

Detecção de COVID-19 em Imagens de Raio-X de Tórax através de Seleção Automática de Pré-processamento e de Rede Neural Convolutacional

João O. B. Diniz^{1,2}, Darlan B. P. Quintanilha², Antonio O. de Carvalho Filho³, Daniel L. Gomes Jr¹, Aristófanés C. Silva², Geraldo Braz Jr², Anselmo C. de Paiva², Daniel de S. Luz⁴

¹Fábrica de Inovação – Instituto Federal Do Maranhão
Maranhão – Brazil

²Núcleo de Computação Aplicada – Universidade Federal do Maranhão
Maranhão – Brazil

³Universidade Federal do Piauí
Piauí – Brazil

⁴Instituto Federal do Piauí
Piauí – Brazil

joao.bandeira@ifma.edu.br

Abstract. COVID-19, even with a decrease in cases, is still considered a global problem, its early detection is still relevant and can be crucial to save lives. This paper presents a method for automatic detection of COVID-19 in chest X-ray images using automatic image enhancement selection and convolutional neural network. The method uses an image pre-processing technique to enhance the distinctive features of COVID-19 in the X-ray and selects a convolutional neural network to classify the images. The results show relevant metrics with an accuracy of 99.39% and F1 – Score of 98.71%. This approach could be valuable for effective disease screening, improving treatment, and reducing COVID-19-related deaths.

Resumo. A COVID-19, mesmo com diminuição dos casos, é considerado um problema global, a detecção precoce ainda é relevante e pode ser crucial para salvar vidas. Este artigo apresenta um método para detecção automática de COVID-19 em raio-X de tórax usando seleção automática de melhoria de imagem e rede neural convolutacional. O método usa pré-processamento de imagem para melhorar as características distintivas da COVID-19 em raio-X e seleciona uma rede neural convolutacional para classificar as imagens. Os resultados mostram métricas relevantes com uma acurácia de 99,39% e F1 – Score de 98,71%. Essa abordagem pode ser valiosa para a triagem eficaz da doença, melhorando o tratamento e reduzindo as mortes relacionadas à COVID-19.

1. Introdução

A partir de dezembro de 2019, a OMS relatou problemas com pneumonia não identificada em Wuhan, China, que rapidamente se tornou um problema emergencial de saúde global.

Em janeiro de 2020, essa doença foi identificada como a causa de morte em vários continentes, e posteriormente nomeada como SARS-CoV-2, ou COVID-19, como a causa de vários casos de pneumonia [Organization et al. 2020].

Comparado a outros problemas respiratórios, como a síndrome respiratória aguda grave (SARS) e a síndrome respiratória do Oriente Médio (MERS), a COVID-19 é a que tem o maior número de contágios em um menor período de tempo [Petrosillo et al. 2020]. O mundo inteiro está procurando respostas e soluções para erradicar essa pandemia, vários estudos de caso foram desenvolvidos para investigar as características particulares dessa doença. Um dos principais mecanismos de estudo que fornece vários subsídios aos especialistas na avaliação de Raio-X de Tórax (do inglês, Chest X-Ray - CXR) [El-Din Hemdan et al. 2020]. Muitos métodos computacionais são propostos para auxiliar os especialistas, a Detecção e Diagnóstico Assistidos por Computador (CAD e CADx) desempenham um papel importante para ajudar este médicos [Rodrigues et al. 2022, Diniz et al. 2021, Silva et al. 2021, Júnior et al. 2021].

Sabendo a importância da classificação de imagens de CXR para diagnóstico de COVID-19 e a necessidade de sistemas automáticos robustos para esta tarefa, o presente trabalho tem o objetivo de classificar imagens de CXR em normal ou COVID-19 usando uma técnica de seleção automático de melhoramento de imagens e seleção automática de rede neural convolucional mais adequada para o problema.

Como principais contribuições, pode-se destacar:

- Desenvolvimento de uma técnica automática para seleção de melhor conjunto de filtros para melhoramento baseada em aprendizado profundo;
- Seleção da melhor arquitetura de aprendizado profundo para classificação de imagens de CXR de pacientes normais e com COVID-19;
- Um método completamente automático e expansivo, baseado em processamento de imagens e aprendizado profundo capaz de melhorar a detecção e diagnóstico de COVID-19.

Em sequência, a Seção 2 resume os trabalhos relacionados, a Seção 3 descreve o método, a Seção 4 apresenta resultados, comparações e discussões do método, e a Seção 5 delinea as conclusões e trabalhos futuros.

2. Trabalhos Relacionados

Devido ao sucesso de técnicas baseadas em Inteligência Artificial para diagnosticar doenças no campo da medicina e ao aumento drástico de casos de COVID-19 em todo o mundo, há a necessidade de sistemas automáticos para detecção e diagnóstico usando técnicas consolidadas, como os de aprendizado profundo. A seguir, é apresentado alguns trabalhos considerados estado da arte para classificação de imagens de CXR de COVID-19.

No trabalho recente de [Narin et al. 2020], modelos baseados em redes neurais convolucionais (ResNet50, InceptionV3 e Inception-ResNetV2) foram aplicados para detecção de pacientes infectados por COVID-19, e obtiveram 98% de acurácia no melhor desempenho. [Apostolopoulos and Mpesiana 2020] também usaram diferentes modelos de aprendizado profundo pré-treinados e alcançaram 98,75% de acurácia e 92,85% de sensibilidade usando duas classes (COVID-19 vs condições normais).

Em [El-Din Hemdan et al. 2020] e [Zhang et al. 2020] também apresentaram resultados expressivos para a detecção de pacientes com COVID-19 usando imagens CXR. Nos dois estudos, diversos modelos de redes neurais convolucionais foram usadas para verificar o desempenho na detecção de COVID-19. Em [El-Din Hemdan et al. 2020], alcançaram resultados de 90% de acurácia para a classe normal e COVID-19, respectivamente. No [Zhang et al. 2020], foram obtidos um sensibilidade de 96% nos casos de COVID-19 e 70,65% de especificidade nos casos normais.

No estudo de [Ozturk et al. 2020], também desenvolveram um modelo (DarkCovidNet) para classificação binária e multiclasse. O DarkCovidNet é inspirado no sistema de detecção de objetos chamado YOLO. O modelo produziu uma acurácia de 98,08% para classes binárias e 87,02% para multiclasse. [Sethy and Behera 2020] classificaram as características obtidas do modelo ResNet50 com o classificador Support Vector Machine (SVM) e apresentam um desempenho de 95,38% de acurácia e 91,41% de F1-score para detecção de COVID-19. Em [Rahimzadeh and Attar 2020], foi proposto uma rede neural, que é uma concatenação das redes Xception e ResNet50V2 para detecção de casos de COVID-19. A acurácia foi de 99,50%, precisão 35,27% e sensibilidade 80,53% para detecção de COVID-19.

O trabalho de [Júnior et al. 2021] apresentou um método para classificação de pacientes de COVID-19 usando CNN como extrator de características e o xGBoost com hiperparâmetros otimizados pelo algoritmo de enxame de partícula (PSO). No melhor cenário, o trabalho alcançou uma precisão de 98,71%, uma precisão de 98,89%, uma sensibilidade de 99,63% e um F1-score de 99,25%.

Embora todas essas abordagens tenham alcançado bons resultados, ainda há muito a ser feito, principalmente pelo fato que poucos trabalhos investem no melhoramento da imagens através de pré-processamento de imagens. Ainda, praticamente todos trabalhos publicados até então sugerem o uso de demasiado de redes neurais convolucionais profundas, contudo, não há um estudo evidenciando a comparação da melhor rede para o problema aliado a este melhoramento proposto.

Assim, este trabalho tem como objetivo, propor uma forma automática (baseado em aprendizado profundo) de seleção de melhor técnica de melhoramento de imagens e de seleção do melhor modelo de aprendizado profundo para classificação em imagens normais e de COVID-19.

3. Materiais e Método

Esta seção é descrito o método proposto por este artigo. Basicamente, o método é composto de 4 passos. O primeiro é a base de dados, onde descrevem-se a base de dados que foi utilizada. O segundo apresenta a etapa de seleção de melhor filtro de pré-processamento automático baseado em redes neural convolucional (do inglês, *convolutional neural network*, CNN). A terceira etapa do método é a seleção de melhor modelo de CNN para classificação das imagens pré-processadas. Por fim, a bases de dados é pré-processada pelo melhor filtro e treinadas pelo melhor modelo e as métricas de validação são extraídas. Figura 1 apresenta um resumo das etapas do método proposto.

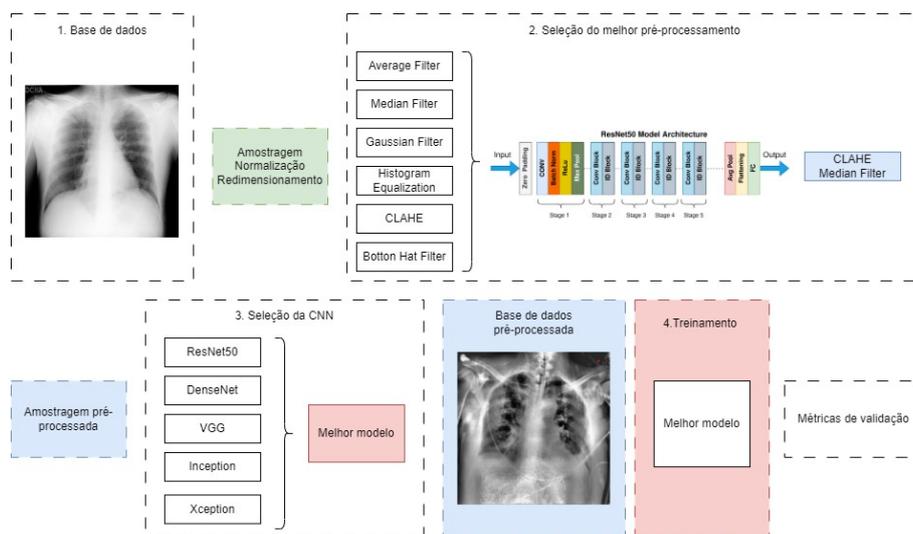


Figura 1. Método proposto.

3.1. Base de dados

Neste trabalho foi utilizado a base de dados *COVID-19 Radiography Database* disponível online no *Kaggle*¹. Uma equipe de pesquisadores de várias universidades e países criou um banco de dados de imagens de radiografia torácica para casos de COVID-19, pneumonia normal e viral em colaboração com médicos [Chowdhury et al. 2020]. A base de dados continua sendo alimentada com casos de COVID-19. Todavia, no momento de download para desenvolvimento do método, existiam 423 casos de COVID-19 e 1341 casos normais (aproximadamente uma proporção de 1:3).

Sabe-se que métodos baseado em CNN necessitam de grande recurso computacional para treinamento. Além disso, algumas imagens possuíam dimensões variadas. Assim, antes da etapa de seleção de melhor pré-processamento, primeiramente uma amostra de 300 casos normais e 100 de COVID-19 foram escolhidos aleatoriamente da base de dados (mantendo a proporção de 1:3). Em seguida, todas imagens foram redimensionadas para 224×224 , de acordo com [Júnior et al. 2021] é um tamanho adequado para processamento adicional dentro do pipeline de aprendizado profundo. Agora, o conjunto de amostragem irá passar pelas demais etapas de seleção de melhor pré-processamento e de modelo.

3.2. Seleção do Melhor Pré-processamento

Nesta seção será descrito as etapas necessárias para a seleção do melhor pré-processamento nas imagens de CXR. Em seguida, elas são descritas com mais detalhes.

3.2.1. Definição de filtros

Primeiramente, são definidos os filtros que serão utilizados, vale destacar que como é uma abordagem automática e extensiva é possível definir outros filtros ou até mesmo aumentar a quantidade. Contudo, devido ao tempo e carga computacional, foram escolhidos seis

¹<https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>

filtros de processamento de imagens ([Gonzalez and Woods 2008]), descritos (resumidamente) abaixo:

1. Filtro da média (Average Filter): é um filtro linear que funciona calculando a média de um conjunto de pixels vizinhos para cada pixel na imagem. Isso resulta em uma redução no ruído de alta frequência na imagem, embora possa levar a uma perda de detalhes finos.
2. Filtro da mediana (Median Filter): é um filtro não linear que funciona substituindo cada pixel na imagem pelo valor da mediana de um conjunto de pixels vizinhos. A mediana é o valor que está no meio do conjunto de valores ordenados.
3. Filtro gaussiano (Gaussian Filter): é um filtro linear que é usado para suavizar imagens, mas preservando mais detalhes em relação ao filtro de média. O filtro de Gaussiana é eficaz em reduzir o ruído de alta frequência enquanto preserva detalhes finos na imagem.
4. Equalização do Histograma (Histogram Equalization): é uma técnica de processamento de imagens que visa melhorar o contraste da imagem, tornando-a mais nítida e fácil de visualizar.
5. CLAHE (Contrast Limited Adaptive Histogram Equalization): é uma extensão da técnica de equalização do histograma que leva em conta as diferenças locais na distribuição de intensidades de pixel. Em vez de aplicar a equalização do histograma globalmente na imagem inteira, a CLAHE divide a imagem em blocos menores e aplica a equalização do histograma em cada bloco individualmente.
6. Filtro Bottom Hat (Bottom Hat Filter): é realizada aplicando-se uma operação de fechamento seguida de uma operação de abertura sobre a imagem original. A imagem resultante é subtraída da imagem original, realçando assim as pequenas regiões escuras que foram fechadas pela operação de fechamento.

Com os filtros definidos, a próxima etapa é definir uma CNN para executar no conjunto de amostras definidos na seção anterior.

3.2.2. Definição da CNN para Pré-processamento

Nesta etapa do método, é preciso ser definido uma CNN para ser utilizada. Destaca-se, novamente, que é um método expansível e qualquer outra rede poderia ser utilizada nesse passo. Contudo, escolheu-se a ResNet [He et al. 2016], devido o fato que em método de visão computacional, já que ela tem capacidade de lidar com redes muito profundas sem perder desempenho.

A principal inovação da ResNet é o uso de blocos residuais, que permitem a construção de redes muito mais profundas do que as tradicionais sem sofrer degradamento no desempenho. Isso é possível graças a conexões "pula-uma" (skip connections) que permitem que a informação do caminho original da rede seja mantida, mesmo quando novas camadas são adicionadas. Essas conexões ajudam a resolver o problema de degradação do desempenho que ocorre em redes muito profundas, pois permitem que o gradiente flua mais facilmente através da rede [He et al. 2016].

Neste trabalho, foi utilizado a mesma arquitetura e hiperparâmetros tradicional proposta por [He et al. 2016] e disponível pela biblioteca *Keras* [Chollet et al. 2015].

3.2.3. Definição de Melhores Filtros

Para definir qual melhor pré-processamento, vale destacar que não apenas um filtro pode ser suficiente, um conjunto deles aplicado em sequência pode ser mais eficiente para melhoramento da imagem. Assim, esta etapa selecionará os conjunto de filtros.

Primeiramente, as imagens da amostragem definida na Seção 3.1 passaram pelos 6 filtros definidos na Seção 3.2.1, então 6 conjuntos de dados com filtros aplicados são criados. Em seguida, estes conjuntos de dados são divididos em treino:teste aleatoriamente na proporção 80:20. Logo, as métricas de validação são extraídas para os 6 conjuntos de teste e aquele que apresentar melhor métrica *F1-Score* é selecionado como o melhor filtro dessa rodada.

Com o primeiro filtro selecionado, este é aplicado em 5 conjuntos de dados novos que passarão por uma nova seleção de um segundo filtro. Como já foi escolhido o primeiro, este não precisará ser usado na segunda rodada. Assim, os 5 conjuntos com o primeiro filtro mais a aplicação do segundo filtro serão treinados e testados. Se no teste algum deles apresentar melhor *F1-Score* que a primeira rodada, este será selecionado como novo melhor pré-processamento. A Figura 2 ilustra a etapa da seleção de melhor pré-processamento.

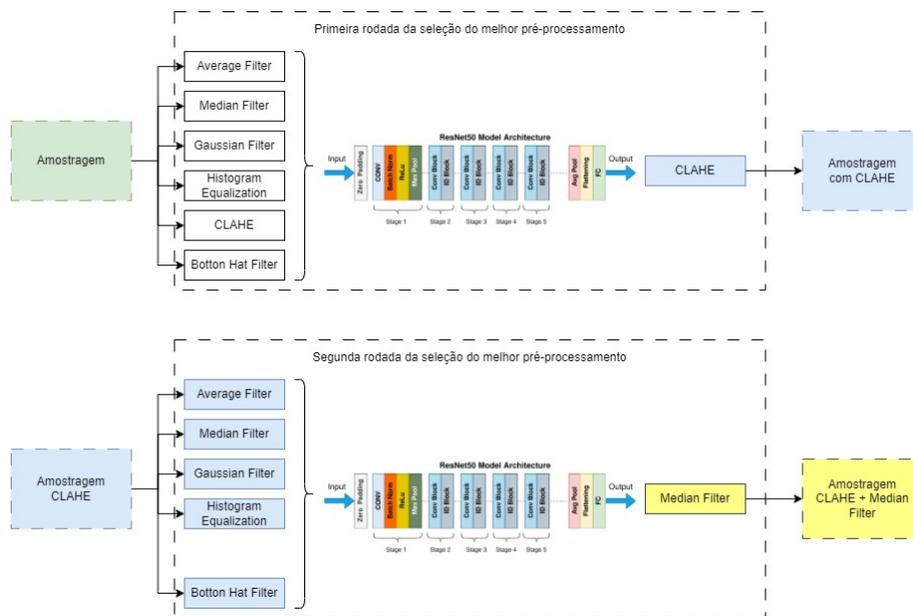


Figura 2. Exemplo de seleção de melhor pré-processamento.

O processo de seleção de novo filtro irá continuar acontecendo até que a métrica apresente melhora, caso contrário, é pausado o processo. Na Figura 2 mostra um exemplo de dois filtros sendo selecionados para o pré-processamento.

3.3. Seleção de Melhor Arquitetura CNN

Com o pré-processamento definido, a próxima etapa é a seleção da melhor CNN para classificação desses pacientes já realçados na etapa anterior. Para isso, foram selecionadas cinco CNN muito utilizadas que alcançam estado da arte em suas tarefas. Novamente

destaca-se que o modelo é expansível e neste passo novas ou outras CNNs podem ser utilizadas. A seguir, descreve-se brevemente cada uma dessas CNNs:

1. ResNet [He et al. 2016]: é uma arquitetura que foi projetada para melhorar o desempenho em conjuntos de dados muito grandes. Ela utiliza blocos residuais que ajudam a prevenir o problema de degradação de redes muito profundas. É uma escolha comum para tarefas de classificação de imagens.
2. DenseNet [Huang et al. 2017]: essa arquitetura utiliza ligações densas entre as camadas da rede neural. Cada camada recebe as entradas de todas as camadas anteriores e envia suas saídas para todas as camadas subsequentes. Isso ajuda a melhorar o fluxo de informações através da rede e reduz o número de parâmetros necessários.
3. VGG [Simonyan and Zisserman 2014]: é uma das arquiteturas mais simples e populares para classificação de imagens. Ela utiliza convoluções em tamanho fixo de 3x3 e camadas de pooling para extrair características de imagens. Ela é conhecida por seu desempenho consistente, mas pode ser lenta e requer muitos recursos computacionais.
4. Inception [Szegedy et al. 2016]: foi projetada para extrair características de diferentes escalas em uma imagem. Ela utiliza convoluções de diferentes tamanhos em paralelo e as combina em uma única camada. Isso ajuda a melhorar a precisão da classificação em imagens complexas.
5. Xception [Chollet 2017]: utiliza separação de canais e profundidade para extrair características das imagens. Ela utiliza convoluções separáveis em profundidade, que executam convoluções separadamente em cada canal da imagem e em seguida, combinam os resultados. Isso ajuda a reduzir o número de parâmetros e a melhorar o desempenho em conjuntos de dados com alta variação de características.

Com a amostragem e o melhor pré-processamento definidos, cinco conjuntos de dados pré-processados passam por treino:teste na proporção de 80:20 correspondendo a cinco arquiteturas escolhidas. Aquele que apresentar melhor métrica de *F1-Score* é mantido como melhor arquitetura de CNN. Vale destacar que a métrica equivalente a ResNet foi calculada na etapa anterior, então apenas 4 treinamentos (DenseNet, VGG, Inception, Xception) são feitos nesta etapa. Ainda, destaca-se que foram utilizadas as arquiteturas conforme autores originais e disponibilizadas pela biblioteca *Keras* [Chollet et al. 2015].

3.4. Treinamento e Teste

Por fim, após a escolha do melhor conjunto de filtros, i.e., melhor pré-processamento e melhor arquitetura de CNN é hora de construir o modelo. Primeiramente, toda a base de dados passa pelo pré-processamento, em seguida, o modelo é treinado usando a melhor arquitetura escolhida. Por fim, métricas de validação são calculadas para verificar a robustez do método.

As seguintes métricas foram utilizadas para a avaliação dos resultados:

- Acurácia (ACC) = $(VP + VN) / (VP + VN + FP + FN)$
- Precisão (PREC) = $VP / (VP + FP)$
- Sensibilidade (SEN) = $VP / (VP + FN)$
- F1-score (F1) = $2 * (PREC * SEN) / (PREC + SEN)$

Onde VP representa os verdadeiros positivos, VN os verdadeiros negativos, FP os falsos positivos e FN os falsos negativos.

4. Resultados e Discussão

Nesta seção são descritos os resultados alcançados pelo método proposto de detecção automática de COVID-19 em CXR. Também é apresentado experimentos que levaram a criação do modelo proposto e uma comparação com os trabalhos relacionados.

Para desenvolvimento do método, foi utilizado um CPU Intel® Core™ i7 CPU @ 2.90GHz, GPU Nvidia® RTX-3060 12GB, 16GB de memória RAM e Sistema Operacional Windows 11 Pro. O ambiente de treinamento foi configurado com a instalação das bibliotecas necessárias, como OpenCV e Keras.

4.1. Etapas do Método

Serão descritos os passos do método e os resultados alcançados nas etapas de seleção automática de pré-processamento e arquitetura. Todas as arquiteturas de CNN foram treinadas conforme a arquitetura padrão disponibilizada pela biblioteca Keras com os seguintes hiperparâmetro: otimizador Adam com taxa de aprendizado de 0,001, um *batch size* de 16 foram selecionados, e *early stopping* com 50 épocas.

Primeiramente, foram retiradas amostras da base de dados (Seção 3.1), onde foram usadas 100 imagens de pacientes normais e 300 de pacientes com COVID-19, observando a proporção já existente de 1:3. Em seguida, essa amostragem foi normalizada e redimensionada para 224×224 . Por sua vez, essa amostra foi apresentada a etapa de seleção de melhor pré-processamento, apesar de ser um método expansível, neste trabalho optou-se por utilizar apenas 6 filtros. Vale destacar que os *kernels* utilizados por todos os filtros foi de 3×3 .

Foi possível escolher a sequência de dois pré-processamento, CLAHE seguido de Filtro da Mediana, após duas rodadas não houve melhora na métrica de *F1 – Score*. Logo, acredita-se que esses dois filtros foram os mais robustos para enaltecer as características que tornam distintos pacientes com e sem COVID-19. Pela sua própria natureza, o CLAHE faz uma equalização local dos valores de pixels levando em consideração características locais. Contudo, isto deixa a imagem com algumas diferenças locais, logo, suavizar a imagem com o filtro da mediana pode contornar esse problema. A Tabela 1 apresenta três rodadas de treinamento com sequência de filtros.

Tabela 1. Resultados da etapa de seleção de melhor pré-processamento

| Primeira Rodada | | Segunda Rodada | | Terceira rodada | |
|---------------------------|----------------------|---------------------------|----------------------|---------------------------|----------------------|
| Filtros | <i>F1 – Score(%)</i> | Filtros | <i>F1 – Score(%)</i> | Filtros | <i>F1 – Score(%)</i> |
| Média | 95.12 | Média | 95.12 | Média | 94.85 |
| Mediana | 93.68 | Mediana | 96.23 | | |
| Gaussiana | 94.87 | Gaussiana | 94.92 | Gaussiana | 94.43 |
| Equalização do Histograma | 95.03 | Equalização do Histograma | 95.67 | Equalização do Histograma | 95.76 |
| CLAHE | 95.92 | | | | |
| Botton Hat | 94.55 | Botton Hat | 94.77 | Botton Hat | 95.21 |

Observa-se que a partir da segunda rodada, não houve melhora então o algoritmo para, e define os filtros em sequência como os melhores (CLAHE + Filtro da Mediana).

Com o pré-processamento definido, a próxima etapa é o treinamento das arquitetura a fim de selecionar a melhor para o problema. Destaca-se novamente que o método é expansível, e esta foram as redes mais comum encontras e por isso foram as definidas inicialmente. A Tabela 2 descreve o resultado para a amostra pré-processada.

Tabela 2. Resultados da etapa de seleção de melhor arquitetura

| Arquitetura | $F1 - Score(\%)$ |
|-----------------|------------------|
| ResNet | 96.23 |
| DenseNet | 95.92 |
| VGG | 96.87 |
| Inception | 97.85 |
| Xception | 97.92 |

Observar-se que a Xception foi a que apresentou o melhor resultado, logo, esta foi escolhida como melhor arquitetura. Vale destacar que entre as redes não há uma diferença tão significativa de métricas, todavia, apenas uma amostra foi treinada para seleção desta arquitetura e acredita-se que esse impacto pode ser maior quando aumentar o número de amostra para a base de dados completa. Assim, ao fim das duas primeiras etapas, a sequência de filtros escolhidos e a arquitetura estão definidas. A próxima etapa é o treinamento e teste em toda a base de dados.

Agora a fim de validar a seleção apresentada, faz-se uma validação cruzada da base de dados onde esta é dividida em 5 – *folds* e as métricas de validação são calculadas. A Tabela 3 apresenta o resultado das métricas seguidas do desvio padrão.

Tabela 3. Resultados da etapa de treinamento com 5 – *folds*, média e desvio padrão

| Fold | ACC(%) | PREC(%) | SEN(%) | $F1 - Score(\%)$ |
|----------------------|-----------------|-----------------|----------------|------------------|
| 1 | 99,51 | 98,01 | 99,42 | 98,43 |
| 2 | 99,02 | 98,12 | 98,85 | 98,78 |
| 3 | 99,33 | 98,83 | 99,57 | 98,21 |
| 4 | 99,61 | 99,07 | 99,72 | 99,16 |
| 5 | 99,49 | 98,64 | 99,49 | 98,99 |
| Média | 99,39 | 98,53 | 99,41 | 98,71 |
| Desvio Padrão | 0,230911 | 0,456103 | 0,33234 | 0,391829 |

Constata-se que o método proposto alcançou resultados expressivos na tarefa de detecção de COVID-19 nesta base de dados. Atribui-se isto ao fato, principalmente, da seleção automática tanto de pré-processamento (que realçou estruturas e características importantes para essa melhor distinção), quanto da arquitetura. Assim, acredita-se que o método pode ser crucial no auxílio de médicos especialista no enfrentamento a COVID-19, que apesar de redução no número de casos, ainda é um problema global.

4.2. Comparação com a Literatura

Com o intuito de comparar o trabalho proposto com os apresentados na literatura e na Seção 2, apresenta-se a Tabela 4.

Nota-se que este são alguns trabalhos apresentados na literatura, em sua maioria no ápice da pandemia no ano de 2020. Ainda assim, pode-se observar que o método proposto tem local de destaque, apresentando a segunda melhor acurácia entre os trabalhos selecionados. Em questão de precisão, sensibilidade e $F1 - Score$, o método só não é superior a [Júnior et al. 2021], contudo, apresenta melhor acurácia que o mesmo. Desta forma, acredita-se que o método é promissor e replicável em outros problemas de visão computacional, sendo uma ferramenta importante nestes cenários.

Tabela 4. Comparação com os trabalhos relacionados.

| Trabalhos | ACC(%) | PREC(%) | SEN(%) | F1 – Score(%) |
|------------------------------------|--------------|--------------|--------------|---------------|
| [Narin et al. 2020] | 98 | - | - | - |
| [Apostolopoulos and Mpesiana 2020] | 98.75 | - | 92.85 | - |
| [El-Din Hemdan et al. 2020] | 90 | - | - | - |
| [Zhang et al. 2020] | 96 | - | - | - |
| [Ozturk et al. 2020] | 98.08 | - | - | - |
| [Sethy and Behera 2020] | 95.38 | - | - | 91.41 |
| [Rahimzadeh and Attar 2020] | 99.50 | 35.27 | 80.53 | - |
| [Júnior et al. 2021] | 98,89 | 98,71 | 99,63 | 99,25 |
| Método Proposto | 99,39 | 98,53 | 99,41 | 98,71 |

4.3. Vantagens e Limitação do Método Proposto

Acredita-se que o método apresenta vantagens e limitações. Listam-se como vantagens:

- A seleção automática de pré-processamento trouxe além de melhorias na métrica de validação, uma vantagem de encontrar filtros que melhor realce as estruturas da imagem;
- Sabe-se que existem inúmeras arquiteturas de CNN e sua escolha depende de cada problema e dos dados coletados, logo, a escolha automática desta arquitetura pode ser crucial para o aumento das métricas de validação e, no método proposto, a alta acurácia sugere que ele é confiável e pode ser útil para triagem e detecção de casos positivos de COVID-19;
- Além disso, destaca-se a parte expansível do método, onde novos filtros e arquiteturas podem ser adicionados a fim encontrar novos conjuntos de pré-processamento e arquitetura mais adequada;
- Ainda, acredita-se que o mesmo método pode ser usado em outras bases de dados para poupar tempo na definição das etapas de seleção de filtros e arquitetura adequada;
- Por fim, com o método robusto apresentado, pode-se conseguir a detecção precoce e eficaz, logo uma chance menor de propagação da doença, o que pode levar à redução do número de mortes relacionadas à COVID-19.

Porém, ainda existem limitações no método, listam-se:

- A etapa de seleção de filtros utiliza um *kernel* padrão. Automatizar essa escolha pode melhorar ainda mais os resultados;
- Os hiperparâmetro da rede e suas arquiteturas são padrões. A seleção automática desses hiperparâmetro ou até mesmo de inserção de camadas pode trazer melhoria ao método;
- Além disso, testes com outras bases de dados poderão validar ainda mais as etapas de seleção automática.

Contudo, acredita-se que o método, além de robusto, é replicável para outros problemas trazendo rapidez e precisão. Aplicado a COVID-19, o método trouxe resultados expressivos comparado a literatura, assim a detecção automática pode ajudar na identificação precoce de casos de COVID-19, o que pode levar a um tratamento mais rápido e eficaz e, consequentemente, salvar vidas.

5. Conclusão

O método apresentado demonstrou ser uma ferramenta promissora para a detecção automática de COVID-19 em imagens de raio-X. A acurácia obtida na detecção de casos

positivos de COVID-19 pode ajudar na identificação precoce de pacientes com a doença, permitindo um tratamento mais rápido e eficaz e, assim, salvar vidas. Ainda, desenvolveu-se etapas cruciais de seleção de melhor pré-processamento e melhor arquitetura, o que torna o método mais robusto ainda. Por fim, destaca-se que o método é expansível, podendo ser inserido novos filtros e arquitetura e até mesmo o uso de outras bases de dados.

Os trabalhos futuros para o método incluem a exploração de melhorias na etapa de seleção de pré-processamento de imagem como seleção automática de *kernel* e na arquitetura da rede neural convolucional, como seleção de hiperparâmetros e camadas novas. A validação do método em diferentes conjuntos de dados e contextos clínicos, e a integração do método em sistemas de diagnóstico de imagem existentes também podem ser destacados como passos futuros.

6. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Empresa Brasileira de Serviços Hospitalares (Ebserh) Brazil (Proc. 409593/2021-4).

Referências

- Apostolopoulos, I. D. and Mpesiana, T. A. (2020). Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, page 1.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258.
- Chollet, F. et al. (2015). Keras. <https://keras.io>.
- Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., Islam, K. R., Khan, M. S., Iqbal, A., Al Emadi, N., et al. (2020). Can ai help in screening viral and covid-19 pneumonia? *Ieee Access*, 8:132665–132676.
- Diniz, J., Ferreira, J., Silva, G., Quintanilha, D., Silva, A., and Paiva, A. (2021). Segmentação de coração em tomografias computadorizadas utilizando atlas probabilístico e redes neurais convolucionais. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 83–94, Porto Alegre, RS, Brasil. SBC.
- El-Din Hemdan, E., Shouman, M. A., and Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. *arXiv*, pages arXiv–2003.
- Gonzalez, R. and Woods, R. (2008). *Digital image processing*. Pearson, Prentice Hall.
- 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.
- Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708.

- Júnior, D. A. D., da Cruz, L. B., Diniz, J. O. B., da Silva, G. L. F., Junior, G. B., Silva, A. C., de Paiva, A. C., Nunes, R. A., and Gattass, M. (2021). Automatic method for classifying covid-19 patients based on chest x-ray images, using deep features and pso-optimized xgboost. *Expert Systems with Applications*, 183:115452.
- Júnior, D. D., Cruz, L., Diniz, J., Júnior, G. B., and Silva, A. (2021). Classificação automática de glóbulos brancos usando descritores de forma e textura e extreme gradient boosting. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 95–106, Porto Alegre, RS, Brasil. SBC.
- Narin, A., Kaya, C., and Pamuk, Z. (2020). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *arXiv preprint arXiv:2003.10849*.
- Organization, W. H. et al. (2020). Coronavirus disease (covid-19) technical guidance: The unity studies: Early investigations protocols. Technical report, World Health Organization.
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., and Acharya, U. R. (2020). Automated detection of covid-19 cases using deep neural networks with x-ray images. *Computers in Biology and Medicine*, 121:103792.
- Petrosillo, N., Viceconte, G., Ergonul, O., Ippolito, G., and Petersen, E. (2020). Covid-19, sars and mers: are they closely related? *Clinical Microbiology and Infection*.
- Rahimzadeh, M. and Attar, A. (2020). A modified deep convolutional neural network for detecting covid-19 and pneumonia from chest x-ray images based on the concatenation of xception and resnet50v2. *Informatics in Medicine Unlocked*, 19:100360.
- Rodrigues, F., Reis, F., Veloso, M., Diniz, J., Veloso, R., and Filho, A. C. (2022). Metodologia automática para detecção de bacilos de tuberculose utilizando retinanet e modelos de cores. In *Anais do XXII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 334–345, Porto Alegre, RS, Brasil. SBC.
- Sethy, P. K. and Behera, S. K. (2020). Detection of coronavirus disease (covid-19) based on deep features. *Preprints*, 2020030300:2020.
- Silva, G., Oliveira, F., Diniz, J., Diniz, P., Quintanilha, D., Silva, A., Paiva, A., and Cavalcanti, E. (2021). An automatic method for prostate segmentation on 3d mri scans using local phylogenetic indexes and xgboost. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 165–176, Porto Alegre, RS, Brasil. SBC.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826.
- Zhang, J., Xie, Y., Li, Y., Shen, C., and Xia, Y. (2020). Covid-19 screening on chest x-ray images using deep learning based anomaly detection. *arXiv preprint arXiv:2003.12338*.