



MÉTODO DE PRÉ-DIAGNÓSTICO DA COVID-19 E PNEUMONIA UTILIZANDO IMAGENS DE RADIOGRAFIA DO TÓRAX E CNN

Amanda C. E. SOUZA¹; Diego SAQUI²

RESUMO

As redes neurais artificiais (RNAs) consistem em um modelo matemático que se assemelha à estrutura neural do cérebro humano. Esses neurônios artificiais adquirem aprendizado por meio da experiência e podem ser usados em atividades como diagnóstico por imagem, análise de dados comportamentais, previsões financeiras, entre outros. *Deep Learning* (DL) foi implementado utilizando múltiplas camadas de RNAs a fim de aprender e processar informações, sendo muito utilizado em tarefas de reconhecimento de imagens. Neste trabalho será utilizado um algoritmo de DL, as Redes Neurais Convolucionais (CNN) para criar um método de pré-diagnóstico da COVID-19 e Pneumonia, esse método será comparado com outros dois criados já existentes na literatura. A comparação visa identificar bons parâmetros e obter uma CNN eficiente. Os resultados demonstrados são parciais, pendente comparação com Tombetta et al. (2020)

Palavras-chave:

Redes Neurais Convolucionais; Detecção de patologias; Diagnóstico por imagem; Inteligência artificial; COVID-19.

1. INTRODUÇÃO

Em dezembro de 2019 surgiu na China a COVID-19, uma patologia que se disseminou globalmente causando uma pandemia. A Organização Mundial da Saúde (OMS) tomou medidas rápidas para evitar a proliferação do vírus e diminuir os casos de infectados, como o isolamento social, uso de máscara, higiene das mãos, uso de álcool em gel, entre outros (CRUZ, 2020).

A detecção da COVID-19 pode ser efetuada por meio de teste RT-PCR, o qual examina as secreções respiratórias em busca do material genético do vírus, e por testes de antígeno, os quais identificam a presença da proteína do SARS-CoV-2 em amostras de soro, plasma e sangue (Ministério da Saúde, 2021). A literatura demonstra que é viável a utilização de imagens de radiografia como ferramenta de diagnóstico para diversas patologias e destaca a eficácia das técnicas de aprendizado de máquina (AM) para otimizar esse processo. Portanto, é possível identificar a COVID-19 e a pneumonia utilizando imagens de radiografia do tórax.

Ao realizar um estudo da arte, os autores Silva et al. (2020) e Trombetta et al. (2020) constataram o crescimento do uso de Redes Neurais Convolucionais (do inglês *Convolutional Neural Network* - CNN) na classificação de imagens médicas. Esses estudiosos optaram por empregar essa técnica no desenvolvimento de um modelo de detecção automática de pneumonia causada pela COVID-19 em radiografias do tórax.

¹ Discente do Bacharelado em Ciência da Computação, IFSULDEMINAS – *Campus* Muzambinho. E-mail: 12171001948@muz.ifsuldeminas.edu.br.

² Orientador, IFSULDEMINAS – *Campus* Muzambinho. E-mail: diego.saqui@muz.ifsuldeminas.edu.br.

Neste contexto, objetiva-se avaliar a viabilidade de um método de pré-diagnóstico para COVID-19 e pneumonia utilizando imagens de radiografia torácica através da aplicação de CNN. Os trabalhos de Silva et al. (2020) e Trombetta et al. (2020) serão empregados para comparação do desempenho da classificação das imagens obtidas. Caso algum desses estudos se destaque, abre-se a possibilidade de desenvolver CNNs de configuração mais simples, tão eficiente quanto as complexas desenvolvidas nos estudos, usando parâmetros semelhantes aos previamente citados.

2. MATERIAL E MÉTODOS

O processo de desenvolvimento desse método iniciou-se pela análise da literatura onde foram selecionados os artigos de Silva et al. (2020) e Trombetta et al. (2020), visando replicar as CNNs complexas desenvolvidas por cada um dos autores. Silva et al. (2020) utilizaram quatro bases de dados: SIRM COVID-19, uma base pública do *GitHub*, coleta de imagens em artigos e a base de dados *chest x-ray* disponível no *Kaggle*. Já Trombetta et al. (2020) escolheram utilizar duas bases de dados do *Kaggle*: *Chest X-Ray Images* (Pneumonia), e o *dataset COVID-19 Chest XRay*.

Utilizando o ambiente de desenvolvimento *Colaboratory* disponibilizado pelo Google, pretende-se combinar os *datasets Chest X-Ray Images* (Pneumonia)³ e *COVID-19 Image Data Collection: Prospective Predictions Are the Future*⁴ com o propósito de aumentar a variedade e a quantidade de imagens disponíveis, totalizando um conjunto de 6419 imagens. Dentre as imagens, 563 são da categoria COVID-19, 4273 retratam casos de pneumonia, e 1583 correspondem à categoria normal (pacientes saudáveis).

Diante da falta de informações detalhadas sobre o desenvolvimento das CNNs, optou-se por reproduzir determinados trechos dos modelos descritos nos artigos originais para uma análise comparativa entre os estudos. Em seu modelo, Silva et al. (2020) utilizou 2905 imagens em 3 categorias: 1341 imagens de pneumonia, 1345 correspondentes ao estado normal, e 219 associadas à COVID-19. Em seguida os autores normalizaram as imagens em 75x75 pixels e as dividiram em 70% para treino e 30% para teste. A mesma proporção e configuração dos dados foi utilizada na etapa de treinamento da CNN clássica. A abordagem de Trombetta et al. (2020) ainda será feita.

A CNN proposta neste estudo segue uma arquitetura clássica, recebendo diversos filtros, cujos valores são ajustados na etapa de treinamento para obtenção de características distintas a partir da entrada. A camada de *pooling* reduz a quantidade de informações a serem processadas nas camadas subsequentes e passa para a camada totalmente conectada, onde as características extraídas das camadas anteriores serão combinadas e produzirão a saída final.

Para criar e treinar a CNN, alguns hiperparâmetros propostos por Silva et al. (2020) foram

³ <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia> Acesso em Agosto/2023


⁴ <https://github.com/ieee8023/covid-chestxray-dataset> Acesso em Agosto/2023

replicados. A função *Softmax* foi adotada na camada de saída, a métrica *Categorical Crossentropy* para calcular o custo em problemas de múltiplas classes. Para otimização do modelo, usou-se o *Adaptive Moment Estimation (ADAM)*, a quantidade de épocas fixada em 200. A fim de mitigar o *overfitting*, uma taxa de *dropout* de 0,5 foi implementada. O tamanho do lote (*batch*) foi estipulado como 64, e a taxa de aprendizagem iniciou-se em 1×10^{-3} , sendo multiplicada da seguinte forma: época 81 em 1×10^{-1} , época 121: 1×10^{-2} , 1×10^{-3} na época 161 e época 181 por $0,5 \times 10^{-3}$. Esse progressivo ajuste da taxa de aprendizagem teve como objetivo principal alcançar uma acurácia consistente, com baixo desvio padrão, nas fases finais da rede. Após a criação da CNN e treinamento, procedeu para a etapa de avaliação dos resultados.


3. RESULTADOS E DISCUSSÃO

A avaliação da CNN desenvolvida seguiu os critérios de Silva et al. (2020), usando acurácia como métrica. Isso envolveu monitorar a acurácia durante treino/teste em cada época e analisar as matrizes de confusão dos modelos. Ao comparar os resultados, a arquitetura *ResNetX50* proposta pelos autores obteve o melhor resultado (Fig. 1a e 1b), iniciando com uma acurácia próxima de 90% e progredindo constantemente, até se estabilizar em 100% perto da 100ª época. Já na Fig. 1c pode-se notar que a CNN clássica apresentou uma acurácia inicial de 80%, aumentou para 90%, mostrou variações, mas mantendo-se em torno desse valor entre as épocas 75 e 200.

Figura 1a, 1b e 1c: Acurácia no treinamento e teste dos modelos aplicados.



Fonte: Silva et al. (2020)




c) Treinamento e Teste da CNN clássica

Fonte: Autoria própria (2023)

Na matriz de confusão de Silva et al. (2020) a arquitetura *ResNetX50* (Fig. 2c) acertou 100% na classificação da COVID-19. A Figura 2a exibe a matriz de confusão da CNN clássica. Apesar dos autores mencionarem ter utilizado 30% das imagens para teste, é possível constatar que os valores presentes nas matrizes das Fig. 2b e 2c não estão coerentes com a proporção total esperada para esse conjunto de imagens.

Figura 2a Matriz de confusão da CNN clássica, **2b e 2c** Matrizes de confusão dos modelos aplicados por Silva et al. (2020)



4. CONCLUSÃO

A comparação do modelo de Silva et al. (2020) e o proposto neste estudo, mostra que o uso dos parâmetros indicados por Silva na CNN clássica resultou em 93% de precisão. No entanto, o método de Silva et al. (2020) continua mais eficaz no pré-diagnóstico de COVID-19 e pneumonia. Os resultados encontrados são parciais, pendente comparação com Tombetta et al. (2020).

REFERÊNCIAS

CRUZ, Roberto Moraes et al. COVID-19: emergência e impactos na saúde e no trabalho. **Revista Psicologia Organizações e Trabalho**, v. 20, n. 2, p. I-III, 2020.

MINISTÉRIO DA SAÚDE. **Diagnóstico**. Ministério da Saúde. Disponível em: <https://www.gov.br/saude/pt-br/coronavirus/diagnostico>. (2021).

SILVA, Luan et al. **Aplicação de Deep Learning no pré-diagnóstico da COVID-19 através de imagens de Raio-X**. 2020. 11 p.

TROMBETTA, Giordano Bruno 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.