

# Deep Learning in Image Analysis for COVID-19 Diagnosis: A Survey

Orrana L. V. de Sousa, Deborah M. V. Magalhães, Pablo de A. Vieira, Romuere R. V. e Silva

**Abstract**—COVID-19 achieved the highest concentration of confirmed cases in the Americas with a significant impact in Latin America and the Caribbean region, where access to water and sanitation is restricted. In this scenario, we surveyed deep learning techniques applied to extract information from images to detect pneumonia caused by SARS-COV-2, directly assisting health professionals through an automatic case screening. We identify the main public and private image datasets and deep network architectures. Thereby, we identified challenges and research directions. Thus, our goal is to provide a theoretical basis to contribute to the development of computational systems to aid the diagnosis of COVID-19.

**Index Terms**—SARS-COV-2, pandemic, deep learning, pneumonia, image processing, screening.

## I. INTRODUÇÃO

A COVID-19, doença causada pelo vírus SARS-COV-2 e descoberta no final do ano de 2019, vem afetando severamente a saúde e a economia na América Latina [1, 2]. Ainda em curso, a pandemia apresenta 21,2 milhões de casos confirmados e 761 mil mortos no mundo. As Américas permanecem como região mais afetada com 53% dos casos e 75% das mortes reportadas (até agosto de 2020) [3].

Tal doença se espalhou por países e territórios da América Latina e Caribe [4], onde Peru é o país que apresenta a maior taxa de mortalidade cumulativa (até agosto de 2020) [3]. No Brasil, país mais populoso dessa região, 6% da população vive em aglomerados habitacionais com alta densidade demográfica, onde há pessoas vulneráveis, em condições precárias de saneamento básico e serviços de saúde. Este cenário apresenta uma maior predisposição para disseminação do novo coronavírus [5]. Ainda, a América Latina é uma região com mais de oitocentos povos indígenas [6]. O acesso limitado à água corrente, seguro saúde e cuidados de saúde são alguns fatores que afetam a capacidade de resposta dos povos indígenas à COVID-19 [7]. Em consequência, eles tem apresentado uma taxa de mortalidade mais alta em comparação a povos não indígenas [3].

A COVID-19 abrange desde casos assintomáticos até casos com sintomas graves como pneumonia extensa, síndrome respiratória aguda grave e falência múltipla de órgãos [8], que levam os pacientes a precisarem de internação em unidades de tratamento intensivo (UTI) [9]. Os longos períodos de internação aliados ao número limitado de leitos

de UTI, verificado em diferentes países da América Latina e Caribe [10], torna a detecção da doença em estágio inicial imprescindível para o tratamento e controle da transmissão. O método padrão de teste é a Reação em Cadeia da Polimerase com Transcrição Reversa em Tempo Real (RT-CPR), utilizado para testar diferentes amostras de fluídos corporais, como sangue, escarro, fezes e urina. Porém a amostra mais utilizada é a de cotonetes faríngeos, com uma taxa de positivos de apenas 63% [11]. Mesmo com baixa sensibilidade e custo elevado, a demanda excede a capacidade real [12].

Tendo em consideração a sensibilidade e escassez do teste RT-CPR, especialmente na região da América Latina e Caribe [13], têm sido adotadas alternativas para auxiliar o diagnóstico da doença, dentre elas, está a análise de imagens para a identificação de evidências de lesões nos pulmões causada por pneumonia. A avaliação manual dessas imagens é cansativa e laboriosa para os profissionais de saúde [14], que precisam ter total disponibilidade para tratar pacientes em um cenário de pandemia. Além disso, é um trabalho complexo devido às semelhanças entre a pneumonia causada pelo SARS-COV-2 e outros tipos, principalmente virais, pela diferença no protocolo de tratamento aplicado [15].

A fim de atenuar tais dificuldades, o uso de técnicas de aprendizado de máquina para processamento de imagens capazes de caracterizar a pneumonia provocada pela COVID-19 é pertinente, pois alivia o trabalho repetitivo, resultando em um diagnóstico mais eficiente [14]. Dentre essas técnicas, destacam-se aquelas de aprendizado profundo (*Deep Learning* - DL), amplamente utilizada na detecção de doenças, entre elas a pneumonia, alcançando alta precisão a partir de imagens do tórax. Portanto, o surgimento e a rápida propagação do novo coronavírus fomentou a utilização de tais técnicas. Contudo, ressalta-se que o diagnóstico não deve ser baseado somente na análise de imagens, já que estas fornecem apenas informações parciais sobre os pacientes, necessitando ainda dos exames laboratoriais.

Nesse contexto, o propósito deste trabalho é realizar um levantamento das pesquisas que utilizam técnicas de DL para extrair informação de imagens capazes de caracterizar a COVID-19. O estudo realizado neste trabalho identifica as principais bases de dados públicas, as modalidades de imagem, arquiteturas de DL, técnicas de aumento de dados, técnicas de segmentação de imagens e o desempenho das soluções abordadas. Todas essas informações constituem uma base teórica relevante para a comunidade que deseja contribuir no desenvolvimento de sistemas computacionais de auxílio ao diagnóstico da COVID-19.

## II. FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta os principais exames para aquisição de imagens utilizadas no auxílio ao diagnóstico da COVID-19. Ainda, nós discutimos a utilização de DL para detecção de lesões que são indicativos da doença.

### A. Radiologia Convencional

A radiologia convencional (RC) é um exame de diagnóstico que utiliza radiação ionizante para descrever e ajudar a diagnosticar doenças e lesões, além de orientar intervenções terapêuticas [16]. Embora outras modalidades de imagem, como TC e ressonância magnética estejam sendo usadas com frequência crescente, a RC continua sendo uma modalidade importante na avaliação de doenças torácicas, mamárias, ósseas e abdominais [17], expondo o paciente a quantidades menores de radiação e estando largamente disponível em hospitais e clínicas [18, 19].

Ela tem sido comumente utilizada por especialistas na detecção da COVID-19 devido a sua rápida realização [20]. O padrão predominante observado é a opacificação e a consolidação em vidro fosco, um infiltrado no lóbulo superior do pulmão que está associado ao aumento da dispnéia com hipoxemia (falta de ar com baixo oxigênio no sangue), sombras irregulares bilaterais e outros achados pulmonares incipientes da infecção [21] (Fig. 1a).

### B. Tomografia Computadorizada

A Tomografia Computadorizada (TC) é um exame que utiliza a radiação ionizante para gerar imagens em cortes (3D) que podem ser analisadas de qualquer ângulo, permitindo assim a visualização de uma grande variedade de estruturas de tecido, além das vistas em uma radiografia convencional [22]. Ela é utilizada como uma ferramenta diagnóstica para muitas aplicações clínicas, desde o diagnóstico de câncer até traumas e exames torácicos.

Estudos recentes têm demonstrado um papel central da TC na detecção e gerenciamento precoces das manifestações pulmonares da COVID-19, com alta sensibilidade (presença da doença corretamente detectada), mas com especificidade (ausência da doença corretamente detectada) ainda limitada [23]. As imagens de TC de tórax para casos positivos da COVID-19 têm um padrão radiológico distinto: opacidades em vidro fosco, consolidação irregular de pontos multifocais e/ou alterações intersticiais com distribuição predominantemente periférica [24, 25] (Fig. 1b).

### C. Aprendizado Profundo

O aprendizado profundo (*Deep Learning* - DL) é uma sub-área da Inteligência Artificial e é utilizada em várias áreas, dentre elas a visão computacional. A principal técnica de DL utilizada em imagens são as Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs). Elas foram projetadas para automaticamente e adaptativamente aprender características espaciais, e são compostas por basicamente três tipos de camadas: convolução, *pooling* e totalmente conectadas [28], como pode ser observado na Fig. 2.

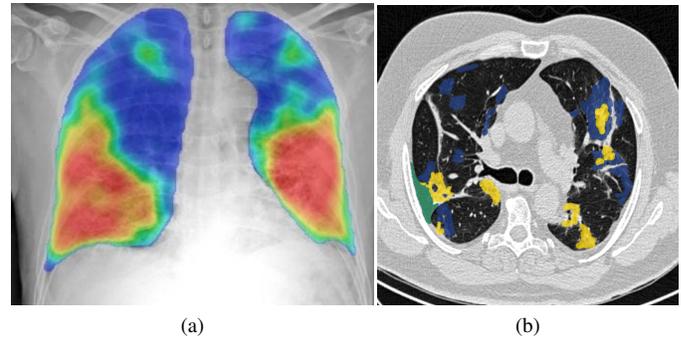


Fig. 1. (a) RC com registro gráfico das temperaturas sobreposto, mostrando características relacionadas a pneumonia. Fonte: [26]. (b) Corte axial segmentado proveniente de TC de um paciente com COVID-19. Opacidades em vidro fosco em azul, consolidação em amarelo e derrame pleural em verde. Fonte: [27].

A camada convolucional consiste em um conjunto de filtros. Durante o processo de treinamento da rede os valores dos filtros são ajustados para que sejam ativados na presença de características importantes dos volumes de entrada, como orientação de bordas e manchas de cores [28]. Nessa camada é realizada a convolução entre os filtros convolucionais e o volume de entrada, em seguida os valores resultantes passam por uma função de ativação, geralmente a ReLU.

Na operação de *pooling*, os valores gerados pelas camadas convolucionais, são substituídos por alguma métrica dessa região. Essa operação é útil para eliminar valores desprezíveis, reduzindo a dimensão da representação dos dados e acelerando a computação necessária para as próximas camadas, além de criar uma invariância a pequenas mudanças e distorções locais [28]. A saída das camadas convolucionais e de *pooling* representam os atributos extraídos. Logo, o objetivo das camadas totalmente conectadas é utilizar essas características para classificar a imagem em classes pré-determinadas.

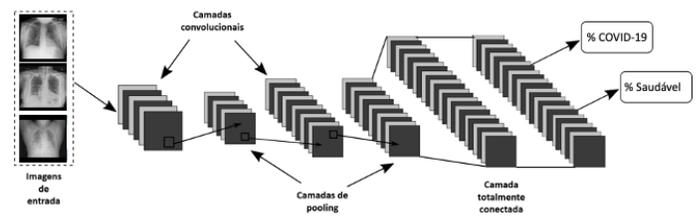


Fig. 2. Exemplo da estrutura de uma rede neural convolucional utilizando como entrada imagens de RC.

Existem basicamente duas abordagens quanto ao uso de CNNs para reconhecimento de padrões em imagens, a saber: 1) CNN treinada com amostras do problema em questão; 2) CNN pré-treinada com outra base de dados (*transfer learning*) [29]. Dentro do aprendizado por transferência, é possível fazer um ajuste fino de uma rede pré-treinada (*fine-tuning*), essa abordagem tem por objetivo treinar somente algumas camadas de uma rede pré-treinada.

## III. METODOLOGIA

A metodologia de levantamento bibliográfico utilizada seguiu as etapas proposto por Kitchenham [30], que

incluem: planejamento, condução e extração dos dados. No planejamento do levantamento bibliográfico, partimos das seguintes questões de pesquisa: (1) Quais bases de imagens médicas estão sendo utilizadas na detecção da pneumonia causada pela COVID-19? e (2) Como as técnicas de aprendizado profundo são empregadas na detecção da pneumonia causada pela COVID-19? Ainda, definimos os seguintes critérios de Inclusão (I) e Exclusão (E): (I) Emprega técnica de visão computacional para processamento de imagens médicas; (I) Realiza detecção da pneumonia através de técnica de aprendizado profundo, servindo de indicativo para o diagnóstico da COVID-19; (E) Estudo anterior a 2020; (E) Estudo cujo idioma é diferente do inglês, português e espanhol; (E) Não é um estudo primário; e (E) Utiliza métricas de avaliação que não sejam passíveis de comparação com demais trabalhos na literatura. Na etapa de condução, submetemos a string de busca (“*deep learning*” OR “*convolutional neural network*”) AND (COVID-19 OR SARS-COV-2 OR *coronavirus*) nas bases IEEE Xplorer, Scielo, Science Direct e PubMed, em seguida aplicamos três etapas de filtragem e, por fim, um total de 38 artigos foram selecionados na última etapa. As informações extraídas dos trabalhos selecionados são sumarizadas na Seção IV. A Figura 3 apresenta as etapas de busca e seleção aplicadas na condução do levantamento bibliográfico.

Bases	Protocolo				Taxa de aceito
	Busca inicial	1º Filtro	2º Filtro	3º Filtro	
	203 artigos retornados	18 artigos removidos	46 artigos aceitos	38 artigos aceitos	
IEEE Xplorer	20	0	10	8	40,0%
Scielo	3	0	0	0	0,0%
Science Direct	123	16	7	7	5,7%
PubMed	57	2	29	23	40,3%
Critérios	Ano >= 2020 Idioma = português, inglês ou espanhol.	Documentos duplicados.	Critérios de inclusão e exclusão aplicados ao título e ao resumo.	Critérios de inclusão e exclusão aplicados ao texto completo.	

Fig. 3. Etapas da condução do levantamento bibliográfico: (1) Busca inicial nas bases, filtrando os artigos por ano de publicação e linguagem; (2) Filtro 1: remoção dos artigos duplicados; (3) Filtro 2: aplicação dos critérios de inclusão e exclusão no título e resumo; e (4) Filtro 3: aplicação dos critérios de inclusão e exclusão no texto completo.

#### IV. RESULTADOS

Levando em consideração os desafios no diagnóstico da COVID-19, o uso de técnicas de DL pode oferecer soluções viáveis a serem utilizadas em ambientes reais. Essas soluções podem ajudar a diminuir a crescente carga de trabalho de profissionais da saúde. Dessa forma, apresentamos como resultados os principais trabalhos encontrados utilizando imagens de RC e TC no auxílio ao diagnóstico dessa patologia.

##### A. Detecção da COVID-19: Radiografias Convencionais

A radiografia é a categoria de exame mais empregada em pacientes sob investigação da COVID-19 [20]. Detalhamos a seguir os principais trabalhos que utilizaram essa técnica. Eles estão divididos nas categorias: avaliação de CNNs existentes, uso de Redes Adversárias Geradoras, uso de Mapas de

Ativação de Classes, uso de técnicas de aprendizado de máquina, propostas de novos modelos e segmentação.

No trabalho de Apostolopoulos and Mpesiana [31], foi avaliado o desempenho de cinco CNNs, com a MobileNet-V2 [32] alcançando a melhor performance. Seguindo essa mesma linha, El Asnaoui and Chawki [33] e Chowdhury et al. [34], avaliaram CNNs já existentes. Os primeiros realizaram um estudo comparativo de sete modelos, com a InceptionResNet-V2 [35] tendo melhores resultados, e o segundo utilizaram oito redes pré-treinadas com a ImageNet [36] - dentre elas, a DenseNet-201 [37] (com aumento de dados) e a CheXNet [38] (sem aumento de dados), que superaram as outras redes. Em Minaee et al. [39], a aprendizagem por transferência foi utilizada para ajustar quatro redes pré-treinadas no conjunto de dados proposto, COVID-Xray-5k. Além disso, uma técnica baseada no trabalho de Zeiler and Fergus [40] foi usada para fazer o mapa de calor de regiões potencialmente infectadas. A SqueezeNet [41] apresentou a melhor performance. Já Apostolopoulos et al. [42] empregaram a MobileNet-V2 [32] para a classificação de RCs de três maneiras diferentes: (a) com o treinamento do zero, (b) aprendizagem por transferência com características próprias, e (c) aprendizagem por transferência com ajuste fino.

Nos trabalhos que utilizaram Redes Adversárias Geradoras (GAN) [43], Albahli [44] propôs um modelo de combinação de autocodificador variacional e GAN para a geração de imagens de granulação fina. Depois, quatro tipos de modelos foram treinados: (1) modelo com aumento de dados, (2) aprendizado por transferência com Inception-V3 [45], (3) modelo ResNet-152 [46] sem aumento de dados, e (4) o primeiro modelo com nove classes direcionadas. O modelo ResNet-152 [46] alcançou a maior acurácia. Além deste, Waheed et al. [47] apresentaram um método para gerar imagens sintéticas por meio do desenvolvimento de um modelo baseado em GAN do Classificador Auxiliar chamado CovidGAN. Após isso, utilizaram as imagens produzidas para detectar COVID-19 através da VGG-16 [48].

Yi et al. [49] usaram um modelo para detecção de tuberculose pulmonar em imagens da COVID-19 com o uso de Mapas de Ativação de Classes (CAMs) na localização apropriada de lesões. Ainda, houveram trabalhos que utilizaram CAM baseado em gradiente (Grad-CAM), como Mahmud et al. [15], que propuseram uma arquitetura chamada CovXNet. Além destes, Brunese et al. [50] utilizaram a VGG-16 [48] aplicando aprendizagem por transferência com ajuste fino, para, primeiro, detectar se há presença de pneumonia em RCs, e, depois, distinguir entre COVID-19 e pneumonia. A localização das áreas sintomáticas da presença da COVID-19 foi realizada com o Grad-CAM.

Nos trabalhos que utilizaram técnicas de aprendizado de máquina, Toğaçar et al. [51] treinaram o conjunto de dados com a MobileNet-V2 [32] e a SqueezeNet [41]. A classificação foi realizada com Máquina de Vetores de Suporte(SVM) [52]. O outro trabalho foi o de Pereira et al. [53], em que os pesos da Inception-V3 [45] treinada com a ImageNet foram combinados com descritores clássicos para extração de atributos. Depois, fizeram dois tipos de classificação: (1) multi-classe, com os algoritmos k-vizinhos mais próximos (kNN) [54], SVM,

Perceptrons Multicamadas (MLP) [55], Árvores de Decisão (DT) [56] e Florestas Aleatórias (RF) [57]; e (2) hierárquica, com o framework Clus-HMC. A classificação no cenário hierárquico teve melhores resultados.

Dentre os trabalhos que propuseram novas arquiteturas, Das et al. [58] apresentaram um modelo baseado na InceptionNet-V3 [45], com aprendizado por transferência através do uso de pesos treinados com a ImageNet. Ucar and Korkmaz [59] apresentaram o COVIDiagnosis-Net, que é baseado na SqueezeNet [41], com o acréscimo do algoritmo de otimização Bayes. Altan and Karasu [60], aplicaram a transformada Curvelet 2D e formaram uma matriz de características a partir dos coeficientes obtidos. Os coeficientes na matriz foram otimizados com a ajuda do algoritmo caótico de busca de esquilos [61] e a detecção foi feita pela EfficientNet-B0 [62]. Panwar et al. [63] propuseram o modelo nCOVnet para classificação baseado na VGG-16 [48] treinada com a ImageNet.

Ainda sobre os trabalhos com novos modelos, Ozturk et al. [64] propuseram o DarkCovidNet, que é baseado no modelo DarkNet-19 e tem uma arquitetura ponta a ponta que classificou imagens. Khan et al. [65] apresentaram o CoroNet, modelo baseado na Xception [66] pré-treinada com a ImageNet. Toraman et al. [67] propuseram um modelo próprio de rede de cápsulas e fizeram a reconstrução dos dados através de codificadores automáticos. Narayan Das et al. [68] apresentaram um modelo baseado em aprendizado por transferência através do modelo Xception [66]. Rahimzadeh and Attar [69] apresentaram uma rede neural concatenada com as características extraídas da Xception [66] e ResNet-50-V2 [46] e, em seguida, conectando essas características a uma camada convolucional que está conectada ao classificador. Vaid et al. [70] fizeram uma modificação da VGG-19 [48] previamente treinada com a ImageNet. Um perceptron multicamadas foi adicionado no topo do modelo para treinar e realizar detecções nos conjuntos de dados.

Por fim, os trabalhos que realizaram segmentação foram os de Rajaraman and Antani [71], Rajaraman et al. [72] e Oh et al. [73]. No primeiro, a segmentação foi feita com a U-Net [74]. Depois, utilizaram os dados segmentados para treinamento e avaliação de cinco CNNs. Após isso, o modelo de melhor desempenho (VGG-16 [48]) foi usado para classificar um outro conjunto de dados segmentado. No final, a VGG-16 [48] foi utilizada para classificar a junção dos dois conjuntos. O segundo trabalho também utilizou a U-Net [74] para segmentação. Depois, treinaram e avaliaram o desempenho de uma CNN própria e uma seleção de modelos CNN pré-treinados com ImageNet para aprender representações de características específicas. O conhecimento aprendido foi transferido e ajustado para melhorar o desempenho e generalização da classificação. Os modelos de melhor desempenho (Inception-V3 [45], VGG-19 [48] e VGG-16 [48]) foram podados iterativamente para reduzir a complexidade e melhorar a eficiência da memória. Depois, usaram várias estratégias para combinar as previsões dos modelos podados para classificar a COVID-19. Por último, o terceiro fez a segmentação com a FC-DenseNet-103 [75] e após isso utilizaram a ResNet-18 [46] usando um treinamento

*patch-a-patch* e inferência. A decisão final foi então feita com base em uma votação por maioria. Por fim, foi calculado um mapa probabilístico Grad-CAM.

### B. Detecção da COVID-19: Tomografias Computadorizadas

Tomografias possuem papel substancial quanto a detecção e diagnóstico da COVID-19. São apresentados a seguir trabalhos que utilizaram TC divididos nas categorias: sem uso de segmentação e com uso de segmentação.

Em Ko et al. [76], o framework FCONet foi proposto, utilizando aprendizado por transferência com base em quatro arquiteturas. A versão com a ResNet-50 [46] superou os modelos FCONet baseado nos outros três modelos pré-treinados. Ardakani et al. [77] utilizaram dez CNNs conhecidas, tendo a ResNet-101 [46] os melhores resultados. Já Sakagianni et al. [78] avaliaram o desempenho de um algoritmo de aprendizado de máquina automatizado, utilizando o Google AutoML Cloud Vision [79] para design, treinamento, validação e teste de modelos. Jaiswal et al. [80] modelaram uma CNN de aprendizado de transferência baseada na DenseNet-201 [37]. O modelo foi utilizado para extrair características usando seus próprios pesos aprendidos com a ImageNet. No trabalho de Han et al. [81], o AD3D-MIL foi proposto, um modelo de aprendizado de múltiplas instâncias 3D baseado na atenção. Pathak et al. [82] utilizaram um modelo próprio de CNN, com o uso de aprendizado de transferência com ResNet-50 [46] treinada com a ImageNet.

Dentre os trabalhos que utilizaram segmentação, Ni et al. [83] desenvolveram um algoritmo que consiste na detecção, segmentação e localização de lesões, usando o modelo proposto MVP-Net e a 3D U-Net [74]. Wang et al. [84] apresentaram a rede COVID-19Net (baseada na DenseNet [37]) para diagnóstico e análise prognóstica e a DenseNet-121-FPN [37, 85] para segmentação. Em Wu et al. [86], um modelo de fusão multi-visão usando uma CNN baseada na modificação da ResNet-50 [46] foi desenvolvido. Além disso, fizeram a utilização de segmentação por limiar. Hu et al. [87] propuseram uma estratégia de DL inspirada na VGG [48]. A rede de segmentação foi baseada na U-Net [74] com múltiplas visualizações para segmentação pulmonar. No trabalho de Wang et al. [88], foi desenvolvida uma estrutura chamada DeCoVNet, seguindo as configurações da AlexNet [89] e ResNet [46]. Como rede de segmentação utilizaram a U-Net [74]. Por fim, Xu et al. [90] segmentaram as regiões candidatas com a VNet-IR-RPN [91]. Essas imagens separadas foram então categorizadas, juntamente com os escores de confiança, usando um modelo de localização-atenção baseado na ResNet-18 [46]. O tipo de infecção e o escore de confiança geral foram calculados usando a função Noisy ou Bayesiana.

Além dos trabalhos mencionados, Roy et al. [92] avaliaram a aplicação de técnicas de DL na análise de imagens de ultrassonografia pulmonar (LUS). Eles apresentaram uma CNN derivada de Redes de Transformadores Espaciais (STN) [93], que prediz a pontuação de gravidade da doença associada a um *frame* de entrada e fornece a localização de artefatos patológicos de uma forma fracamente supervisionada.

Além disso, apresentaram um novo método para agregação da pontuação de *frames* em nível de vídeo e utilizaram as redes de segmentação U-Net [74], U-net++ [94] e Deeplabv3+ [95]. Como resultado, um F1-score de 65,1% foi obtido.

### C. Discussões

As Tabelas I e II apresentam as principais técnicas de DL empregadas em imagens de RC e TC. Ainda, essas tabelas indicam quais trabalhos aplicaram pré-processamento de imagens (PPI), aprendizado por transferência (TA), aumento de dados (DA) e algoritmos de segmentação (S).

A Tabela I apresenta acurácias elevadas para diferentes arquiteturas de classificação. Altan and Karasu [60] obtiveram a maior acurácia, sensibilidade e F1, com 99,7%, 99,4% e 99,5%, respectivamente. Além disso, Das et al. [58] obtiveram 100% de especificidade, 100% de precisão e 100% na AUC. Em contrapartida, alguns trabalhos tiveram resultados inferiores, como Panwar et al. [63] e Rahimzadeh and Attar [69] que alcançaram uma especificidade de 78,6% e precisão de 35,3%, respectivamente. Esses resultados implicam que o trabalho [63] tem efetividade mediana em identificar negativos corretamente, e que, devido ao grande desbalanceamento entre classes, o trabalho [69] tem valor alto de falsos positivos. Na Tabela II, Ko et al. [76] apresentaram o melhor resultado em termos de acurácia, sensibilidade e especificidade com 99,9%, 99,6% e 100%, respectivamente. Os melhores resultados de precisão, F1 e AUC foram 97,3% [87], 97,0% [83] e 99,4% [77]. Por outro lado, trabalhos como Ni et al. [83] e Wu et al. [86] alcançaram especificidade de 25,0% e 61,5%, respectivamente.

Dentre os trabalhos das Tabelas I e II, 37,8% realizaram aumento de dados, 56,7% utilizaram aprendizado por transferência, 24,3% fizeram segmentação e 59,4% aplicaram pré-processamento nas imagens. TA foi mais empregado em trabalhos de RC que TC, sendo 64,0% dos trabalhos no primeiro e 41,7% do segundo. Assim como técnicas de PPI também foram mais utilizadas em RC que em trabalhos de TC (64,0% e 50,0%, respectivamente). Além disso, nota-se a discrepância entre o número de artigos que segmentaram suas imagens nas duas categorias. Em RC, apenas três artigos utilizaram segmentação, enquanto que metade dos artigos de TC utilizaram esta técnica. Isso se deve ao maior número de informações encontradas em imagens de TC e o desafio em segmentar radiografias devido às costelas projetadas nos tecidos moles, confundindo assim o contraste da imagem [20].

Essas tabelas apontam resultados promissores para utilização de técnicas de DL em conjunto com imagens de RC e TC na detecção da pneumonia em decorrência da COVID-19. No entanto, as vantagens e desvantagens de cada tipo de imagem devem ser consideradas. As imagens de RC são menos complexas que as de TC, portanto, possuem um custo de processamento menor. No entanto, não são recomendadas para a classificação precoce da doença [96]. Já imagens de TC apresentam mais informações e melhores opções de seleção para análise, além de serem utilizadas para a detecção precoce, mas são menos acessíveis devido ao custo do exame [97].

### D. Bases de Imagens

A falta de dados para o desenvolvimento de pesquisa no contexto do novo coronavírus fez com que diversas bases de imagens fossem criadas. A Tabela III apresenta bases de RC com os respectivos números de amostras por classe. Dentre as bases selecionadas uma é privada. A Tabela IV sumariza as bases de TC públicas e privadas bem como o número de amostras por classe. Tais bases englobam doenças que vão desde a pneumonia causada pela COVID-19 até outros tipos de pneumonias, tuberculose e câncer de pulmão.

Dentre as bases disponíveis, as mais amplamente adotadas são a *COVID-19 Image Data Collection* com 451 imagens de RC, a *COVID-Net Open Source Initiative* que possui 573 imagens de RC, e a *SARS-CoV-2 CT Scan Dataset* com 1252 imagens de TC. Na Tabela IV, notamos uma carência de bases de imagens públicas com um número representativo de amostras da COVID-19. Ainda, há um desbalanceamento entre classes de imagens. Desse modo, os modelos de DL encontram obstáculos neste cenário, visto que o número reduzido de amostras e o desbalanceamento intraclasse pode comprometer o desempenho de classificação.

## V. DESAFIOS E DIREÇÕES DE PESQUISA

### A. Limitações das Bases de Dados

Nos trabalhos levantados, independente da modalidade de imagem adotada, observamos a escassez de dados referentes a pneumonia causada pela COVID-19. Uma vez que estamos abordando uma pandemia em curso, foram realizadas várias iniciativas para compartilhamento e criação de bases de dados, no entanto, tais iniciativas esbarram na regulamentação de compartilhamento de dados do seu país de origem. O número reduzido de amostras e o desbalanceamento entre classes impacta diretamente no modelo de detecção. Tais fatores podem provocar o sobreajuste (*overfitting*) dos modelos, causando baixo desempenho na classe minoritária. Isso ocorre geralmente em sistemas de reconhecimento baseados em CNNs, pois estas exigem um grande número de amostras para ajustar modelos durante o estágio de treinamento e fornecer resultados precisos de classificação. Assim, as técnicas a seguir foram utilizadas para solucionar este problema.

1) *Técnicas de Reamostragem*: A fim de igualar as amostras entre classes foram empregadas em Pereira et al. [53] técnicas de reamostragem, tais como: ADASYN [102], SMOTE [103], AIIKNN [104] e Tomek Links [104] (TL). Eles são algoritmos de reamostragem binária clássicos que foram aplicados a problemas de desequilíbrio de várias classes, com a conversão de um problema multi-classe em um conjunto de subclasses binárias. Essas técnicas são divididas em estratégias de superamostragem, *undersampling* e híbridas. A primeira criando amostras sintéticas para a classe minoritária, a segunda removendo amostras na classe majoritária e a última sendo uma junção entre elas.

2) *Técnicas de Aumento de Dados*: Amplamente utilizadas no campo de processamento de imagens, técnicas de aumento de dados consistem em aplicar transformações matemáticas, a fim de gerar novas amostras. Assim, essas técnicas aprimoram o tamanho e a qualidade dos conjuntos de dados de

TABLE I  
DESEMPENHO DOS MODELOS DE APRENDIZADO PROFUNDO UTILIZANDO RC PARA DETECÇÃO DA PNEUMONIA CAUSADA PELA COVID-19.

Método	Técnicas	Acc(%)	Sens(%)	Espec(%)	Prec(%)	F1(%)	AUC(%)
Apostolopoulos and Mpesiana [31] (TA, PPI)	VGG-19   MobileNet-V2   Inception   Xception   Inception-ResNet-V2	96,8	98,6	96,5	-	-	-
El Asnaoui and Chawki [33] (TA, PPI)	VGG-16   VGG-19   DenseNet-201   InceptionResNet-V2   Inception-V3   ResNet-50   MobileNet-V2	92,2	92,1	96,1	92,4	92,1	-
Chowdhury et al. [34] (DA, PPI, TA)	MobileNet-V2   SqueezeNet   ResNet-18   ResNet-101   DenseNet-201   CheXNet   Inception-V3   VGG-19	97,9	97,9	98,8	97,9	97,9	-
Minaee et al. [39] (DA, TA)	ResNet-18   ResNet-50   SqueezeNet   DenseNet-161	-	98,0	92,9	-	-	-
Apostolopoulos et al. [42] (DA, TA, PPI)	MobileNet-V2	99,2	97,4	99,4	-	-	-
Albahli [44] (PPI, TA)	Modelo próprio   Inception-V3   ResNet-152	89,0	-	-	-	-	-
Waheed et al. [47] (DA, TA, PPI)	VGG-16	95,0	90,0	97,0	96,0	93,0	-
Yi et al. [49]	Modelo próprio	89,0	-	-	-	-	-
Mahmud et al. [15]	CovXNet	90,2	-	89,1	90,8	90,4	91,1
Brunese et al. [50] (TA, PPI)	VGG-16	97,0	91,5	96,0	-	91,5	-
Toğaçar et al. [51] (PPI)	MobileNet   SqueezeNet	-	-	-	99,3	-	-
Pereira et al. [53] (DA, TA, PPI)	Inception-V3	89,0	-	-	-	-	-
Das et al. [58] (TA)	InceptionNet-V3	94,0	88,0	100	100	93,0	100
Ucar and Korkmaz [59] (TA, PPI)	SqueezeNet	98,3	-	99,1	-	98,3	-
Altan and Karasu [60] (DA, PPI)	EfficientNet-B0	99,7	99,4	99,8	99,6	99,5	-
Panwar et al. [63] (PPI)	nCOVnet e VGG-16	-	97,6	78,6	-	-	88,1
Ozturk et al. [64]	DarkNet-19	87,0	85,3	92,2	89,9	87,4	-
Khan et al. [65]	Xception	89,6	89,9	96,4	90,0	89,8	-
Toraman et al. [67] (DA, PPI)	CapsuleNet	84,2	91,8	84,2	84,6	89,2	-
Narayan Das et al. [68] (TA)	Xception	97,4	97,1	97,3	-	96,9	-
Rahimzadeh and Attar [69] (DA, TA, PPI)	Xception   ResNet-50-V2	99,5	80,5	99,6	35,3	-	-
Vaid et al. [70] (TA)	VGG-19	96,3	-	-	-	-	-
Rajaraman and Antani [71] (S)	VGG-16   Inception-V3   Xception   DenseNet-121   NasNet-Mobile	93,1	97,1	86,5	92,2	94,6	95,6
Rajaraman et al. [72] (S, TA, PPI)	Modelo próprio   VGG-16   VGG-19   Inception-V3   Xception   InceptionResNet-V2   MobileNet-V2   DenseNet-201   NasNet-Mobile	97,5	96,8	-	98,1	97,5	99,2
Oh et al. [73] (S, TA, PPI)	ResNet-18	88,9	-	96,4	83,4	84,4	-

Acc: acurácia; Sens: sensibilidade; Espec: especificidade; Prec: precisão, F1: F1-score; AUC: área sob a curva ROC.

TABLE II  
DESEMPENHO DOS MODELOS DE APRENDIZADO PROFUNDO UTILIZANDO TC PARA DETECÇÃO DA PNEUMONIA CAUSADA PELA COVID-19.

Método	Técnicas	Acc(%)	Sens(%)	Espec(%)	Prec(%)	F1(%)	AUC(%)
Ko et al. [76] (DA, TA, PPI)	VGG16   ResNet50   Inception-V3   Xception	99,9	99,6	100	-	-	-
Ardakani et al. [77] (TA, PPI)	AlexNet   VGG-16   VGG-19   SqueezeNet   GoogleNet   MobileNet-V2   ResNet-18   ResNet-50   ResNet-101   Xception	99,5	100	99,0	-	-	99,4
Sakagianni et al. [78]	AutoML Cloud Vision	-	88,3	-	88,3	-	-
Jaiswal et al. [80] (DA, TA)	DenseNet201	96,2	96,3	96,2	96,3	96,3	97,0
Han et al. [81] (DA)	AD3D-MIL	94,3	90,5	-	95,9	92,3	98,8
Pathak et al. [82] (TA)	Modelo próprio   ResNet-50	93,0	91,5	94,8	95,2	-	-
Ni et al. [83] (S)	MVP-Net	94,0	100	25,0	-	97,0	-
Wang et al. [84] (S, TA)	DenseNet	78,3	80,4	76,6	-	77,0	87,0
Wu et al. [86] (S, PPI)	ResNet50	70,0	73,0	61,5	-	-	73,2
Hu et al. [87] (DA, S, PPI)	VGG16	96,2	94,5	95,3	97,3	-	97,0
Wang et al. [88] (DA, S, PPI)	AlexNet   ResNet	90,1	95,0	78,6	-	-	95,9
Xu et al. [90] (DA, S, PPI)	ResNet18	86,7	86,7	-	81,3	83,9	-

Acc: acurácia; Sens: sensibilidade; Espec: especificidade; Prec: precisão, F1: F1-score; AUC: área sob a curva ROC.

treinamento, de modo que modelos melhores de DL possam ser construídos [105]. Dentre as transformações de imagem utilizadas nos trabalhos estão rotações, translações, variação de altura/largura, adição de distorções, zoom, inserção de

TABLE III

BASES DE IMAGENS PÚBLICAS E PRIVADAS(\*) DE RC APLICADAS NA DETECÇÃO DA PNEUMONIA CAUSADA PELA COVID-19.

Base	Quantidade de imagens
Japanese Society of Radiological Technology [98]	154: nódulo pulmonar   93: normal
U.S. National Library of Medicine (USNLM) dataset [99]	394: tuberculose   406: normal
Corona Hack: Chest X-Ray-Dataset	58: COVID-19   4270: pneumonia   1576: normal
ChexPert Dataset	4576: pneumonia   16627: normal
Italian Society of Medical and Interventional Radiology COVID-19 Database	115: COVID-19
COVID-19 Image Data Collection	451: COVID-19   592: pneumonia
COVID-19 Radiography Database	219: COVID-19   1345: pneumonia viral   1341: normal
Radiopaedia	96: COVID-19
COVID-19 Chest Imaging at Thread Reader	50: COVID-19
Pneumonia Detection Challenge [100]	1062: pneumonia   84312: normal
Chest X-Ray Images (Pneumonia) Pediatric CXR Dataset [101]	4273: pneumonia   1583: normal
Twitter COVID-19 CXR Dataset	3883: pneumonia   1349: normal
COVID-19 Chest X-ray Dataset Initiative	50: COVID-19
Automated Detection of COVID-19 Cases Using Deep Neural Networks with X-Ray Images Dataset	48: COVID-19
Digital Pathology Classification Challenge	125: COVID-19   500: pneumonia   500: normal
COVID-Net Open Source Initiative	337 de COVID-19
Guangzhou Medical Center	573 de COVID-19, 5559 de pneumonia e 8066 normais
Sylhet Medical College Dataset*	4273: pneumonia   1583: normal
	305: COVID-19

\*Base de imagens privadas.

ruido e brilho. O aumento dos dados pode ser incluído como uma etapa de processamento adicional no treinamento das CNNs. Dentre os trabalhos que utilizaram estas técnicas estão: [34, 39, 42, 44, 47, 59, 60, 67, 69].

3) *Capsule Networks (CapNets)*: Neste tipo de rede é aplicada uma abordagem distinta ao processamento de imagens, o que inclui o mapeamento equivariante (preservação de informações de posição e pose) e o mapeamento da hierarquia de partes (atribui cada parte a um todo) [106]. Além disso, este tipo de arquitetura não precisa de um grande conjunto de dados, pois mesmo que possam se beneficiar das técnicas de aumento, elas apresentam um desempenho melhor em bases desbalanceadas [67].

4) *Aprendizado por Transferência*: O aprendizado por transferência possibilita a extração de características em bases de dados pequenas. Visto a limitação do número de amostras de pneumonia causada por COVID-19, diferentes trabalhos [31, 33, 34, 39, 42, 47, 53, 58, 68, 69, 72, 73] utilizaram modelos pré-treinados comumente com a ImageNet. Os resultados para detecção encontrados mostram que o aprendizado por transferência viabilizou significativamente o processo de classificação, permitindo retreinar arquiteturas com um número relativamente pequeno de imagens, demonstrando ser uma alternativa na detecção da pneumonia causada por COVID-19.

TABLE IV

BASES DE IMAGENS PÚBLICAS (\*) E PRIVADAS DE TOMOGRAFIAS APLICADAS NA DETECÇÃO DA PNEUMONIA CAUSADA PELA COVID-19.

Base	Quantidade de imagens
Iran University of Medical Sciences	510: COVID-19   510: não-COVID
COVID-CT-Dataset: A CT Scan Dataset about COVID-19*	349: COVID-19   397: não-COVID
Wonkwang University Hospital	421 de COVID, 1357: pneumonia não-COVID   444: câncer de pulmão   998: normal
Chonnam National University Hospital	673: COVID-19
Italian Society of Medical and Interventional Radiology	100: COVID-19
Taihe Hospital	84: COVID-19
Wuhan First Hospital	11: COVID-19
Jinling Hospital	1: COVID-19
Wuhan and Henan Dataset	560: COVID-19   149: pneumonia
Beijing Dataset	53 de COVID-19
Heilongjiang Dataset	92: COVID-19   69: pneumonia
Anhui Dataset	102: pneumonia e 124: pneumonia
Huangshi Dataset	117: COVID-19
Sichuan Dataset	4106: câncer de pulmão
Renmin Hospital of Wuhan University	265: COVID-19   35 pneumonia
The First Hospital of China Medical University	103: COVID-19   46: pneumonia
Beijing Youan Hospital	46: pneumonia
SARS-CoV-2 CT Scan Dataset*	1252: COVID-19   1230: não-COVID
Shandong Province Hospitals	230: COVID-19   100: pneumonia   130: não-pneumonia
Wuhan Red Cross Society	138: COVID-19
Shenzhen Second Hospital	12: COVID-19   150: pneumonia   150: não-pneumonia
Union Hospital, Tongji Medical College and Huazhong University of Science and Technology Dataset	313: COVID-19   229: não-COVID
Chest CT Images Dataset	413: COVID-19   439: pneumonia ou normal
Wenzhou Central Hospital and the First People's Hospital of Wenling	219: COVID-19
First Affiliated Hospital	224: pneumonia   175: normal

\*Bases de imagens públicas.

## B. Segmentação

Normalmente, um dos principais problemas no diagnóstico médico é a subjetividade do especialista na hora da decisão. Em interpretação de imagens médicas, especialmente, a complexidade da imagem, a experiência e a fadiga do perito podem influenciar diretamente no resultado final, particularmente em um cenário de estresse do sistema de saúde. Nesse contexto, a segmentação se refere ao processo de dividir uma imagem em múltiplas regiões, com o objetivo de simplificar e/ou mudar a representação de uma imagem para facilitar a sua análise [107]. Com a segmentação, o processo de análise pode ser facilitado do ponto de vista médico, além de trazer benefícios para técnicas de DL, como a melhoria da eficiência computacional, visto que uma porção menor da imagem será processada, e a melhoria da precisão [108].

Notamos que seis dos trabalhos com TC empregaram técnicas de segmentação [83, 84, 86, 87, 88, 90], já que este tipo de imagem é mais complexa. Em contrapartida,

apenas três de RC usaram segmentação [71, 72, 73]. Tanto nos trabalhos de RC quanto TC, a arquitetura U-Net se destacou para a segmentação de imagens [71, 72, 83, 87, 88].

### C. Desafios da Utilização de Aprendizado Profundo

Devido a acessibilidade de radiografias e tomografias, a escolha do tipo de imagem a ser utilizada é um dos desafios encontrados em DL, principalmente devido ao tamanho e à disponibilidade de bases. Bases de TC apresentam um número superior de imagens, entretanto são essencialmente de fontes privadas, enquanto que bases de RC possuem menor número, mas originam largamente de fontes públicas. Essa disponibilidade de imagens de RC facilita o seu uso em pesquisas. No entanto, técnicas de DL necessitam de grandes quantidades de dados no treinamento a fim de evitar o sobreajuste do modelo [31]. Para contornar esse desafio, são empregadas técnicas de aumento de dados.

O estágio da doença em que esses exames foram feitos é um outro ponto a ser comentado. RCs não são recomendados como modalidade de imagem na detecção da COVID-19 no estágio inicial, visto que demonstra sensibilidade limitada nessa etapa. Embora o uso da TC como ferramenta de triagem não esteja ainda estabelecido, estudos recentes têm demonstrado um papel central da tomografia na detecção e gerenciamento precoces das manifestações pulmonares, com alta sensibilidade, mas com especificidade ainda limitada [109].

Outro desafio é a escolha de quais arquiteturas utilizar, visto que existe uma grande variedade, com um grande número de parâmetros, o que pode impactar negativamente no tempo computacional do modelo. Além disso, existe também o risco de sobreajustar os dados, especialmente quando o número de parâmetros excede em muito o número de observações independentes. A partir do levantamento das arquiteturas aplicadas nos trabalhos de radiografia (Tabela I), foi possível identificar que as redes das famílias VGG, Inception, MobileNet e ResNet foram as mais empregadas, sendo apresentadas em 9, 8, 6 e 6 dentre os 25 trabalhos, respectivamente. Porém, deve-se ressaltar que a família VGG foi a que apresentou melhor desempenho dentro as redes utilizadas. Com relação aos trabalhos de tomografia, a família ResNet foi a que se destacou, sendo utilizada em 6 trabalhos dentre os 12. Percebe-se também que, independente de terem sido utilizadas como principal modelo ou se serviram de base para a criação de outros, essas famílias alcançaram boas acurácias, sendo assim alternativas na detecção da COVID-19.

## VI. CONCLUSÃO

Neste trabalho, realizamos um levantamento de pesquisas que utilizam abordagens de DL para extrair características de RC e TC a fim de detectar a pneumonia causada pelo novo coronavírus. Nós mostramos que independente da modalidade de imagem utilizada na detecção da pneumonia, as técnicas de DL obtiveram resultados significativos em diferentes métricas, especialmente o *F1-score* que tem relação com a taxa de falso negativo. Dentre as diversas arquiteturas adotadas, as redes das famílias VGG e ResNet foram majoritariamente utilizadas.

A acurácia das arquiteturas da primeira família foi superior quando as bases de imagem eram constituídas de RC, enquanto que da segunda quando eram de TC.

Apesar dessas técnicas despontarem como alternativa eficaz para auxílio ao diagnóstico, elas ainda enfrentam alguns desafios. Têm sido realizados diversos esforços para disponibilização de bases de imagens públicas, no entanto, o número de amostras que caracterizam a COVID-19 ainda é pequeno quando comparado a outras classes de doenças. Desse modo, pesquisas voltadas para maneiras eficientes de aumento de dados e balanceamento intraclasses serão relevantes no contexto de DL. Outro desafio é que muitas vezes as imagens trazem um conjunto de informação irrelevante, portanto, uma etapa de segmentação *a priori* pode contribuir para tornar o treinamento do modelo profundo mais rápido e acurado. Portanto, pesquisas voltadas para segmentação rápida de regiões de interesse para detecção da pneumonia causada pelo SARS-COV-2 contribuirão para o enfrentamento da pandemia.

## REFERENCES

- [1] S. Cimerman, A. Chebabo, C. A. da Cunha, and A. J. Rodríguez-Morales, "Deep impact of covid-19 in the healthcare of latin america: the case of brazil," *Braz J Infect Dis*, 2020.
- [2] A. López-Feldman, C. Chávez, M. A. Vélez, H. Bejarano, and A. B. Chimeli, "Environmental impacts and policy responses to covid-19: A view from latin america," *Environmental and Resource Economics*, pp. 1–6, 2020.
- [3] "Coronavirus disease (covid-2019) situation reports," World Health Organization. [Online]. Available: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports/>
- [4] M. J. Miller, J. R. Loaiza, A. Takyar, and R. H. Gilman, "Covid-19 in latin america: Novel transmission dynamics for a global pandemic?" *PLOS Neglected Tropical Diseases*, vol. 14, no. 5, pp. 1–5, 05 2020.
- [5] R. J. Pereira, G. N. L. do Nascimento, L. H. A. Gratão, and R. S. Pimenta, "The risk of covid19 transmission in favelas and slums in brazil," *Public Health*, 2020.
- [6] J. Fierro, "Indigenous people, recognition, and democracy in latin america," *Ethnic and Racial Studies*, pp. 1–20, 2019.
- [7] T. Power, D. Wilson, O. Best, T. Brockie, and L. Bourque Bearskin, "Covid-19 and indigenous peoples: an imperative for action," *Journal of Clinical Nursing*, 2020.
- [8] E. Mahase, "Coronavirus: covid-19 has killed more people than sars and mers combined, despite lower case fatality rate," *BMJ*, vol. 368, 2020.
- [9] G. Grasselli, A. Pesenti, and M. Cecconi, "Critical Care Utilization for the COVID-19 Outbreak in Lombardy, Italy: Early Experience and Forecast During an Emergency Response," *JAMA*, vol. 323, no. 16, pp. 1545–1546, 04 2020.
- [10] J. K. Andrus, T. Evans-Gilbert, J. I. Santos, M. G. Guzman, and P. J. Rosenthal, "Perspectives on battling

- covid-19 in countries of latin america and the caribbean,” *The American journal of tropical medicine and hygiene*, vol. 103, no. 2, p. 593, 2020.
- [11] W. Wang, Y. Xu, R. Gao *et al.*, “Detection of SARS-CoV-2 in Different Types of Clinical Specimens,” *JAMA*, 03 2020.
- [12] X. Xie, Z. Zhong, W. Zhao, C. Zheng, F. Wang, and J. Liu, “Chest ct for typical 2019-ncov pneumonia: relationship to negative rt-pcr testing,” *Radiology*, pp. 200 343–200 343, 2020.
- [13] K. Simbana-Rivera, L. Gomez-Barreno, J. Guerrero, F. Simbana-Guaycha, R. Fernandez, A. Lopez-Cortes, A. Lister, and E. Ortiz-Prado, “Interim analysis of pandemic coronavirus disease 2019 (covid-19) and the sars-cov-2 virus in latin america and the caribbean: Morbidity, mortality and molecular testing trends in the region,” *medRxiv*, 2020.
- [14] R. Silva, F. Araujo, L. Santos, R. Veras, and F. Medeiros, “Optic disc detection in retinal images using algorithms committee with weighted voting,” *IEEE Latin America Transactions*, vol. 14, no. 5, pp. 2446–2454, 2016.
- [15] T. Mahmud, M. A. Rahman, and S. A. Fattah, “CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization,” *Computers in Biology and Medicine*, vol. 122, jul 2020.
- [16] W. E. Brant and C. A. Helms, *Fundamentals of diagnostic radiology*. Lippincott Williams & Wilkins, 2012.
- [17] M. Y. Chen, T. L. Pope, and D. J. Ott, *Basic radiology*. McGraw-Hill Education - Europe, 2011.
- [18] V. Agarwal, S. Uretsky, and A. N. Makaryus, “Multimodality imaging (x-ray, ct and mri) in pericardial disease,” in *Management of Pericardial Disease*. Springer, 2014, pp. 89–107.
- [19] N. Dalbeth and A. Doyle, “Chapter 8 - imaging of gout,” in *Gout*, N. Schlesinger and P. E. Lipsky, Eds. Elsevier, 2019, pp. 89 – 100.
- [20] F. Shi, J. Wang, J. Shi, Z. Wu, Q. Wang, Z. Tang, K. He, Y. Shi, and D. Shen, “Review of artificial intelligence techniques in imaging data acquisition, segmentation and diagnosis for covid-19,” *IEEE Reviews in Biomedical Engineering*, pp. 1–1, 2020.
- [21] K. Chan, V. Wong, and S. Tang, “Covid-19: An update on the epidemiological, clinical, preventive and therapeutic evidence and guidelines of integrative chinese–western medicine for the management of 2019 novel coronavirus disease,” *The American journal of Chinese medicine*, pp. 1–26, 2020.
- [22] H. Singh, J. A. Neutze, and J. R. Enterline, *Radiology fundamentals: Introduction to imaging & technology*. Springer, 2014.
- [23] J. Kanne, B. Little, J. Chung *et al.*, “Essentials for radiologists on covid-19: an update—radiology scientific expert panel,” *Radiology*, 2020.
- [24] T. Ai, Z. Yang, H. Hou *et al.*, “Correlation of chest ct and rt-pcr testing in coronavirus disease 2019 (covid-19) in china: a report of 1014 cases,” *Radiology*, p. 200642, 2020.
- [25] M. Chung, A. Bernheim, X. Mei *et al.*, “Ct imaging features of 2019 novel coronavirus (2019-ncov),” *Radiology*, vol. 295, pp. 202–207, 2020.
- [26] K. Murphy, H. Smits, and A. J. Knoop, “Covid-19 on the chest radiograph: A multi-reader evaluation of an ai system,” *Radiology*, p. 201874, 2020.
- [27] “Covid-19 ct segmentation dataset,” 2020, <http://medicalsegmentation.com/covid19/>.
- [28] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [29] L. Torrey and J. Shavlik, “Transfer learning,” in *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*. IGI Global, 2010, pp. 242–264.
- [30] B. Kitchenham, “Procedures for performing systematic reviews,” *Keele, UK, Keele University*, vol. 33, no. 2004, pp. 1–26, 2004.
- [31] I. D. Apostolopoulos and T. A. Mpesiana, “Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks,” *Physical and Engineering Sciences in Medicine*, vol. 43, no. 2, pp. 635–640, jun 2020.
- [32] M. S. e A. Howard e M. Zhu e A. Zhmoginov e L. Chen, “Mobilenetv2: Inverted residuals and linear bottlenecks,” in *Conference on Computer Vision and Pattern Recognition*, 2018, pp. 4510–4520.
- [33] K. El Asnaoui and Y. Chawki, “Using x-ray images and deep learning for automated detection of coronavirus disease,” *Journal of Biomolecular Structure and Dynamics*, 2020.
- [34] M. E. H. Chowdhury, T. Rahman, A. Khandakar, R. Mazhar, M. A. Kadir, Z. B. Mahbub, K. R. Islam, M. S. Khan, A. Iqbal, N. Al-Emadi, M. B. I. Reaz, and M. T. Islam, “Can AI help in screening Viral and COVID-19 pneumonia?” *IEEE Access*, p. 1, 2020.
- [35] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, “Inception-v4, inception-resnet and the impact of residual connections on learning,” *AAAI Conference on Artificial Intelligence*, 02 2016.
- [36] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, “ImageNet: A Large-Scale Hierarchical Image Database,” in *CVPR09*, 2009.
- [37] G. Huang, Z. Liu, L. van der Maaten, and K. Weinberger, “Densely connected convolutional networks,” in *The IEEE Conference on Computer Vision and Pattern Recognition*, July 2017.
- [38] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, and H. Mehta, “Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning,” *arXiv*, 2017.
- [39] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. Jamalipour Soufi, “Deep-COVID: Predicting COVID-19 From Chest X-Ray Images Using Deep Transfer Learning,” *Medical Image Analysis*, p. 101794, jul 2020.

- [40] M. D. Zeiler and R. Fergus, "Visualizing and understanding convolutional networks," in *Lecture Notes in Computer Science*, vol. 8689 LNCS, no. PART 1. Springer Verlag, 2014, pp. 818–833.
- [41] F. Iandola, S. Han, M. Moskewicz, K. Ashraf, W. Dally, and K. Keutzer, "Squeezenet: Alexnet-level accuracy with 50x fewer parameters and <0.5mb model size," arXiv, 2016.
- [42] I. D. Apostolopoulos, S. I. Aznaouridis, and M. A. Tzani, "Extracting Possibly Representative COVID-19 Biomarkers from X-ray Images with Deep Learning Approach and Image Data Related to Pulmonary Diseases." *Journal of Medical and Biological Engineering*, vol. 40, no. 3, pp. 1–8, may 2020.
- [43] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, and D. Warde-Farley, "Generative adversarial networks," *Advances in neural information processing systems*, vol. 3, no. 06, 2014.
- [44] S. Albahli, "Efficient GAN-based Chest Radiographs (CXR) augmentation to diagnose coronavirus disease pneumonia," *International Journal of Medical Sciences*, vol. 17, no. 10, pp. 1439–1448, jun 2020.
- [45] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-v4, inception-resnet and the impact of residual connections on learning," *AAAI Conference on Artificial Intelligence*, 2016.
- [46] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [47] A. Waheed, M. Goyal, D. Gupta, A. Khanna, F. Al-Turjman, and P. R. Pinheiro, "CovidGAN: Data Augmentation Using Auxiliary Classifier GAN for Improved Covid-19 Detection," *IEEE Access*, vol. 8, pp. 91 916–91 923, 2020.
- [48] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," in *International Conference on Learning Representations*, 2015.
- [49] P. H. Yi, T. K. Kim, and C. T. Lin, "Generalizability of Deep Learning Tuberculosis Classifier to COVID-19 Chest Radiographs: New Tricks for an Old Algorithm?" *Journal of Thoracic Imaging*, 2020.
- [50] L. Brunese, F. Mercaldo, A. Reginelli, and A. Santone, "Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays." *Computer Methods and Programs in Biomedicine*, vol. 196, p. 105608, jun 2020.
- [51] M. Toğaçar, B. Ergen, and Z. Cömert, "COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches," *Computers in Biology and Medicine*, vol. 121, jun 2020.
- [52] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf, "Support vector machines," *IEEE Intelligent Systems and their applications*, vol. 13, no. 4, pp. 18–28, 1998.
- [53] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla, and Y. M. Costa, "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios," *Computer Methods and Programs in Biomedicine*, vol. 194, oct 2020.
- [54] J. M. Keller, M. R. Gray, and J. A. Givens, "A fuzzy k-nearest neighbor algorithm," *IEEE transactions on systems, man, and cybernetics*, no. 4, pp. 580–585, 1985.
- [55] S. K. Pal and S. Mitra, "Multilayer perceptron, fuzzy sets, and classification," *IEEE Transactions on Neural Networks*, vol. 3, no. 5, pp. 683–697, 1992.
- [56] S. R. Safavian and D. Landgrebe, "A survey of decision tree classifier methodology," *IEEE transactions on systems, man, and cybernetics*, vol. 21, no. 3, pp. 660–674, 1991.
- [57] L. Breiman, "Random forests," *Machine Learning*, vol. 45, pp. 5–32, 2001.
- [58] D. Das, K. C. Santosh, and U. Pal, "Truncated inception net: COVID-19 outbreak screening using chest X-rays," *Physical and Engineering Sciences in Medicine*, 2020.
- [59] F. Ucar and D. Korkmaz, "COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images." *Medical Hypotheses*, vol. 140, p. 109761, apr 2020.
- [60] A. Altan and S. Karasu, "Recognition of COVID-19 disease from X-ray images by hybrid model consisting of 2D curvelet transform, chaotic salp swarm algorithm and deep learning technique," *Chaos, Solitons and Fractals*, vol. 140, nov 2020.
- [61] M. Sanaj and P. J. Prathap, "Nature inspired chaotic squirrel search algorithm (cssa) for multi objective task scheduling in an iaas cloud computing atmosphere," *Engineering Science and Technology, an International Journal*, 2019.
- [62] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," arxiv, 2019.
- [63] H. Panwar, P. Gupta, M. Siddiqui, R. Menendez, and V. Singh, "Application of deep learning for fast detection of covid-19 in x-rays using ncovnet," *Chaos, Solitons, and Fractals*, vol. 138, sep 2020.
- [64] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in Biology and Medicine*, vol. 121, jun 2020.
- [65] A. Khan, J. Shah, and M. Bhat, "CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images," *Computer Methods and Programs in Biomedicine*, vol. 196, nov 2020.
- [66] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 1251–1258.
- [67] S. Toraman, T. B. Alakus, and I. Turkoglu, "Convolutional capsnet: A novel artificial neural network approach to detect COVID-19 disease from

- X-ray images using capsule networks,” *Chaos, Solitons and Fractals*, vol. 140, nov 2020.
- [68] N. Narayan Das, N. Kumar, M. Kaur, V. Kumar, and D. Singh, “Automated Deep Transfer Learning-Based Approach for Detection of COVID-19 Infection in Chest X-rays,” *IRBM*, 2020.
- [69] M. Rahimzadeh and A. Attar, “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*, vol. 19, p. 100360, jan 2020.
- [70] S. Vaid, R. Kalantar, and M. Bhandari, “Deep learning COVID-19 detection bias: accuracy through artificial intelligence,” *International Orthopaedics*, 2020.
- [71] S. Rajaraman and S. Antani, “Weakly labeled data augmentation for deep learning: A study on COVID-19 detection in chest X-rays,” *Diagnostics*, vol. 10, no. 6, jun 2020.
- [72] S. Rajaraman, J. Siegelman, P. O. Alderson, L. S. Folio, L. R. Folio, and S. K. Antani, “Iteratively Pruned Deep Learning Ensembles for COVID-19 Detection in Chest X-Rays,” *IEEE Access*, vol. 8, pp. 115 041–115 050, 2020.
- [73] Y. Oh, S. Park, and J. C. Ye, “Deep Learning COVID-19 Features on CXR using Limited Training Data Sets,” *IEEE Transactions on Medical Imaging*, p. 1, 2020.
- [74] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention*, 2015, pp. 234–241.
- [75] S. J. e M. Drozdal e D. Vazquez e A. Romero e Y. Bengio, “The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation,” in *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2017, pp. 1175–1183.
- [76] H. Ko, H. Chung, K. W. Kim, Y. S. Shin, and S. J. Kang, “COVID-19 pneumonia diagnosis using a simple 2D deep learning framework with a single chest CT image,” *Journal of Medical Internet Research*, jun 2020.
- [77] A. A. Ardakani, A. R. Kanafi, U. R. Acharya, N. Khadem, and A. Mohammadi, “Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks,” *Computers in Biology and Medicine*, vol. 121, jun 2020.
- [78] A. Sakagianni, G. Feretzakis, D. Kalles, C. Koufopoulou, and V. Kaldis, “Setting up an Easy-to-Use Machine Learning Pipeline for Medical Decision Support: A Case Study for COVID-19 Diagnosis Based on Deep Learning with CT Scans,” *Studies in Health Technology and Informatics*, vol. 272, pp. 13–16, 2020.
- [79] E. Bisong, “Google automl: Cloud vision,” in *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Springer, 2019, pp. 581–598.
- [80] A. Jaiswal, N. Gianchandani, D. Singh, V. Kumar, and M. Kaur, “Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning,” *Journal of Biomolecular Structure and Dynamics*, 2020.
- [81] Z. Han, B. Wei, Y. Hong, T. Li, J. Cong, X. Zhu, H. Wei, and W. Zhang, “Accurate Screening of COVID-19 using Attention Based Deep 3D Multiple Instance Learning,” *IEEE Transactions on Medical Imaging*, p. 1, 2020.
- [82] Y. Pathak, P. Shukla, A. Tiwari, S. Stalin, and S. Singh, “Deep Transfer Learning Based Classification Model for COVID-19 Disease,” *IRBM*, 2020.
- [83] Q. Ni, Z. Y. Sun, L. Qi, W. Chen, and Y. Yang, “A deep learning approach to characterize 2019 coronavirus disease (COVID-19) pneumonia in chest CT images,” *European Radiology*, pp. 1–11, jul 2020.
- [84] S. Wang, Y. Zha, W. Li, Q. Wu, X. Li, and M. Niu, “A Fully Automatic Deep Learning System for COVID-19 Diagnostic and Prognostic Analysis,” *European Respiratory Journal*, p. 2000775, may 2020.
- [85] T. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, “Feature pyramid networks for object detection,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 936–944.
- [86] X. Wu, H. Hui, M. Niu, L. Li, and L. Wang, “Deep learning-based multi-view fusion model for screening 2019 novel coronavirus pneumonia: A multicentre study,” *European Journal of Radiology*, vol. 128, jul 2020.
- [87] S. Hu, Y. Gao, Z. Niu, Y. Jiang, L. Li, X. Xiao, M. Wang, E. F. Fang, W. Menpes-Smith, J. Xia, H. Ye, and G. Yang, “Weakly Supervised Deep Learning for COVID-19 Infection Detection and Classification From CT Images,” *IEEE Access*, pp. 118 869–118 883, 2020.
- [88] X. Wang, X. Deng, Q. Fu, Q. Zhou, J. Feng, H. Ma, W. Liu, and C. Zheng, “A Weakly-supervised Framework for COVID-19 Classification and Lesion Localization from Chest CT,” *IEEE Transactions on Medical Imaging*, p. 1, 2020.
- [89] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in Neural Information Processing Systems 25*, F. Pereira, C. Burges, L. Bottou, and K. Weinberger, Eds. Curran Associates, Inc., 2012, pp. 1097–1105.
- [90] X. Xu, X. Jiang, C. Ma, P. Du, and X. Li, “A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia,” *Engineering*, jun 2020.
- [91] W. Wu, X. Li, P. Du, G. Lang, M. Xu, K. Xu, and L. Li, “A deep learning system that generates quantitative ct reports for diagnosing pulmonary tuberculosis,” *arXiv*, 2019.
- [92] S. Roy, W. Menapace, S. Oei, B. Luijten, E. Fini, C. Saltori, I. Huijben, and N. Chennakeshava, “Deep learning for classification and localization of COVID-19 markers in point-of-care lung ultrasound,” *IEEE Transactions on Medical Imaging*, p. 1, 2020.
- [93] M. Jaderberg, K. Simonyan, A. Zisserman *et al.*, “Spatial transformer networks,” in *Advances in neural information processing systems*, 2015, pp. 2017–2025.

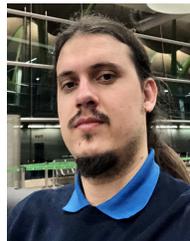
- [94] S. M. K. Hasan and C. Linte, "U-netplus: A modified encoder-decoder u-net architecture for semantic and instance segmentation of surgical instruments from laparoscopic images," in *41st International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 2019, 07 2019, pp. 7205–7211.
- [95] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," in *European conference on computer vision*, 2018.
- [96] H. Y. F. Wong, H. Y. S. Lam, A. H.-T. Fong, S. T. Leung, and T. W.-Y. Chin, "Frequency and distribution of chest radiographic findings in covid-19 positive patients," *Radiology*, p. 201160, 2020.
- [97] F. Shi, J. Wang, J. Shi, Z. Wu, and Q. Wang, "Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation and Diagnosis for COVID-19," *IEEE Reviews in Biomedical Engineering*, 2020.
- [98] J. Shiraishi, S. Katsuragawa, J. Ikezoe, T. Matsumoto, and T. Kobayashi, "Development of a digital image database for chest radiographs with and without a lung nodule: Receiver operating characteristic analysis of radiologists' detection of pulmonary nodules," *American Journal of Roentgenology*, vol. 174, no. 1, pp. 71–74, 2000.
- [99] S. Jaeger, S. Candemir, S. Antani, Y.-X. J. Wang, P.-X. Lu, and G. Thoma, "Two public chest X-ray datasets for computer-aided screening of pulmonary diseases." *Quantitative imaging in medicine and surgery*, vol. 4, no. 6, pp. 475–477, 2014.
- [100] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, "ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases," in *30th IEEE Conference on Computer Vision and Pattern Recognition*, nov 2017, pp. 3462–3471.
- [101] D. S. Kermany, M. Goldbaum, W. Cai, C. C. Valentim, and H. Liang, "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," *Cell*, vol. 172, no. 5, pp. 1122–1131, feb 2018.
- [102] H. He, Y. Bai, E. A. Garcia, and S. Li, "Adasyn: Adaptive synthetic sampling approach for imbalanced learning," in *2008 IEEE international joint conference on neural networks*. IEEE, 2008, pp. 1322–1328.
- [103] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "Smote: synthetic minority over-sampling technique," *Journal of artificial intelligence research*, vol. 16, pp. 321–357, 2002.
- [104] I. Tomek, "An experiment with the edited nearest-neighbor rule," *IEEE Trans on Systems, Man, and Cybernetics*, vol. 6, pp. 448–452, 1976.
- [105] C. Shorten and T. Khoshgoftaar, "A survey on image data augmentation for deep learning," *Journal of Big Data*, vol. 6, no. 1, p. 60, 2019.
- [106] M. Patrick, A. Adekoya, A. Migthy, and B. Edward, "Capsule networks—a survey," *Journal of King Saud University-Computer and Information Sciences*, 2019.
- [107] R. Gonzalez and R. Woods, *Digital Image Processing*. Pearson Education, 2008.
- [108] Y. Guo, Y. Liu, T. Georgiou, and M. Lew, "A review of semantic segmentation using deep neural networks," *International journal of multimedia information retrieval*, vol. 7, no. 2, pp. 87–93, 2018.
- [109] J. d. A. B. Araujo-Filho, M. V. Y. Sawamura, A. A. N. Costa, G. G. Cerri, and C. H. Nomura, "Covid-19 pneumonia: what is the role of imaging in diagnosis?" *Jornal Brasileiro de Pneumologia*, vol. 46, 2020.



**Orrana L. V. de Sousa** é aluna do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Piauí (UFPI). Bacharel em Sistemas de Informação pela UFPI. Suas pesquisas se concentram em análise de dados com foco em detecção de desastres naturais.



**Deborah M. V. Magalhães** é professora da Universidade Federal do Piauí, Campus Senador Helvídio Nunes de Barros, Picos. Doutora e Mestre em Engenharia de Teleinformática pela Universidade Federal do Ceará. Suas pesquisas se concentram em análise de dados e processamento de áudio para detecção de patologias e classificação de sons.



**Pablo de A. Vieira** é aluno do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Piauí. Graduado em Gestão em Sistemas de Informação pelo Instituto de Ensino Superior de Teresina. Suas pesquisas se concentram em visão computacional.



**Romuere R. V. e Silva** é professor da Universidade Federal do Piauí (UFPI) Campus Senador Helvídio Nunes de Barros, Picos. Doutor em Engenharia de Teleinformática pela Universidade Federal do Ceará, graduado e mestre em Ciência da Computação pela UFPI. Suas pesquisas se concentram em visão computacional aplicado a imagens médicas.