

Uso de uma Rede Neural Convolutacional para Análise de Exames de Radiografia de Pulmão com Detecção de Covid-19, Pneumonia e Tuberculose

Camila Munzlinger^{1,2}, Igor Yepes¹, Rafael Rieder²

¹Instituto Federal Farroupilha (IFFAR) - Campus Frederico Westphalen
Frederico Westphalen – RS – Brazil

²Universidade de Passo Fundo (UPF)
Passo Fundo – RS – Brasil

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

igor.yepes@iffarroupilha.edu.br, rieder@upf.br

Resumo. *O trabalho cotidiano de um médico radiologista se mostra deveras árduo, devido a demanda de diagnósticos e laudos requeridos em laboratórios de análises clínicas, a sobrecarga de horas de trabalho e a falta de tempo para a realização de um atendimento coerente com as necessidades dos pacientes. Com isso em mente, este artigo apresenta um sistema baseado em redes neurais convolucionais desenvolvido para auxiliar profissionais radiologistas na sua rotina de trabalho, agilizando diagnósticos e disponibilizando tempo para atendimento mais humanizado. O estudo faz adaptação de um modelo inteligente ResNet-50 utilizando a técnica de transfer learning, com o intuito de prever doenças pulmonares em imagens de raios-X, sendo elas Covid-19, pneumonia e tuberculose. Após o treinamento do modelo considerando uma base de dados aberta, com imagens validadas, alcançou-se uma acurácia geral de ~89% na predição de diagnósticos para as doenças citadas.*

1. Introdução

As doenças Covid-19, pneumonia e tuberculose são infecções que afetam principalmente os pulmões. Estas doenças podem ser identificadas através de imagens de radiografia do tórax, pelas quais médicos radiologistas podem analisar se há a presença de alguma dessas infecções pulmonares no paciente [Dezube 2021].

A partir da pandemia de Covid-19 em 2020, diversas instituições incentivam a pesquisa de algoritmos inteligentes para identificação de doenças através de raios-X. Devido a este fato, existe também a possibilidade de armazenar imagens de radiografias em bancos de dados abertos [Kaggle 2023, Nguyen et al. 2020, FIPS 2023], sem a identificação dos pacientes. Isto possibilita que diferentes algoritmos sejam testados com a mesma base para obter resultados diferenciados.

Na área da Saúde, médicos radiologistas atuam na análise e na interpretação de imagens de raios-X para diagnosticar e emitir laudos dos pacientes. Esses profissionais costumam lidar com picos de atendimentos que geram longas e desgastantes jornadas de trabalho [Duarte & Noro 2013]. Essa carga de trabalho poderia ser reduzida com uma eficiente ferramenta computacional de suporte ao processo decisório [van Leeuwen et al. 2021], que também contribuiria para na agilidade da tarefa

e no tempo de resposta, proporcionando um atendimento mais humanizado aos pacientes [Pagano & Chioca 2018].

Conforme [Bharati et al. 2020], diversas pesquisas para desenvolvimento de algoritmos de aprendizado profundo vêm sendo aplicados na área de radiologia para classificar doenças e proporcionar ao médico um suporte ao seu trabalho diário e, respectivamente, seus diagnósticos. Além disso, o uso de um sistema inteligente pode ajudar na detecção de doenças em estágios iniciais, contribuindo para o tratamento precoce e a adoção de medidas preventivas [Yildirim et al. 2022].

Com isso em mente, este artigo apresenta o desenvolvimento de um sistema baseado em redes neurais convolucionais (CNNs) para diagnosticar doenças pulmonares, considerando a classificação de imagens de raios-X em quatro classes: Covid-19, Pneumonia, Tuberculose e nenhuma das anteriores. O objetivo é oferecer uma solução capaz de auxiliar profissionais na sua rotina de trabalho, agilizando a análise e a definição de diagnósticos, e disponibilizando tempo para atendimento mais humanizado aos pacientes.

2. Trabalhos Relacionados

O projeto RadVid-19 é uma ação organizada por radiologistas brasileiros que tem como objetivo a coleta de exames de raios-X e tomografia com confirmação ou suspeita de Covid-19 [RadVid19 2020]. De acordo com os autores, o projeto implementou um algoritmo para realizar a análise de imagens de tomografias. O sistema gera um relatório que pode ser acessado por um radiologista, com o intuito de servir como ferramenta auxiliar na tomada de decisão clínica.

Segundo [Silva et al. 2020], existem várias pesquisas que utilizam a classificação de imagens para ajudar no diagnóstico precoce da tuberculose, da pneumonia, e lesões pulmonares através de radiografia torácica. Nesse âmbito, pode-se citar o trabalho de [Sharma et al. 2020], que visa criar modelos eficientes de aprendizado profundo, treinados com imagens de radiografia de tórax, para triagem rápida de pacientes com Covid-19 e outras doenças infecciosas. Outro exemplo é o estudo de [Hussein et al. 2022], que propõe uma arquitetura híbrida de equalização de histograma adaptativo limitado por contraste e CNNs para classificação de doenças pulmonares.

3. Metodologia

Primeiramente, fez-se uma rápida análise do uso de CNNs em diagnósticos de raios-X, para saber que doenças podem ser identificadas por imagens desta natureza. A partir disso, definiu-se como foco a construção de uma solução para detecção de doenças que atingem o pulmão. Em seguida, foi realizada a codificação do sistema proposto, considerando o conjunto de dados disponível em [JTIPT 2021], que possui a separação das imagens para treinamento, validação e teste. Esta base de dados possui imagens de raios-X categorizadas em Pneumonia, Covid-19, Tuberculose e Normal (pulmões saudáveis).

Posteriormente, foram realizados treinamentos da rede neural e testes com a base de dados, modificando parâmetros em busca de uma taxa de acurácia de 90%. Considerou-se essa acurácia mínima como satisfatória, pois apresenta resultados de alta precisão e baixo risco, considerada válida para que o médico radiologista trabalhar considerando os resultados da Inteligência Artificial [González 2019].

Para finalizar o projeto, desenvolveu-se uma interface gráfica para efetuar a submissão de uma imagem para avaliação do modelo, com suporte às extensões *jpg*, *png* e *jpeg*). Ela encaminha a imagem para inferência do modelo, que retorna um possível diagnóstico para análise e validação do profissional usuário do sistema.

Os seguintes recursos foram utilizados para desenvolver o sistema: computador com processador Ryzen 5, 12GB RAM, HDD 1TB (Windows 10 Pro); conta no Google para armazenamento das imagens em nuvem (Drive) e para treinamento, validação e teste do modelo (Colab); linguagem Python v. 3.7.13 (ambiente de desenvolvimento Pycharm); bibliotecas tensorflow (v. 2.8.0), keras, matplotlib, seaborn, zipfile e numpy.

4. Resultados e Discussão

Para a abordagem desse trabalho, optou-se pelo uso da técnica de *transfer learning*. Nesse contexto, tomou-se como base inicial o algoritmo disponibilizado por [Granatyr 2021], que demonstra o uso da arquitetura ResNet-50 [He et al. 2016] com parâmetros de pesos retirados da ImageNet.

Uma arquitetura personalizada foi adicionada após a última camada da ResNet-50, com uma camada para o cálculo do *pooling* global e mais quatro camadas densas. As ativações *relu* estão presentes nas três últimas camadas, e a última camada possui a função *softmax* para gerar as probabilidades de classificação. Dessa forma, tem-se um modelo com as camadas de entrada provenientes da ResNet-50 e a saída personalizada para o objetivo desse estudo.

No treinamento, apenas os pesos das cinco camadas finais são atualizados para fino ajuste, enquanto os pesos das 174 primeiras camadas são mantidos. Essa abordagem de *transfer learning* permite que o modelo seja ajustado para o problema específico sem a necessidade de treinamento das camadas convolucionais, economizando tempo e recursos. Assim, pode-se extrair a maior quantidade de características possível das imagens de interesse, e classificar conforme as categorias desejadas.

Utilizou-se o *Google Drive* para salvar a base de dados com um total de 7097 imagens, sendo separadas em 6326 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 encontrar padrões e aprender com estes, contribuindo para alcançar uma acurácia satisfatória para este estudo (próxima ou superior a 90%).

Na Figura 1(a), é possível analisar o valor de perda (*loss*) da rede neural ao longo de todo o treinamento. Esse valor representa a diferença entre o valor de saída da rede e o esperado para uma determinada entrada. 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.

Ao identificar o valor da sucesso no treinamento da rede, encontrou-se uma acurácia de ~89% após a execução em 100 épocas. Esse resultado preliminar chegou muito próximo do esperado para utilizar a rede em situação real. Quanto mais próximo a acurácia chega de 1, melhor a performance que está tendo a rede. A Figura 1(b) retrata o valor de acurácia de acordo com cada ciclo executado na CNN.

Foram utilizados 100 épocas para realizar o treinamento da CNN proposta, prin-

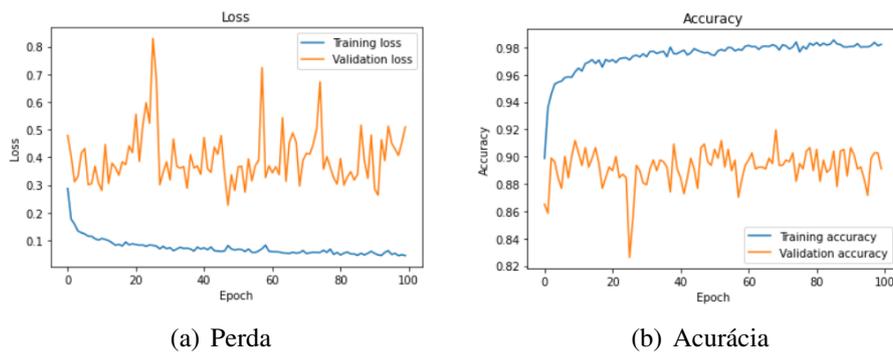


Figura 1. Gráficos dos valores de perda e de acurácia ao longo de 100 épocas.

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.

A Figura 2 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 de confusão e traz, na diagonal, os números de verdadeiros positivos. Já o restante dos quadrantes 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 duas 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.

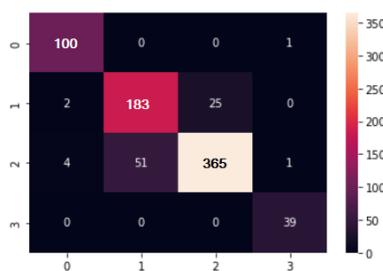


Figura 2. Matriz de confusão do modelo proposto.

Foi realizado o download do modelo treinado no *Google Colab*, considerando os pesos de cada classe definidos no treinamento. Posteriormente, esse modelo pode ser utilizado por aplicações de uso local. Para tanto, criou-se uma simples aplicação que permite a submissão de imagem, através de uma interface gráfica, para inferência no modelo. Nessa tela foi incluído um botão que, ao ser clicado, abre o explorador de arquivos, permitindo que o usuário escolha uma imagem de raio-X disponível para análise.

Ao selecionar a imagem desejada, o modelo CNN retorna um vetor de quatro 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. Computacionalmente, a posição 0 representa a 'COVID19', a 1 um pulmão 'NORMAL', a 2 'PNEUMONIA' e a 3 a 'TUBERCULOSE'. Na Figura 3 é possível visualizar uma imagem de raio-X que, ao passar pela análise do sistema, foi classificada com a possibilidade de ser 99% tuberculose (o sistema faz a conversão para um valor percentual, facilitando a leitura do usuário).

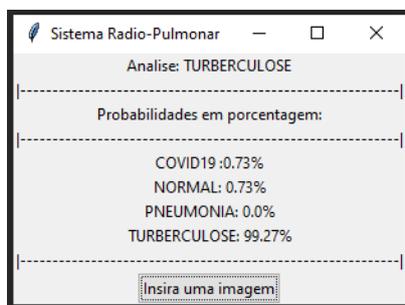


Figura 3. Tela após uma consulta de imagem para análise do modelo proposto.

5. Conclusão

Este trabalho apresentou uma proposta de sistema, baseado em CNN, para auxiliar radiologistas na sua rotina de trabalho. Através dos resultados obtidos, compreende-se que o desenvolvimento de um sistema de apoio ao diagnóstico, a partir de imagens de raios-X, como apresentado neste estudo, é viável. Para evoluir a solução, ainda é preciso executar o treinamento do modelo com mais épocas, como forma de melhorar e alcançar a acurácia mínima satisfatória. De todo modo, ao utilizar a *CNN* proposta, pode-se concluir que o objetivo deste estudo foi atingido com resultados preliminares.

Como trabalhos futuros, sugere-se desenvolver uma interface mais elaborada e criar um sistema de forma mais intuitiva, capaz de armazenar históricos e se comunicar com outras aplicações. Recomenda-se também a validação junto a médicos radiologistas, na prática, como forma de avaliar a usabilidade e a utilidade da solução. Além disso, é importante aumentar e balancear o conjunto de dados, como forma de aperfeiçoar sua predição no apoio à tomada de decisão. Para garantir a identificação do melhor momento para encerrar o treinamento, é recomendado executar o código em uma máquina que suporte mecanismos de Early Stopping e permita a execução de mais de 100 ciclos.

Referências

- 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>.
- Dezube, R. (2021). Diagnóstico por imagem do tórax. *Manual MSD Versão para Profissionais da Saúde*.
- Duarte, M. d. L. C. and Noro, A. (2013). Humanização do atendimento no setor de radiologia: dificuldades e sugestões dos profissionais de enfermagem. *Cogitare Enfermagem*, 18(3).
- FIPS (2023). Fips: X-ray tomographic datasets. Disponível em: <https://www.fips.fi/dataset.php> Acesso em: 01 Mar 2023. Finnish Inverse Problems Society.

- González, M. (2019). O que é acurácia? entenda o conceito e sua importância. Disponível em: <https://blog.idwall.co/o-que-e-acuracia/> Acesso em: 13 Abr 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 Fev 2022. Udemy: IA Expert Academy.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.
- Hussein, F., Mughaid, A., AlZu'bi, S., El-Salhi, S. M., Abuhaija, B., Abualigah, L., and Gandomi, A. H. (2022). Hybrid clahe-cnn deep neural networks for classifying lung diseases from x-ray acquisitions. *Electronics*, 11(19):3075.
- JTIPT (2021). Chest x-ray (pneumonia,covid-19,tuberculosis). Disponível em: <https://www.kaggle.com/datasets/jtiptj/chest-xray-pneumoniacovid19tuberculosis> Acesso em: 23 Fev 2022. Kaggle.
- Kaggle (2023). Find open datasets and machine learning projects - kaggle. Disponível em: <https://www.kaggle.com/datasets/> Acesso em: 01 Mar 2023.
- Nguyen, H. Q., Lam, K., Le, L. T., Pham, H. H., Tran, D. Q., Nguyen, D. B., Le, D. D., Pham, C. M., Tong, H. T. T., Dinh, D. H., Do, C. D., Doan, L. T., Nguyen, C. N., Nguyen, B. T., Nguyen, Q. V., Hoang, A. D., Phan, H. N., Nguyen, A. T., Ho, P. H., Ngo, D. T., Nguyen, N. T., Nguyen, N. T., Dao, M., and Vu, V. (2020). Vindr-cxr: An open dataset of chest x-rays with radiologist's annotations.
- 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.
- 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 Abr 2022. CONASS.
- Sharma, A., Rani, S., and Gupta, D. (2020). Artificial intelligence-based classification of chest x-ray images into covid-19 and other infectious diseases. *International journal of biomedical imaging*, 2020:1–10.
- 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*.
- van Leeuwen, K. G., de Rooij, M., Schalekamp, S., van Ginneken, B., and Rutten, M. J. (2021). How does artificial intelligence in radiology improve efficiency and health outcomes? *Pediatric Radiology*, pages 1–7.
- Yildirim, M., Eroğlu, O., Eroğlu, Y., Çınar, A., and Cengil, E. (2022). Covid-19 detection on chest x-ray images with the proposed model using artificial intelligence and classifiers. *New Generation Computing*, 40(4):1077–1091.