 países causou a morte de mais de 800 mil pessoas. Já em 2019, uma mutação da mesma linhagem de vírus, o SARS-CoV-2, conhecido popularmente como COVID-19, já causou a morte de mais de 5,5 milhões de pessoas em todo o mundo. Somente no Brasil, segundo o site OurWorldInData², houve mais de 34 milhões de casos que levaram à morte de mais de 683 mil pessoas (RITCHIE et al., 2020).

Com a evolução de técnicas baseadas em Aprendizado Profundo (em inglês, *Deep Learning* — DL), em particular Redes Neurais Convolucionais (em inglês, *Convolutional Neural Networks* — CNN) (ZHANG et al., 1998) para extração de características de imagens de alta resolução e a redução do custo computacional, tornou-se possível e viável a criação de classificadores de doenças respiratórias pulmonares por meio de radiografias torácicas, como: detecção do vírus COVID-19 (NARIN, Ali; KAYA, Ceren; PAMUK, Ziyne., 2021) (APOSTOLOPOULOS, Ioannis D.; MPESIANA, Tzani A. , 2020), detecção de infecção por pneumonia (JAIN, Rachna et al., 2020) e diagnóstico precoce da infecção por tuberculose (LAKHANI, Paras; SUNDARAM, Baskaran, 2017) (PASA, F. et al., 2019).

Logo, com os avanços recentes em modelos de Aprendizado Profundo, surge a necessidade de desenvolver sistemas de assistência ao diagnóstico por imagem de baixo custo. Nesse contexto, apresentamos neste trabalho, a viabilidade da utilização de Redes Neurais Convolucionais na classificação de achados radiológicos, com o objetivo de proporcionar em trabalhos futuros aos profissionais de saúde a possibilidade de enviar imagens radiológicas torácicas para a plataforma web desenvolvida, para processar e analisar os achados radiológicos, onde os resultados e diagnósticos auxiliares serão então apresentados na interface de usuário intuitiva e responsiva, fornecendo informações importantes para o diagnóstico e tratamento dos pacientes.

O presente trabalho envolveu pesquisa, no âmbito de Iniciação Científica (IC), na área de Reconhecimento de Padrões (em inglês, *Pattern Recognition* — PR) e Aprendizado de Máquina (em inglês, *Machine Learning* — ML), baseado em Aprendizado Profundo. Neste projeto, os problemas de interesse envolvem extração de características e padrões de classificação em imagens de raio-X torácicas baseado em Redes Neurais Convolucionais. E também, no âmbito de Iniciação Científica (IC), na área de Arquitetura de Software e Desenvolvimento Web.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo geral deste trabalho propõe o desenvolvimento de um sistema experimental que consiste no processamento e análise de imagens radiológicas torácicas por meio da aplicação de Redes Neurais Convolucionais.

Isto, por meio de uma plataforma web para auxílio no diagnóstico médico como instrumento complementar viabilizando a detecção e reconhecimento de algumas doenças e infecções em pacientes afetados.

1 <https://www.who.int>

2 <https://ourworldindata.org>

2.2 Objetivos específicos

Para que o Objetivo Geral deste projeto seja alcançado, foi estabelecido, o desenvolvimento de objetivos específicos atingidos no decorrer do desenvolvimento deste trabalho, a saber:

- **Análise e Definição de Requisitos:** Este objetivo consiste na análise e identificação de requisitos necessários para o bom desenvolvimento do sistema proposto;
- **Modelagem de Diagramas e Especificações:** Este objetivo consiste na construção de Diagramas e Especificações onde foram registradas todas as funcionalidades, interações, processos, classes e objetos do sistema proposto. Além do design da arquitetura e interface do sistema proposto;
- **Aquisição do Conjunto de Dados:** Este objetivo consiste na aquisição e entendimento de Conjuntos de dados a serem trabalhados;
- **Pré-Processamento:** Este objetivo consiste na aplicação de técnicas de pré-processamento e padronização nas amostras de imagens presentes nos conjuntos de dados adquiridos;
- **Construção do Modelo:** Este objetivo consiste na construção do modelo, definindo valores de hiperparâmetros e heurísticas dos modelos de Redes Neurais Convolucionais utilizadas no sistema de apoio ao diagnóstico radiológico torácico;
- **Treinamento do Modelo:** Este objetivo consiste na execução do modelo construído utilizando as amostras de imagens presentes nos conjuntos de dados de treinamento adquiridos;
- **Validação do Modelo:** Este objetivo consiste na validação e análise dos resultados obtidos (e.g., precisão de classificação, consumo computacional, entre outros) no processo de extração de características e padrões de classificação das imagens radiológicas torácicas;
- **Construção do Sistema:** Este objetivo consiste na construção do sistema, levando em consideração as especificações detalhadas nos objetivos anteriores.

3 JUSTIFICATIVA

A interpretação de imagens radiológicas, como radiografias torácicas, pode ser desafiadora e está sujeita a erros humanos, o que pode resultar em diagnósticos imprecisos e atrasos no tratamento. O uso de Redes Neurais Convolucionais oferece um potencial significativo para melhorar a precisão e eficiência do diagnóstico, permitindo uma análise mais detalhada e precisa do tecido pulmonar, estruturas cardíacas e possíveis anormalidades.

Ao desenvolver uma plataforma web integrada a Redes Neurais Convolucionais como sistema de apoio ao diagnóstico radiológico torácico, busca-se fornecer aos profissionais de saúde uma ferramenta confiável e rápida para auxiliá-los na interpretação das radiografias. Isso pode resultar em diagnósticos mais precisos, detecção precoce de doenças, tratamentos mais adequados e melhores resultados para os pacientes.

Dessa forma, a justificativa para o desenvolvimento deste trabalho está na busca em aprimorar a precisão e eficiência de achados radiológicos, através do uso de Redes Neurais Convolucionais e da criação de uma plataforma web intuitiva e responsiva.

Para além da Introdução, a seguir, na seção Revisão Bibliográfica é apresentado uma visão geral da fundamentação teórica necessária para compreender os conceitos envolvidos nas ferramentas de desenvolvimento utilizadas para o desenvolvimento deste trabalho. Em seguida, na seção Metodologia são apresentados os métodos e metodologias adotadas para o desenvolvimento deste trabalho. Em seguida, na seção Resultados são apresentados os resultados de pesquisa alcançados ao longo do desenvolvimento deste trabalho. Após, na seção Considerações Finais são apresentadas as considerações finais deste trabalho, bem como, a proposta de trabalhos futuros.

4 REVISÃO BIBLIOGRÁFICA

Em (SOMMERVILLE, 2011) são apresentados tópicos e fatos importantes na engenharia de software e desenvolvimento ágil, assim como a modelagem de sistemas através da UML (em inglês, *Unified Modeling Language*) (BOOCH, Grady et al., 1996), esses recursos foram fundamentais e significativos para o desenvolvimento deste trabalho.

A arquitetura de Rede Neural Convolucional foi proposta originalmente por (LECUN et al., 1998). A partir do ano de 2012 vem conquistando espaço em desafios de reconhecimento e classificação de imagens como na competição *Large Scale Visual Recognition Challenge* (ILSVRC). Hoje, temos à disposição, uma gama de diferentes arquiteturas de Redes Neurais Convolucionais, para citar algumas: LeNet (LECUN et al., 1998), AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), VGG (SIMONYAN; ZISSERMAN, 2014), (HE et al., 2016), GoogLeNet (SZEGEDY et al., 2015), ResNet (HE et al., 2016), e seus resultados as tornam estado da arte para a resolução de tarefas na área de Visão Computacional.

A AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) foi apresentada como uma solução para o treinamento de Redes Neurais Convolucionais para classificação de imagens utilizando o conjunto de dados visuais Imagenet (DENG et al., 2009) no *Large Scale Visual Recognition Challenge*. O artigo foi uma revolução na área de Visão Computacional (em inglês, *Computer Vision* — CV) apresentando uma solução para o reconhecimento de imagens de grande conjunto de dados visuais com imagens de alta resolução, com 5 camadas de convolução (*convolution*) e 2 camadas totalmente conectadas (*fully-connected*), representada na Figura 1.

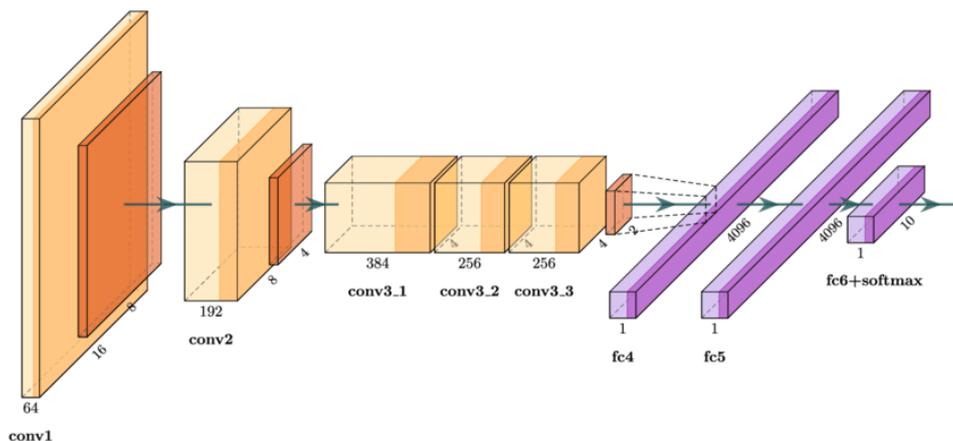


Figura 1 — Modelo da arquitetura AlexNet. Fonte: (STRISCIUGLIO; LOPEZ-ANTEQUERA; PETKOV, 2020).

Nesse artigo, foi apresentado um novo conceito em Redes Neurais Convolucionais, apresentando a possibilidade de treinar tais modelos através de Unidades de Processamento Gráfico (em inglês, *Graphics Processing Unit* — GPU) sendo mais eficientes do que Unidade de Central de Processamento (em inglês, *Central Processing Unit* — CPU). Além disso, os autores apresentam a função de ativação ReLU (em inglês, *Rectified Linear Units*) como uma opção a função Tanh (*tangente hiperbólica*), o que se tornou um padrão. Deste modo, a AlexNet é 6 vezes mais rápida para a convergência do treinamento do modelo de Rede Neural Convolucional.

A VGG (SIMONYAN; ZISSERMAN, 2014), trouxe como novidade a possibilidade de aumentar o número de camadas, entre 16 e 19, como pode ser observada na Figura 2, reduzindo a convolução para *kernels* de 3x3, aumentando o número de filtros por camadas e mantendo a resolução por algumas camadas antes de realizar o Max-Pooling (*técnica para redução das imagens*), de *kernel* de 2x2.

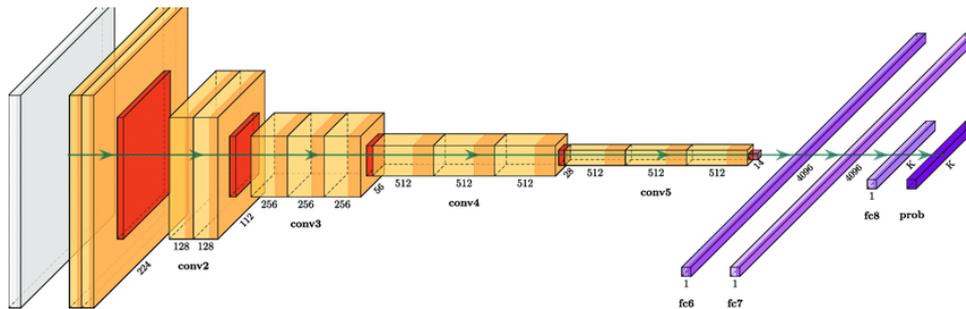


Figura 2 — Modelo da arquitetura VGG. Fonte: (BLAUCH; BEHRMANN; PLAUT, 2019).

Com a VGG, os autores mostram resultados satisfatórios no que diz respeito à utilização de filtros menores aplicados em Redes Neurais Convolucionais Profundas, apontando uma melhoria significativa na performance do modelo. Usando a VGG, quanto maior o número de camadas menor foram os erros, limitando a 19 camadas, onde não havia mais uma grande evolução.

Ao treinar tais arquiteturas, um problema ainda enfrentado está relacionado ao poder computacional necessário, onde, muitas vezes torna-se um recurso indisponível e/ou até mesmo caro. De modo a minimizar o problema de poder computacional, neste trabalho, propomos a utilização de uma instância de máquina virtual pré-configurada de alto desempenho gratuita na infraestrutura do Google – o Google Colaboratory3.

5 METODOLOGIA

Optamos em estabelecer o uso de técnicas e sólidos princípios da Engenharia de Software (SOMMERVILLE, 2011), desta forma foi possível detectar os requisitos necessários para o bom desenvolvimento do sistema proposto, onde são registradas todas as funcionalidades, interações, processos, classes e objetos pertencentes ao sistema. Desta maneira, foram realizadas as etapas de Análise e Definição de Requisitos e Modelagem de Diagramas e Especificações. De modo que, para a representação conceitual dos dados, entidades, cardinalidades e as interações entre elas, foram utilizados os diagramas UML (BOOCH, 2006), que permitem uma visualização facilitada dos elementos pertencentes ao sistema. Desta forma, foi desenvolvido, tais diagramas: Diagrama de Caso de Uso, Especificações de Casos de Uso, Modelo Conceitual de Dados, Modelo Conceitual de Classes, Alocação de Recursos (Hardware e Software), e por fim, Diagrama de Implantação.

Para a realização dos experimentos, acessamos diversas fontes de conjuntos de dados de imagens radiografias torácicas de pacientes médicos. Na Figura 3, é possível observar a aparência das imagens necessárias para o desenvolvimento deste trabalho.



Figura 3 — Amostras de radiografias torácicas de conjunto de dados visuais de pacientes com Pneumonia. Fonte: (KERMANY et al., 2018).

Como observado na Figura 3, as amostras são compostas de imagens relacionadas a rótulos que indicam a característica encontrada na imagem.

Os critérios de seleção de conjuntos de dados de imagens de raio-X definidos para este trabalho, consistiu em: (a) O conjunto de dados deve ser de caráter gratuito, (b) O conjunto de dados deve conter imagens de raio-X torácicas, e; (c) O conjunto de dados deve possuir amostras de imagens de pacientes saudáveis, pacientes com tuberculose, pacientes com pneumonia e pacientes com COVID-19. Após a coleta e entendimento dos conjuntos de dados adquiridos, foram aplicadas técnicas de pré-processamento e padronização nas amostras de imagens e estas amostras de imagens foram decompostas em (a) conjunto de dados de treinamento, e; (b) conjunto de dados de validação.

Para realizar a tarefa de apoio ao diagnóstico radiológico torácico, adotamos como metodologia a execução das etapas básicas ao se trabalhar com modelos de Aprendizado de Máquina, etapas estas que consistem no treinamento de uma Rede Neural Convolutacional e posteriormente sua validação (ou teste), avaliado a precisão do sistema de classificação.

6 RESULTADOS

O desenvolvimento Front-End da plataforma web deu-se em duas principais frentes, sendo estas: (a) o servidor e (b) a plataforma em si. O servidor foi desenvolvido usando Supabase⁴ que utiliza o Banco de Dados PostgreSQL⁵, enquanto a plataforma foi desenvolvida utilizando Tailwind CSS⁶ e Svelte⁷. Além disso, nas etapas preliminares este projeto, foi utilizado o Figma⁸ para a criação e visualização da disposição das telas, com intuito de apresentar uma visualização prévia da plataforma. Na Figura 4, é possível observar as telas prévias desenvolvidas nas etapas preliminares deste trabalho, e que sustentaram a construção da plataforma web.

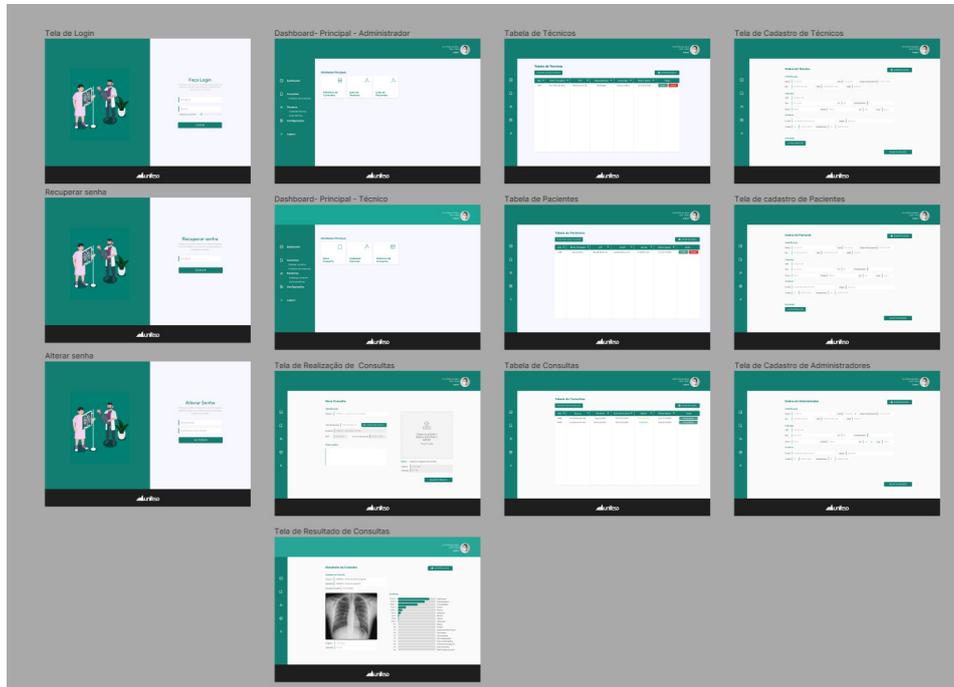


Figura 4 — Telas projetadas no Figma. Fonte: **Elaborado pela Autora.**

4 <https://supabase.com>

5 <https://www.postgresql.org>

6 <https://tailwindcss.com>

7 <https://svelte.dev>

8 <https://www.figma.com>

A Linguagem de Programação adotada para o desenvolvimento do sistema de classificação foi Python⁹, linguagem amplamente utilizada em aplicações de Aprendizado de Máquina. No contexto da modelagem e treinamento das Redes Neurais Convolucionais, foi utilizado o Keras¹⁰, um *framework* de código aberto em Python que integra outras bibliotecas relacionadas, entre elas, destacam-se: Theano¹¹, TensorFlow¹², e Cognitive Toolkit¹³. Essas ferramentas são otimizadas e apresentam um desempenho excepcional, porém exigem um nível avançado de conhecimento para a criação de Redes Neurais.

Para a realização deste trabalho, foram selecionados seis conjuntos de dados públicos provenientes de diversas fontes, a fim de obter uma ampla diversidade e abrangência de informações que incluem: Chest X-Ray Images (Pneumonia) (KERMANY et al., 2018), COVID-19 Radiography Database (RAHMAN et al., 2021) (CHOWDHURY et al., 2020), Tuberculosis (TB) Chest X-Ray Database (RAHMAN et al., 2020), COVID-19 Chest X-Ray (MAGUOLO; NANNI, 2020) (TARTAGLIONE et al., 2020), COVID-19 Hannover Medical School (WINTHER et al., 2020) e COVID19 Pneumonia Normal Chest X-Ray PA (WANG et al., 2017) (COHEN; MORRISON; DAO, 2020).

Para integrar os diferentes conjuntos de dados e manter a relação entre os dados, foi aplicada a técnica de *Data Merging*. Nesse contexto, as imagens de radiografias torácicas foram agrupadas com base nos diagnósticos dos pacientes. Essa abordagem permitiu criar um conjunto de dados visuais inicial contendo 24.008 imagens, classificadas da seguinte maneira: 4.208 imagens foram classificadas como COVID-19, 4.059 imagens foram classificadas como Pneumonia, 700 imagens foram classificadas como Tuberculose e 15.041 imagens foram classificadas como saudáveis.

Após consultar profissionais da área de saúde, foi identificado que um sistema de auxílio ao diagnóstico de radiografias que fosse capaz de identificar achados radiológicos seria mais útil do que simplesmente classificar doenças. Essa abordagem permitiria a identificação de sintomas e características específicas nas radiografias, que, combinadas com outros exames e informações clínicas dos pacientes, possibilitariam um diagnóstico mais preciso das doenças. Os achados radiológicos são características ou anomalias identificadas em imagens radiológicas, como radiografias, Tomografias Computadorizadas (TC) ou Ressonâncias Magnéticas (RM), que podem indicar a presença de uma condição médica específica. Esses achados são observados por profissionais de saúde, como radiologistas, e auxiliam no diagnóstico e no monitoramento de doenças.

Diante dessa orientação, foi realizada a busca de dados relacionados a achados radiológicos presentes nas radiografias. Para isso, foi criado um segundo conjunto de dados visuais para o treinamento do modelo, baseado no conjunto de dados visuais disponibilizado pelo Nacional Institute of Health (WANG et al., 2017), que contém 100.000 radiografias classificadas em 19 classes de achados radiológicos e de radiografias sem achados radiológicos. No entanto, este, o conjunto de dados visuais, apresentava um desequilíbrio significativo entre as classes. Isso pode afetar negativamente o desempenho e a precisão dos modelos de Aprendizado de Máquina, levando a resultados enviesados ou sub-representação de classes minoritárias.

Em virtude do considerável desequilíbrio entre as classes presentes no conjunto de dados visuais utilizado neste estudo, uma estratégia de redução de escopo foi adotada a fim de direcionar a análise para um conjunto de sete classes com uma quantidade mínima de 1400 imagens disponíveis. As classes mantidas para o treinamento inicial do sistema foram: (a) atelectasia; (b) derrame; (c) infiltração; (d) massa; (e) nódulo; (f) pneumotórax; e (g) sem achados.

Inicialmente, foram configurados três modelos de Redes Neurais Convolucionais: (a) MobilenetV3; (b) ResnetV2; e (c) InceptionResnetV2, usando as configurações padrão e *Transfer Learning* com o conjunto de

9 <https://www.python.org>

10 <https://keras.io>

11 <https://github.com/Theano/Theano>

12 <https://www.tensorflow.org>

13 <https://learn.microsoft.com/en-us/cognitive-toolkit>

dados Imagenet. Esses modelos foram projetados para treinar conjuntos de dados com imagens coloridas de três canais (RGB). Apesar da configuração das Redes Neurais Convolucionais no *framework* Keras, o treinamento das redes não convergiu, mantendo uma acurácia de aproximadamente 14%, o que indicava que não havia aprendizado significativo. No entanto, ao usar uma implementação do modelo InceptionV3 (SZEGEDY et al., 2015b) e adaptar o código para processar imagens em escala de cinza, houve uma melhoria significativa. O modelo atingiu 95% de acurácia no treinamento, mas a acurácia foi de apenas 34% durante a avaliação no conjunto de validação indicando a presença de overfitting no modelo como pode ser observado na Figura 5 apresentada a seguir.

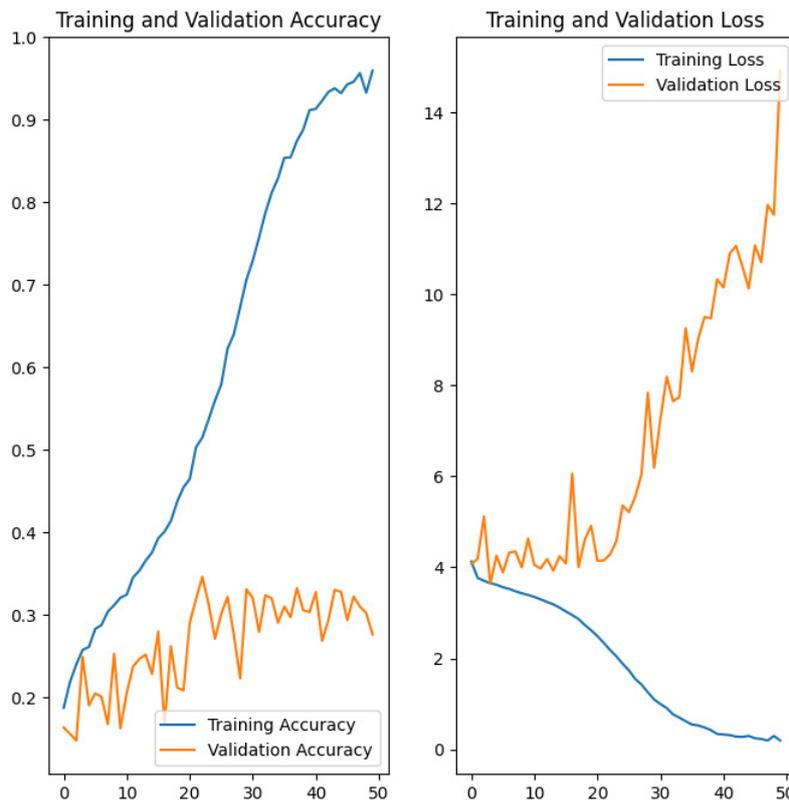


Figura 5 — Resultado de acurácia e erro do treinamento do modelo InceptionV3 com o conjunto de dados visuais de achados radiológicos. Fonte: **Elaborado pela Autora.**

Na Figura 5, o overfitting pode ser identificado quando há uma diferença significativa entre as curvas de acurácia dos dados de treinamento e validação. O modelo apresenta uma alta taxa de acurácia nos dados de treinamento, em contrapartida, apresenta uma alta taxa de acurácia nos dados de validação, indicando que não está generalizando adequadamente bem com a entrada de novas imagens.

7 CONSIDERAÇÕES FINAIS

Este trabalho apresentou a dificuldade encontrada durante o treinamento de modelos de Redes Neurais Convolucionais para a identificação de achados radiológicos em radiografias torácicas, em que as tentativas realizadas não obtiveram convergência satisfatória.

A falta de convergência dos modelos de Redes Neurais Convolucionais pode ser atribuída a diversos fatores. Um dos principais é a disponibilidade limitada de dados de treinamento e a falta de diversidade no conjunto de dados visuais também podem afetar a capacidade do modelo de generalizar corretamente para novas amostras. Diante dessas dificuldades, é fundamental explorar estratégias adicionais para melhorar a convergência dos modelos de Redes Neurais Convolucionais e, conseqüentemente, a qualidade das classificações. Isso pode incluir o aumento do tamanho e diversidade do conjunto de dados visuais de treinamento, a otimiza-

ção dos hiperparâmetros, a utilização de técnicas de transferência de aprendizado, bem como a exploração de arquiteturas mais avançadas de Redes Neurais Convolucionais.

A tecnologia desempenha um papel cada vez mais importante na medicina e no cuidado com a saúde, o desenvolvimento de plataformas especializadas como a apresentada neste trabalho torna-se essencial. Ao unir tais tecnologias, visamos oferecer futuramente aos profissionais de saúde, uma experiência intuitiva e responsiva, permitindo o processamento eficiente de imagens radiológicas torácicas. Em um contexto onde a importância deste tipo de software torna-se uma alternativa cara, e muitas vezes indisponível, este tipo de iniciativa proporciona a pesquisa e desenvolvimento de soluções acessíveis e eficazes, com o objetivo de minimizar tal carência para a sociedade da região serrana do Estado do Rio de Janeiro, servindo de instrumento complementar no diagnóstico radiológico e médico.

8 TRABALHOS FUTUROS

Como trabalhos futuros, destacamos a necessidade de complementar o desenvolvimento deste trabalho. Ao abordar as etapas a seguir, espera-se que a plataforma web esteja completa, robusta e pronta para fornecer diagnósticos auxiliares precisos e eficientes no contexto de apoio ao diagnóstico radiológico torácico, a seguir:

- **Implementação do Modo Noturno na Plataforma:** Adição de uma opção visual mais confortável e adaptável aos usuários, além de melhoria da experiência geral do usuário;
- **Otimização dos Códigos:** Aperfeiçoamento dos códigos para garantir uma interface mais amigável, além de melhoria da experiência geral do usuário;
- **Implementação de Sistema de Autenticação de Dois Fatores (2FA):** Inclusão de um Sistema de Autenticação de dois fatores (2FA) do inglês, Two-Factor Authentication, visando aprimorar a segurança do acesso dos usuários;
- **Teste de Unidade:** Este objetivo consiste na cobertura de testes referentes a validação de dados válidos e inválidos via I/O (entrada/saída);
- **Implantação do Modelo:** Este objetivo consiste na implantação e integração do modelo com o sistema;
- **Gerenciamento e Monitoramento:** Este objetivo consiste no gerenciamento e monitoramento do modelo, realizando retreinamento caso necessário, a fim de manter o modelo preciso e relevante.

9 REFERÊNCIAS BIBLIOGRÁFICAS

APOSTOLOPOULOS, Ioannis D.; MPESIANA, Tzani A. Covid-19: automatic detection from x ray images utilizing transfer learning with convolutional neural networks. *Physical and engineering sciences in medicine*, v. 43, n. 2, p. 635-640, 2020.

BLAUCH, N. M.; BEHRMANN, M.; PLAUT, D. C. Computational insights into human expertise for familiar and unfamiliar face recognition. *Psyarxiv [Abstract][Google Scholar]*, 2019.

BOOCH, Grady et al. The unified modeling language. *Unix Review*, v. 14, n. 13, p. 5, 1996.

BOOCH, Grady. *UML: guia do usuário*. Elsevier Brasil, 2006.

CHOWDHURY, M. E. et al. Can ai help in screening viral and covid-19 pneumonia? *Ieee Access, IEEE*, v. 8, p. 132665–132676, 2020.

COHEN, J. P.; MORRISON, P.; DAO, L. COVID-19 Image Data Collection. 2020.

DENG, J. et al. Imagenet: A large-scale hierarchical image database. In: 2009 IEEE Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.], 2009. p. 248–255.

- HE, K. et al. Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2016. p. 770–778.
- JAIN, Rachna et al. Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, v. 165, p. 108046, 2020.
- KERMANY, D. S. et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, Elsevier, v. 172, n. 5, p. 1122–1131, 2018.
- KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, 2012.
- LAKHANI, Paras; SUNDARAM, Baskaran. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*, v. 284, n. 2, p. 574–582, 2017.
- LECUN, Yann et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2324, 1998.
- MAGUOLO, G.; NANNI, L. A Critic Evaluation of Methods for COVID-19 Automatic Detection from X-Ray Images. 2020.
- NARIN, Ali; KAYA, Ceren; PAMUK, Ziyet. Automatic detection of coronavirus disease (covid 19) using x-ray images and deep convolutional neural networks. *Pattern Analysis and Applications*, v. 24, n. 3, p. 1207–1220, 2021.
- PASA, F. et al. Efficient deep network architectures for fast chest X-ray tuberculosis screening and visualization. *Scientific reports*, v. 9, n. 1, p. 1–9, 2019.
- RAHMAN, T. et al. Exploring the effect of image enhancement techniques on covid-19 detection using chest x-ray images. *Computers in biology and medicine*, Elsevier, v. 132, p. 104319, 2021.
- RAHMAN, T. et al. Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization. *IEEE Access*, v. 8, p. 191586–191601, 2020.
- RITCHIE, H. et al. Coronavirus Pandemic (COVID-19). *Our World in Data*, 2020.
- SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- SOMMERVILLE, I. *Engenharia de software*. 9a. edição, Pearson Education do Brasil, 2011.
- STRISCIUGLIO, N.; LOPEZ-ANTEQUERA, M.; PETKOV, N. Enhanced robustness of convolutional networks with a push–pull inhibition layer. *Neural Computing and Applications*, Springer, v. 32, p. 17957–17971, 2020.
- SZEGEDY, C. et al. Going deeper with convolutions. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2015. p. 1–9.
- SZEGEDY, C. et al. Rethinking the inception architecture for computer vision. *CoRR*, abs/1512.00567, 2015. Disponível em: <<http://arxiv.org/abs/1512.00567>>.
- TARTAGLIONE, E. et al. Unveiling COVID-19 from CHEST x-ray with deep learning: A hurdles race with small data. *International Journal of Environmental Research and Public Health*, MDPI AG, v. 17, n. 18, p. 6933, sep 2020. Disponível em: <<https://doi.org/10.3390%2Fijerph17186933>>.
- WANG, X. et al. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2017. p. 2097–2106.
- WINTHER, H. B. et al. COVID-19 Image Repository. 5 2020. Disponível em: <https://figshare.com/articles/dataset/COVID-19_Image_Repository/12275009>.
- ZHANG, Zhengyou et al. Comparison between geometry-based and gabor-wavelets-based facial expression recognition using multi-layer perceptron. In: Proceedings Third IEEE International Conference on Automatic face and gesture recognition. IEEE, 1998. p. 454–459.