



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de São José do Rio Preto

Pedro Lucas Miguel

Investigação de Deep Learned Features no Contexto de Imagens de COVID-19

São José do Rio Preto
2022

Pedro Lucas Miguel

Investigação de Deep Learned Features no Contexto de Imagens de COVID-19

Trabalho de Conclusão de Curso (TCC) apresentado como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação, junto ao Conselho de Curso de Bacharelado em Ciência da Computação, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de São José do Rio Preto.

Financiadora: CNPq - Proc. 01/2020

Orientador:

Prof. Dr. Leandro Alves Neves

São José do Rio Preto
2022

M636i Miguel, Pedro Lucas
Investigação de Deep Learned Features no Contexto de Imagens de COVID-19 / Pedro Lucas Miguel. -- São José do Rio Preto, 2022
70 p. : il., tabs., fotos

Trabalho de conclusão de curso (Bacharelado - Ciência da Computação) - Universidade Estadual Paulista (Unesp), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto
Orientador: Leandro Alves Neves

1. Redes neurais (Computação). 2. Inteligência artificial Aplicações médicas. 3. Processamento de imagens. 4. COVID-19 (Disease). I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

Pedro Lucas Miguel

Investigação de Deep Learned Features no Contexto de Imagens de COVID-19

Trabalho de Conclusão de Curso (TCC) apresentado como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação, junto ao Conselho de Curso de Bacharelado em Ciência da Computação, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de São José do Rio Preto.

Financiadora: CNPq - Proc. 01/2020

Comissão Examinadora:

Prof. Dr. Adriano Mauro Cansian

UNESP – Câmpus de São José do Rio Preto

Prof. Dr. Leandro Alves Neves

UNESP – Câmpus de São José do Rio Preto
Orientador

Prof. Dr. Wallace Casaca

UNESP – Câmpus de São José do Rio Preto

**São José do Rio Preto
1 de Dezembro de 2022**

Dedico este trabalho a minha mãe por todo o suporte que me trouxe até aqui. Dedico também este trabalho a todos os meus colegas que me acompanharam nesta jornada.

Agradecimentos

Antes de mais nada, agradeço a minha mãe por ter sido a minha força motriz durante todo o processo da graduação, pois sem o seu suporte, eu não teria tido condições que chegar a onde estou.

Estendo também meus agradecimentos para meu colega Bruno Caobianco Polotto, por todo o suporte relacionado a compreensão de termos e conceitos presentes na área da medicina.

Agradeço todos os professores que colaboraram com o meu crescimento acadêmico, em especial, agradeço o Prof. Dr. Leandro Alves Neves por toda a ajuda que a mim foi concedida, não só durante a graduação e durante o desenvolvimento de meu trabalho científico, mas por também ter atuado como um excelente mentor nos mais variados campos da vida.

Finalmente, agradeço ao apoio financeiro fornecido pelo CNPq e PROPe para o desenvolvimento deste trabalho.

"Sailing t'wards the unknown, with my crew on the sea.
And the day that i return, a hero i shall be"

- The Longing - Patty Gurdy

Resumo

Neste trabalho, foi desenvolvido um estudo fundamentado em *deep learned features* por *transfer learning* para definir um conjunto de atributos e técnicas a fim de classificar e reconhecer padrões em imagens radiográficas de COVID-19. A análise foi realizada por meio de três modelos de aprendizado profundo. As arquiteturas escolhidas foram a *Residual Neural Network* com 50 camadas (ResNet-50), *Dense Convolutional Network* com 201 camadas (DenseNet-201) e a EfficientNet-b0 (com 237 camadas). Neste estudo, a camada *avg_pool* de cada arquitetura foi escolhida para a análise, com 2048 descritores na ResNet-50, 1920 na DenseNet-201 e 1280 na EfficientNet-b0. As *deep learned features* mais relevantes foram definidas para o processo de classificação, aplicando o algoritmo ReliefF com limiares distintos e duas estratégias de classificação: classificadores aplicados individualmente e por meio de *ensemble*, usando a abordagem de fusão em nível de pontuação. Como parte das contribuições deste trabalho, foram identificadas duas principais combinações, ambas resultantes do modelo DenseNet-201 e um único conjunto de features mais representativo. A primeira combinação foi com o uso do classificador SMO (98,38% de acurácia) e a segunda foi do *ensemble* (acurácia de 97,89%). O conjunto de atributos mais relevante envolveu somente 210 *deep learned features*, com apenas 10% do total inicial de atributos. As informações expostas são contribuições relevantes para os especialistas interessados no estudo e desenvolvimento de sistemas direcionadas para imagens radiográficas representativas de COVID-19.

Palavras-chave: Imagens radiográficas, COVID-19, redes neurais convolucionais, *deep learned features*, ReliefF, reconhecimento de padrões.

Abstract

In this proposal, a study based on deep learned features from transfer learning was conducted to obtain a set of features and techniques to classify and recognize patterns in COVID-19 images. The analyses was conducted using a total of three deep learning models. The chosen models were Residual Neural Network using 50 layers (ResNet-50), Dense Convolutional Network using 201 layers (DenseNet-201) and EfficientNet-b0 using 237 layers. In this proposal, the chosen layer for analysis was the avg_pool layer from each model, this layer is composed by 2048 features on ResNet-50, 1920 features on DenseNet0201, and finally, 1280 features on the EfficientNet-b0. The most relevant deep learned features where obtained for the classification process, applying the RelieF algorithm and two classification strategies: classifiers applied individually and through ensemble of classifiers using score level fusion. As part of the contributions obtained from this study, two combinations were identified, both of them using the DenseNet-201 model with the same set of features. The first combination used the SMO classifier (accuracy of 98,38%) and the second combination used ensemble (accuracy of 97,89%). The most relevant set of features was composed with only 210 deep learned features, using only 10% of the initial amount of features. Those informations are relevant contributions to specialists that are interested in the study and development of systems oriented to X-ray images of COVID-19.

Keywords: *Radiographic images, COVID-19, convolutional neural networks, deep learned features, RelieF, pattern recognition.*

Lista de Figuras

2.1	Ilustração da arquitetura clássica de uma CNN.	22
2.2	Exemplo <i>max pooling</i> (Tamanho do filtro = 2; Passo = 2).	22
2.3	Diagrama esquemático do modelo ResNet-50.	27
2.4	Ilustração de um bloco residual na arquitetura ResNet-50.	27
2.5	Modelo esquemático da DenseNet-201	29
2.6	Estratégias para aumentar o desempenho de uma CNN.	31
2.7	Diagrama esquemático do modelo EfficientNet-b0.	33
2.8	Ilustração da estrutura de um vetor de características, em que cada linha da tabela representa um único vetor de características.	34
4.1	Diagrama esquemático do método proposto.	47
4.2	Exemplos de imagens de COVID-19 de uma base pública (COHEN et al., 2020)	50
5.1	Valores de acurácias (%) em função dos vetores com dimensões de 10 a 250 <i>deep learned features</i> por <i>transfer learning</i> e um <i>ensemble</i> de classificadores, considerando a camada <i>avg_pool</i> da ReseNet-50, DenseNet-201 e EfficientNet-b0.	55
5.2	Valores de acurácias (%) em função de diferentes composições de ve- tores de <i>deep learned features</i> por <i>transfer learning</i> e classificadores, explorando a camada <i>avg_pool</i> da rede ResNet-50	56

5.3	Valores de acurácias (%) em função de diferentes composições de vetores de <i>deep learned features</i> por <i>transfer learning</i> e classificadores, explorando a camada <i>avg_pool</i> da rede DenseNet-201	57
5.4	Valores de acurácias (%) em função de diferentes composições de vetores de <i>deep learned features</i> por <i>transfer learning</i> e classificadores, explorando a camada <i>avg_pool</i> da rede EfficientNet-b0	57
5.5	Valores de acurácias (%) obtidos com a aplicação das redes ResNet-50, DenseNet-201 e EfficientNet-b0, explorando classificações com até 50 <i>epochs</i>	59

Lista de Tabelas

3.1	Sumarização dos trabalhos correlatos, abordando a estratégia utilizada e as acurácias conquistadas em cada contexto de imagens radiográficas de COVID-19.	44
3.2	Sumarização dos trabalhos correlatos, abordando o uso de CNNs Consolidadas	44
3.3	Sumarização dos trabalhos correlatos, abordando o uso de Análise de Características	45
4.1	Número de características da camada <i>avg_pool</i> das redes analisadas .	49
5.1	Resumo das cinco melhores associações de técnicas para a classificação de imagens radiográficas de COVID-19, com as indicações das métricas de acurácia, medida-F e AUC.	58
5.2	Visão ilustrativa de trabalhos correlatos direcionados para a classificação de imagens radiográficas pulmonares de COVID-19.	60

Lista de Abreviações

ACC Acurácia

ANN Artificial Neural Network

AUC Área sob a Curva ROC

CNN Convolutional Neural Network

FN Falso Negativo

FP Falso Positivo

IBk Instance Based k

LWL Locally weighted learning

PCA Principal Component Analysis

RaF Random Forest

RaT Random Tree

ReLU Rectified Linear Activation Function

ResExLBP Residual Exemplar Local Binary Pattern

RNA Rede Neural Artificial

ROC Receiver Operating Characteristic

SMO Sequential Minimal Optimization

SVM Support Vector Machine

VN Verdadeiro Negativo

VP Verdadeiro Positivo

Sumário

1	Introdução	15
1.1	Justificativas e Motivação	17
1.2	Objetivos	18
1.3	Organização do Projeto	19
2	Fundamentação Teórica	20
2.1	Redes Neurais Convolucionais	20
2.1.1	Problema do Gradiente de Fuga	23
2.1.2	O Problema do Sobreajuste (<i>Overfitting</i>)	23
2.1.3	Transferência de Aprendizado	24
2.1.4	Funções de ativação	25
2.2	Modelos de CNNs	26
2.2.1	Especificação da CNN ResNet	26
2.2.2	Especificação da CNN DenseNet	28
2.2.3	Especificação da CNN EfficientNet	30
2.3	Extração de Características	33
2.4	Seleção de Características Utilizando o Algoritmo RelieF	34
2.5	Abordagens para Classificação de Características	35
2.5.1	Baseados em função	35
2.5.2	Baseados em <i>Lazy Learning</i>	36
2.5.3	Baseados em Árvore de Decisão	37

2.5.4	<i>Ensemble</i> de Classificadores	38
2.6	Métricas para Avaliação de Desempenho	39
3	Revisão Bibliográfica	41
3.1	CNNs Especializadas	41
3.2	CNNs Consolidadas	42
3.3	Análise de Características	43
3.4	Considerações Sobre os Trabalhos Relacionados	44
4	Metodologia	46
4.1	Estruturação do Método: Visão Geral	46
4.2	Etapa 1: Definição do processo de extração de <i>deep learned features</i> e contexto de aplicação	48
4.2.1	Camadas selecionadas para análise	48
4.2.2	Base de Dados	49
4.3	Etapa 2: Composição e seleção dos conjuntos de <i>deep learned features</i>	50
4.4	Etapa 3: Análises e extração de conhecimento	51
4.5	Ferramentas e Ambiente de Desenvolvimento	52
5	Resultados	54
5.1	Principais combinações entre vetores de <i>deep learned features</i> e estra- tégias de classificação	54
5.2	Discussão sobre os resultados obtidos	58
6	Conclusões	61
6.0.1	Divulgação e Apresentação	62
	Referências	63

Capítulo 1

Introdução

A análise de imagens radiográficas é um dos métodos utilizados na prática clínica para definir diagnósticos e prognósticos de uma dada doença. Estes tipos de imagens são notoriamente caracterizadas por apresentarem um alto potencial de exploração, tornando-as objeto de estudo no âmbito da visão computacional e reconhecimento de padrões (RAHMAN et al., 2022; XING et al., 2022). Neste contexto, o estudo de imagens radiográficas possibilita a extração e aprendizado de padrões considerados relevantes para se realizar o diagnóstico de doenças. Estes processos, porém, apresentam um alto nível de complexidade, tornando necessária a criação de estratégias que consigam realizar esse tipo de análise de forma automatizada. Neste cenário, várias metodologias baseadas no processo de aprendizado por representação foram criadas com o intuito de solucionar esses tipos de problemas (SU et al., 2022; SONG et al., 2022).

O aprendizado por representação abrange um conjunto de técnicas para realizar a transformação automática de dados, como *pixels* de uma imagem digital, em um vetor de características. Este processo possibilita investigar possíveis padrões existentes no domínio sob análise. Neste contexto, os modelos baseados em *deep learning* (ou aprendizado profundo), se destacam entre as diferentes abordagens de aprendizado de máquina, por terem múltiplos níveis de representações e, com isso, realizam o

aprendizado de funções de alta complexidade (LECUN; BENGIO; HINTON, 2015; MIDDYA; ROY, 2022; WANG; HARGREAVES, 2022; KAMALOV et al., 2022).

Dentre os diferentes tipos de técnicas de *deep learning*, pode-se destacar os algoritmos de redes neurais artificiais (RNA), do inglês *artificial neural network* (ANN). Este conceito surgiu na década de 80, com o intuito de se obter modelos que conseguissem solucionar problemas reais e aplicados (PSALTIS; SIDERIS; YAMAMURA, 1988). As RNAs visam criar modelos capazes de simular o comportamento de análise e tomada de decisões do cérebro humano, e para isso, elas se utilizam de módulos de transformações, que nada mais são do que modelos matemáticos capazes de simular uma rede de neurônios, sendo que as conexões entre neurônios são definidas por pesos. Durante a fase de treinamento da rede, as conexões mais relevantes são reforçadas para se obter a melhor representação dos dados e, consequentemente, uma classificação mais precisa (JAIN; MAO; MOHIUDDIN, 1996).

O aumento da capacidade de processamento dos computadores permitiu explorar um tipo específico de RNA, conhecido como Rede Neural Convolucional, do inglês *Convolutional Neural Network* (CNN), o qual tem fornecido avanços importantes em processamento de imagens, vídeos, áudios, descoberta de medicamentos e estruturas genéticas (LECUN; BENGIO; HINTON, 2015; Bhanu Mahesh; Satyanarayana Murty; Rajya Lakshmi, 2021; URBANIAK; WOLTER, 2021; CHOI et al., 2021). A principal estratégia apresentada para reduzir taxas de erros de classificação, especialmente em problemas complexos, foi aumentar significativamente o número de camadas (profundidade) de uma CNN (HINTON, 2007). Essa prática tornou-se comum em diversas aplicações de Redes Neurais Convolucionais, como as redes treinadas na base de imagens ImageNet (DENG et al., 2009). Apesar disso, essa estratégia impõe dificuldades para o treinamento da rede, especialmente pelo gradiente de fuga extremamente pequeno.

O problema do gradiente de fuga (HOCHREITER, 1998) ocorre durante a fase de

treinamento, em que as conexões das camadas iniciais da rede começam a perder a sua "capacidade de aprender". Este comportamento se dá em decorrência do processo de atualização dos pesos das conexões destas camadas. Como consequência, as características extraídas (*deep learned features*) não são significativamente distintas para favorecer a etapa de classificação, pois tendem a ser muito específicos ao conjunto de dados usado na etapa de treinamento. Por outro lado, se os conjuntos de dados de treinamento são amplos o suficiente, a rede é forçada a aprender uma variedade de padrões, tornando os atributos aprendidos mais generalizáveis. Quando isso acontece, os atributos podem ser investigados separadamente, sem depender das camadas da rede em que foram projetadas para realizar a classificação. Este tipo de estratégia é conhecida como características aprendidas (ou mesmo descritores/atributos aprendidos) por *transfer learning* e tem sido explorada em diferentes estudos envolvendo o processamento de imagens (YU; DONG, 2018; VU et al., 2015; OTÁLORA et al., 2015; NANNI et al., 2020; SUGENO et al., 2021), indicando uma das justificativas que fundamentaram este projeto.

1.1 Justificativas e Motivação

A COVID-19 é uma doença causada pelo coronavírus SARS-CoV-2, afetando as vias aéreas pulmonares. Essa doença pode gerar alguns sintomas na pessoa infectada, como febre, tosse e dificuldade respiratória, sintomas esses que podem evoluir para síndromes respiratórias mais graves, levando o paciente a óbito (MINISTÉRIO..., 2020). Neste contexto, as imagens radiográficas e tomográficas pulmonares são comumente utilizadas para o diagnóstico de COVID-19. Logo, sistemas computacionais podem ser desenvolvidos e aplicados para apoiar especialistas na tarefa de analisar e reconhecer padrões dessa doença, sendo essa uma das principais motivações para o desenvolvimento deste estudo.

Neste contexto, modelos computacionais baseados em *deep learning* indicaram

resultados relevantes no processo de classificação de imagens médicas (GREENSPAN; GINNEKEN; SUMMERS, 2016), em especial, para o reconhecimento de padrões em imagens de COVID-19 (YU; DONG, 2018; VU et al., 2015; OTÁLORA et al., 2015; NANNI et al., 2020; SUGENO et al., 2021). Porém, poucas propostas exploram uma abordagem que visa uma análise sistemática de subconjuntos de *deep learned features*, por meio do algoritmo RelifF, com o uso de diferentes classificadores, sejam aplicados individualmente ou via um *ensemble*.

1.2 Objetivos

Neste estudo, é apresentando uma proposta fundamentada em *deep learned features* por *transfer learning*, com o intuito de definir combinações de atributos e técnicas para a classificação e reconhecimento de padrões em imagens radiográficas de COVID-19. Os objetivos específicos são:

- Explorar três modelos de CNNs em imagens de COVID-19 e obter os atributos convolucionais que representam as classes de imagens sob investigação;
- Selecionar os atributos convolucionais mais relevantes e generalizáveis, via uma estratégia de ranqueamento de atributos, para maximar o desempenho de classificação;
- Aplicar classificadores reconhecidos da área de inteligência artificial para identificar as melhores combinações no contexto de imagens de COVID-19;
- Realizar a fusão (*ensemble*) de classificadores para explorar os pontos fortes de cada um, considerando uma abordagem de fusão por pontuação (*score-level fusion*);
- Identificar as melhores combinações de atributos que fundamentaram os melhores desempenhos para o contexto de imagens de COVID-19.

1.3 Organização do Projeto

Os principais conceitos para o entendimento do projeto estão no Capítulo 2, com informações sobre as Redes Neurais Convolucionais, extração, seleção e classificação de características, além das métricas para avaliação de desempenhos. No Capítulo 3 estão os trabalhos relacionados que embasam o desenvolvimento deste projeto. No Capítulo 4 estão as informações da metodologia desenvolvidos para conquistar os objetivos. Já no capítulo 5 estão presentes os resultados obtidos pela aplicação da metodologia proposta por este estudo, além de uma comparação com resultados obtidos com trabalhos correlatos. Por fim, no capítulo 6 é apresentada a conclusão do trabalho.

Capítulo 2

Fundamentação Teórica

Neste capítulo são apresentados os conceitos necessários para a compreensão do projeto proposto, tais como informações sobre Redes Neurais Convolucionais, processo de extração, ranqueamento e classificação de características, além de métricas comumente exploradas para avaliar modelos de aprendizado de máquina.

2.1 Redes Neurais Convolucionais


As Redes Neurais Convolucionais, do inglês *Convolutional Neural Networks* (CNNs), foram desenvolvidas com o intuito de realizar análises em dados estruturados (LECUN; BENGIO; HINTON, 2015). De forma geral, a topologia de uma CNN consiste em três conceitos principais: campos receptivos locais; pesos compartilhados; e amostragem espacial ou temporal (LECUN et al., 1998). Essa definição está atrelada a diferentes camadas convolucionais presentes em uma CNN, sendo essas camadas responsáveis pela extração de características da rede. Parte da popularidade do uso de CNNs no contexto de análise de imagens, por exemplo, se deve aos resultados obtidos por arquiteturas testadas na competição ILSVRC2012 (KRIZHEVSKY I. SUTSKEVER, 2012).

De forma geral, a arquitetura convencional de uma CNN, como ilustrado na Fi-

gura 2.1, é iniciada por meio de camadas convolucionais intercaladas por camadas de *pooling* que, por fim, são seguidas de camadas totalmente conectadas (ZHOU; GREENSPAN; SHEN, 2017). As camadas de convolução visa extrair características locais de uma matriz (imagem) dada como entrada. Isso se dá por meio do uso de núcleos de aprendizado, comumente denominados como *Kernels*, que se encontram nessas camadas de convolução para calcular mapas de características. As camadas convolucionais que se encontram mais ao início de uma CNN conseguem extrair características de mais baixo nível, como cantos, bordas e texturas. Já as camadas mais profundas da rede conseguem obter características mais complexas e sofisticadas (SANTOS; PONTI, 2019).


As camadas de *pooling* realizam uma redução dos mapas de características que são definidos via camadas de convolução (AFFONSO et al., 2017), além de garantir que a rede se concentre em padrões mais importantes. Isso se dá por meio de um processo de enrijecimento da rede para pequenas variações de padrões aprendidos (NAMATÊVS, 2017). Existem várias maneiras de aplicar o processo de *pooling* (GHOLAMALINEZHAD; KHOSRAVI, 2020), sendo *max pooling* a mais conhecida. Este processo, como ilustrado na Figura 2.2, consiste em computar o maior valor entre algumas unidades locais presentes em um mapa de características.

Figura 2.1: Ilustração da arquitetura clássica de uma CNN.



Fonte: Adaptada de (LECUN; BENGIO; HINTON, 2015).

Figura 2.2: Exemplo *max pooling* (Tamanho do filtro = 2; Passo = 2).



Fonte: (OPEN...,).

2.1.1 Problema do Gradiente de Fuga

Quando se trata de neurais convolucionais, uma das estratégias mais comuns para se obter uma melhor precisão de classificação é o aumento na quantidade de camadas convolucionais. Apesar desse tipo de abordagem favorecer um aumento na precisão de classificação da rede, ela também pode acarretar uma série de problemas durante a etapa de treinamento da rede, em que os pesos das conexões entre camadas são atualizados com o intuito de fortalecer apenas as conexões relevantes no contexto em análise. Um problema presente nesta etapa é conhecido como gradiente de fuga.

O gradiente de fuga (HOCHREITER, 1998) indica que as conexões mais ao início de uma rede CNN perdem a "capacidade de aprender", em razão de envolver valores muito pequenos nas atualizações dos pesos. Isso prejudica o reforço de conexões relevantes e, como consequência, as características extraídas (*deep learned features*) não são significativamente distintas a fim de favorecer a etapa de classificação.

2.1.2 O Problema do Sobreajuste (*Overfitting*)

O *overfitting*, assim como o problema do gradiente de fuga, se apresenta durante a etapa de treinamento da rede, em que o modelo se torna extremamente especializado na classificação do conjunto de dados de treinamento. Este tipo de comportamento é observado em conjuntos de dados demasiadamente pequenos para o treinamento.

Existem vários métodos capazes de minimizar a ocorrência de *overfitting* em uma CNN, tais como: *Batch Normalization*, *Checkpoints* e *Dropout*.

- *Batch Normalization*

Este método consiste em normalizar todos os pesos obtidos após a saída de uma camada da rede e, após isso, realizar o processo de *back-propagation* por meio dos parâmetros normalizados (IOFFE; SZEGEDY, 2015; MA; KLABJAN, 2017).

- *Checkpoint*

A estratégia de *checkpoint* consiste na seleção de uma métrica de avaliação de desempenho (como medida-F, AUC, entre outras) que será utilizada como parâmetro para descartar ou não uma iteração de treinamento. Após o início do treinamento, durante a etapa de validação, a métrica será utilizada para definir se os resultados da iteração atual são melhores dos que os previamente obtidos e, em caso positivo, o treinamento da rede é salvo nessa iteração. Dessa forma, caso a rede comece a obter resultados piores durante a validação, eles não serão permanentemente salvos.

- *Dropout*

Essa técnica consiste na desativação aleatória de neurônios via uma probabilidade pré-definida. O objetivo dessa técnica é diminuir as dependências entre os neurônios, permitindo assim evitar o *overfitting*, além de melhorar a eficiência dos treinos em conjuntos com poucas amostras (ZHOU; GREENSPAN; SHEN, 2017).

2.1.3 Transferência de Aprendizado

O conceito de Transferência de Aprendizado, do inglês *transfer learning*, consiste em um processo de "reutilização de aprendizado" do conhecimento de um modelo como ponto de partida para o aprendizado de um segundo modelo. Essa estratégia se apresenta como uma das mais utilizadas no contexto de Redes Neurais Convolucionais (ZHUANG et al., 2019). Dentre as vantagens fornecidas pelo uso de *transfer learning*, um destaque é a maior facilidade para realizar o treinamento de um novo modelo. Isso garante ao modelo ter um início de processamento com conexões relevantes mais reforçadas, possibilitando minimizar problemas de *overfitting* e Gradiente de fuga, além de favorecer o aprendizado em um novo conjunto de dados. Além disso, o uso de

transfer learning permite que a rede seja treinada com um número menor de dados rotulados, acelerando o processo de treinamento.

2.1.4 Funções de ativação

As funções de ativação são componentes importantes para qualquer tipo de arquitetura de rede neural. De forma geral, as funções de ativação são elementos matemáticos que calculam a relevância da informação recebida na entrada de cada neurônio, controlando a amplitude do sinal emitido na saída de cada neurônio da rede (KARLIK; OLGAC, 2011). As funções de ativação mais conhecidas como Sigmoid e ReLU.

- Sigmoid

A função de ativação Sigmoid, Equação 2.1, é amplamente utilizada para a solução problemas de classificação binária, por assumir apenas valores entre 0 e 1. No entanto, por se tratar de uma função não simétrica a zero, ela pode provocar problemas como o gradiente de fuga, caso não seja devidamente escalonada, dificultando o processo de treinamento (SHARMA, 2017).

$$\text{Sigmoid}(x) = \frac{1}{1 + \exp(-x)}. \quad (2.1)$$

- ReLU

A função ReLU (*rectified linear activation function*), Equação 2.2, é atualmente uma das mais utilizadas em redes neurais pelo baixo custo computacional. Essa função ativa apenas os neurônios que receberam entradas positivas.

$$\text{ReLU}(x) = \max(0, x). \quad (2.2)$$

2.2 Modelos de CNNs


Arquiteturas de Redes Neurais Convolucionais exploram diferentes estratégias para o processo de classificação e reconhecimento de padrões em imagens. Alguns exemplos de sucesso podem ser constatados nos modelos nomeados *ResNet* (Seção 2.2.1), *DenseNet* (Seção 2.2.2) e *EfficientNet* (Seção 2.2.3).

2.2.1 Especificação da CNN ResNet

O modelo ResNet (*Residual Neural Network*) é um dos mais inovadores, desde o sucesso da rede AlexNet na competição ILSVRC2012 (HE et al., 2016), especialmente eficiente para análise de imagens médicas (RAJPAL et al., 2021; SHEHAB et al., 2021; SARWINDA et al., 2021). A ResNet é distribuída em vários sub-modelos nomeados a partir da quantidade de camadas utilizadas (ResNet-18, ResNet-34, ResNet-101 e outros). Um modelo com 50 camadas (ResNet-50) é ilustrado na Figura 2.3.


A ResNet-50 é constituída por blocos residuais, conforme ilustração na Figura 2.4, e uma saída x passa uma conexão *shortcut path* (ou *skip connections*) para ser somada com o caminho principal $f(x)$. É importante destacar que $f(x)$ consiste na saída da última camada convolucional do bloco, exatamente antes da função ReLU. Sendo assim, a saída do bloco residual é $ReLU(f(x) + x)$. Esse tipo de abordagem permite que a rede seja treinada com centenas ou até milhares de camadas, sem incorrer no problema do gradiente de fuga, já que o gradiente é retropropagado diretamente para as camadas anteriores. Outro benefício importante das *skip connections* é permitir que o modelo consiga aprender uma função de identidade a fim de garantir que a camada tenha um desempenho pelo menos tão bom quanto a camada anterior (ELGENDY, 2020).

Figura 2.3: Diagrama esquemático do modelo ResNet-50.



Fonte: Elaborado pelo autor.

Figura 2.4: Ilustração de um bloco residual na arquitetura ResNet-50.



Fonte: (HE et al., 2016).

2.2.2 Especificação da CNN DenseNet


A DenseNet (*Dense Convolutional Network*) explorou uma nova abordagem para realizar as conexões entre as camadas, apresentando resultados significativos no âmbito de processamento de imagens médicas (CHAUHAN; PALIVELA; TIWARI, 2021; KONG; CHENG, 2022; WANG et al., 2021). Segundo a metodologia proposta para o desenvolvimento deste modelo (HUANG et al., 2016), uma rede neural convolucional pode alcançar maior profundidade, com maior acurácia e melhor eficiência na etapa de treinamento, se existir conexões entre as camadas localizadas iniciais e finais. Dessa forma, na DenseNet, foi explorada uma abordagem em que todas as camadas do modelo estão conectadas entre si. A quantidade de conexões diretas presentes em uma DenseNet é dada pela Equação 2.3, em que L é a quantidade total de camadas da rede.

$$L = \frac{L(L+1)}{2} \quad (2.3)$$

Dada uma camada L_0 , os valores para compor os dados de entrada desta camada serão os mapas de características de todas as camadas anteriores a L_0 e, consequentemente, o mapa de características de L_0 , além de todos os outros mapas pertencentes as camadas anteriores a ela, serão usados como entrada para uma camada L_{0+1} . Essa estratégia é aplicada em todos os níveis de camadas e minimiza o problema de gradiente de fuga e reduz substancialmente o número de parâmetros da rede.

A DenseNet possui múltiplos sub-modelos, nomeados a partir da quantidade de camadas utilizadas, tais como DenseNet-121, DenseNet-129, entre outros. Um diagrama esquemático do modelo DenseNet-201 está na Figura 2.5.

Figura 2.5: Modelo esquemático da DenseNet-201




Fonte: (WANG; ZHANG, 2020).

2.2.3 Especificação da CNN EfficientNet

O modelo EfficientNet foi criado com o intuito de utilizar uma abordagem mais sistemática para realizar o processo de otimização de uma rede neural convolucional (TAN; LE, 2020), apresentando resultados muito interessantes, em especial, também no âmbito de análises de imagens médicas (ALI et al., 2022; Shamila Ebenezer et al., 2022). Segundo a metodologia descrita na literatura (TAN; LE, 2020), existem quatro formas principais para obter melhores resultados em uma CNN (Figura 2.6):

- Aumento da largura dos mapas de características;
- Aumento da profundidade da rede por meio de um maior número de camadas;
- Aumentando a resolução das imagens de entrada;
- Utilizar as três estratégias anteriores em conjunto.

Figura 2.6: Estratégias para aumentar o desempenho de uma CNN.



Fonte: Adaptado de (TAN; LE, 2020).

Apesar dessas abordagens apresentarem bons resultados para aumentar o poder de classificação de uma CNN, em sua maioria, acabam sendo utilizadas de forma arbitrária, tornando o processo de otimização tedioso, além de fornecer resultados abaixo do esperado no quesito de acurácia e eficiência (TAN; LE, 2020).

Dessa forma, a EfficientNet considera uma maneira sistemática para definir como que essas estratégias devem ser utilizadas, a fim de se obter bons resultados de classificação. Para isso, foi desenvolvido um método nomeado de *compound scaling method*, cuja função é determinar um balanço entre as abordagens de otimização descritas anteriormente por meio de fatores de escala constantes. Esses fatores são nomeados como α , β e γ , conforme Equação 2.4.


$$\begin{aligned} d &= \alpha^\phi, w = \beta^\phi, r = \gamma^\phi, \\ \alpha \cdot \beta \cdot \gamma &\approx 2, \\ \alpha &\geq 1, \beta \geq 1, \gamma \geq 1, \end{aligned} \tag{2.4}$$

em que ϕ representa os recursos computacionais necessários para executar a rede; d é o fator de escala para profundidade da rede; w é o fator de escala para a largura dos mapas de características; e r é o fator de escala para a resolução dos dados de entrada.

Usando os limites definidos na Equação 2.4, os valores de α , β e γ utilizam um processo chamado *grid search* (LIASHCHYNSKYI; LIASHCHYNSKYI, 2019) para determinar a melhor combinação entre os fatores de escala. Por meio dessa metodologia, o modelo EfficientNet conseguiu uma acurácia de 84,3% na base ImageNet, com uma rede 8.4x menor e 6.1x mais rápida em comparação as redes presentes no *Top 1*.

Por fim, a EfficientNet também possui múltiplos sub-modelos, em especial, o EfficientNet-b0 (*baseline*). Na Figura 2.7 é apresentado um diagrama esquemático do modelo EfficientNet-b0.

Figura 2.7: Diagrama esquemático do modelo EfficientNet-b0.



Fonte: Elaborado pelo autor.

2.3 Extração de Características

O processo de extração de características representa uma das etapas mais importantes no processo de análise de dados. O objetivo é encontrar um conjunto de características, valores que representam as informações visuais em uma imagem, para oferecer uma maior significância no processo de classificação, por exemplo (PEDRINI; SCHWARTZ, 2008). Esses valores podem ser organizados como vetores de características a fim de facilitar o processo de análise (GUYON et al., 2008). Um vetor de características é uma estrutura que permite organizar uma série de informações que podem ser obtidas a partir da análise de imagens, como níveis de borda, texturas, etc. Essas características, são então organizadas de forma a facilitar o processo de interpretação e análise das mesmas (GONZALEZ; WOODS, 2018). As características obtidas a partir dos processos internos de um modelo CNN são conhecidos como *deep learned features*. A Figura 2.8 ilustra a organização dos elementos em um vetor de características.

A partir dos vetores de características, várias técnicas podem ser aplicadas para

Figura 2.8: Ilustração da estrutura de um vetor de características, em que cada linha da tabela representa um único vetor de características.

	Característica 1	Característica 2	...	Característica N
Imagem 1	10	20	...	90
Imagem 2	5	10	...	25
...	...	...	...	...
Imagem M	2	4	...	40

Fonte: Elaborado pelo autor.

analisar as *features* com o propósito de compreender os dados mais relevantes para classificar e reconhecer padrões de imagens.

2.4 Seleção de Características Utilizando o Algoritmo

ReliefF

O processo de seleção de características visa obter um subconjunto de atributos mais relevantes para melhorar o desempenho de um sistema de classificação, por exemplo, evitando ainda a presença de *overfitting* (DASH; LIU, 1997). Dentre as abordagens utilizadas para essa finalidade, existem os algoritmos baseados em filtragem. De forma geral, os algoritmos baseados em filtragem caracterizam-se pela não dependência da estratégia de classificação, ranqueamento os atributos a partir de suas propriedades intrínsecas (GNANA; BALAMURUGAN; LEAVLINE, 2016; CHANDRASHEKAR; SAHIN, 2014). Um exemplo de algoritmo é o ReliefF, que é uma expansão do algoritmo de filtragem Relief (KIRA; RENDELL, 1992b). O ReliefF realiza um ranqueamento de características mais importantes adotando critérios específicos, como análises das distâncias absolutas entre as instâncias e as classes das imagens, e ainda considerando a contribuição média de características vizinhas, tornando o processo ainda mais robusto e confiável (KONONENKO; ŠIMEC; ROBNIK-ŠIKONJA, 1997). A saída fornecida pelo algoritmo ReliefF, consiste em um vetor de características organizado por ordem de importância com base nos pesos calculados

para cada característica (KONONENKO, 1994). O cálculo de peso W da característica A é ajustado por meio das diferenças de probabilidades P , calculadas via a instância mais próxima à classe diferente I_d e a instância mais próxima à mesma classe I_s :

$$W[A] = P(I_d) - P(I_s) \quad (2.5)$$

2.5 Abordagens para Classificação de Características

O processo de classificação de características é um processo em que, dado um conjunto de características, é possível obter métricas que avaliam a relevância desse conjunto. Com o uso desse tipo de técnica, em junção com abordagens de seleção de características, é possível obter um subconjunto de atributos capaz de indicar a melhor acurácia para realizar o processo de classificação. Para tanto, existem múltiplas categoriais de algoritmos que realizam o processo de classificação, organizados como algoritmos baseados em função, *lazy learning* e árvores de decisão, por exemplo. Além disso, os métodos podem ser explorados aplicando a abordagem de *ensemble* de classificadores com uma estratégia de fusão dos resultados.

2.5.1 Baseados em função

Os classificadores Baseados em função utilizam das características do objeto sob análise com o intuito de identificar a qual classe esse objeto pertence. Esse processo de classificação é realizado a partir da combinação linear das características apresentadas pelo objeto em análise (YUAN; HO; LIN, 2012). Neste trabalho, foram escolhidos os classificadores *Support Vector Machine* e *Sequential Minimal Optimization*.

- *Support Vector Machine*

Proposto por (VAPNIK, 1963), o algoritmo *Support Vector Machine* (SVM) utiliza uma função *kernel* a fim de mapear os dados de entrada, por meio de pontos

em um determinado espaço, para um espaço de características de alta dimensão. O objetivo é obter uma separação linear do problema. Esse espaço de alta dimensão é denominado como hiperplano, separando e correlacionando os dados de treinamento com as categorias existentes. Por fim, os dados de validação são classificados conforme a sua localização espacial nas categorias definidas a partir desse hiperplano.

- *Sequential Minimal Optimization*

Proposto por (PLATT, 1998), o algoritmo *Sequential Minimal Optimzation* (SMO) é uma evolução do algoritmo SVM. No caso do algoritmo SVM, a função *kernel* trata-se de uma função quadrática. Logo, é necessário realizar a implementação de um *quadratic programming solver*, adicionando uma complexidade maior para a implementação e compreensão do funcionamento do método. Já o algoritmo SMO, visa dividir o problema descrito anteriormente em vários problemas menores, com o intuito de evitar a necessidade de solucionar equações quadráticas (FLAKE; LAWRENCE, 2002).

2.5.2 Baseados em *Lazy Learning*

Os classificadores baseados em *Lazy Learning* tem como principal característica o "atraso" no processo de generalização do conjunto de dados de treinamento. Isso se deve, pois os classificadores baseados em *Lazy Learning* armazenam todo o conjunto de dados de treinamento, e realizam o processo de classificação apenas quando um conjunto de testes é fornecido (AHA, 1997). Neste trabalho, foram selecionados os algoritmos *Locally weighted learning* e *Instance Based k*.

- *Locally weighted learning*

O algoritmo *Locally weighted learning* (LWL) (FRANK; HALL; PFAHRINGER, 2003; ATKESON; MOORE; SCHAAL, 1996) é um algoritmo baseado

em instâncias e visa associar pesos aos pontos de informação (*data points*) sob análise. O objetivo deste algoritmo é aproximar os pontos de informação selecionados para os pontos de informação desejados, isso é alcançado através de um processo de média entre os pesos dos pontos sob análise e os pontos de teste.

- IBk

O algoritmo *Instance Based k* (IBk) (AHA; KIBLER, 1991) recorre à abordagem de *K-nearest neighbours*, em que K é igual ao número de classes em análise. De forma geral, para cada *feature* em análise, o algoritmo procura pelas K *features* mais próximas combinando-as em um grupo, e por fim, analisa o desempenho deste grupo formado.

2.5.3 Baseados em Árvore de Decisão

Os classificadores baseados em Árvore de Decisão adotam uma estrutura similar a de uma árvore, em que, cada nó representa um atributo (*feature*), cada galho (conexão entre os nós) representa uma decisão e cada folha representa uma das classes analisadas. Essa estrutura visa imitar o pensamento humano, facilitando assim a interpretação deste tipo de classificador (PATEL; PRAJAPATI, 2018). Para este trabalho, foram selecionados os algoritmos *Random Forest* e *Random Tree*:

- *Random Forest*

O algoritmo de *Random Forest* (RaF) (BREIMAN, 2001) realiza a construção e combinação de várias árvores de decisão, utilizadas para realizar a classificação de padrões. O intuito dessa combinação é contornar os problemas de *overfitting*, além de melhorar a aprendizagem de uma única árvore. Inicialmente, K características do conjunto de treinamento são selecionadas aleatoriamente. Essas características são utilizadas para encontrar o nó raiz que representa a característica mais relevante para a tomada de decisão. Dessa forma, outras características

são relacionadas aos nós subsequentes, permitindo que o resultado da classificação se apresente nas folhas da árvore. Esse processo então é repetido, visando gerar diversas árvores de decisão, possibilitando que seja feita uma análise de precisão baseada no número de predições efetuadas pelas múltiplas árvores.

- *Random Tree*

Similar ao *Random Forest*, o algoritmo *Random Tree* (RaT) também utiliza a criação de árvores de decisão baseadas em um valor K de características aleatórias, porém, o algoritmo de RaT cria uma única árvore para realizar a classificação (WEKA..., b).

2.5.4 *Ensemble de Classificadores*

O uso de múltiplos classificadores é uma abordagem comum no âmbito de análise de desempenho de sistemas de reconhecimento de padrões. Quando múltiplos classificadores são utilizados, busca-se encontrar um classificador que consiga fornecer o melhor desempenho. Diferentes algoritmos podem ser aplicados para essa finalidade. Porém, os resultados podem combinados a fim de se obter um resultado único, relevante, a partir da junção de classificações individuais, evitando ainda problemas como *overfitting*. Neste contexto, o uso de *ensemble* de classificadores visa explorar os pontos mais fortes de cada classificação (LUMINI; NANNI, 2017).

Existem diferentes abordagens utilizadas para se realizar um *ensemble*, por exemplo, uso de fusão em nível de pontuação (*score-level fusion*). Nesta abordagem, a predição de cada classificador é adotada como uma opinião da classe que deve ser atribuída a uma determinada imagem sob análise. A decisão final é dada por meio da fusão das n predições dos classificadores, por exemplo, seguindo a regra da soma para produzir a predição final (Equação 2.6).

$$P = \frac{1}{n} \sum_{i=1}^n p_i, \quad (2.6)$$

em que P é a predição final; n é o número total de predições; p_i é a predição, normalizada no intervalo $[0,1]$, do classificador i .

2.6 Métricas para Avaliação de Desempenho

A avaliação de um sistema de classificação pode ser realizar por meio de métricas específicas, tais como acurácia, medida-F e Área sob a Curva ROC (AUC) (DUDA; HART; STORK, 2012).

A acurácia (ACC) é uma das métricas mais comuns na análise de resultados de classificação de imagens. Essa métrica é obtida a partir de uma estrutura nomeada matriz de confusão, envolvendo as categorias:

- Verdadeiros Positivos (VP), valores positivos que foram corretamente classificados como positivos pelo sistema;
- Verdadeiros Negativos (VN), valores negativos classificados corretamente como negativos;
- Falsos Positivos (FP), valores negativos classificados incorretamente pelo sistema;
- Falsos Negativos (FN), valores positivos classificados incorretamente pelo sistema.

A partir disso, a acurácia pode é dada por:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.7)$$

A acurácia corresponde a um valor entre 0% e 100%.

Outra métrica relevante na análise de um sistema de classificação é a medida-F, que indica a qualidade geral de um método. Essa métrica é independente de amostras em cada categoria sob análise, inclusive sobre possíveis desbalanceamentos. A medida-F consiste na média harmônica entre duas outras métricas: precisão (*Prec*) e *recall* (*Rec*). A métrica *Prec* indica a razão entre as amostras classificadas como uma determinada classe e o total de amostras da mesma classe (Equação 2.8):

$$Prec = \frac{VP}{VP + FP} \quad (2.8)$$

O cálculo de *Rec* é realizado de forma similar, porém, agora considerando a outra classe (Equação 2.9).

$$Rec = \frac{VP}{VP + FN} \quad (2.9)$$

Portanto, a medida-F, também denominada como F1, é dada pela Equação 2.10:

$$\text{medida-F} = \frac{2 \times Prec \times Rec}{Prec + Rec} \quad (2.10)$$

Por fim, uma curva ROC, do inglês *Receiver Operating Characteristic*, é definida por meio da métrica *Rec* (Equação 2.9) e especificidade (Equação 2.11). A especificidade define a taxa de amostras negativas que foram corretamente classificadas como negativas. Portanto, um gráfico ROC é uma representação entre 1 – especificidade (eixo x) e *Rec* ou sensibilidade (eixo y). Sendo assim, uma AUC pode assumir valores entre um intervalo de [0,1], em que valores de AUC maiores que 0,5 indicam classificadores com alguma habilidade de discriminação, já uma AUC igual 1 define uma classificação perfeita (FAWCETT, 2006).

$$\text{especificidade} = \frac{VN}{VN + FP} \quad (2.11)$$

Capítulo 3

Revisão Bibliográfica

Neste capítulo, são apresentados trabalhos relacionados ao contexto de Redes Neurais Convolucionais para classificação de imagens de COVID-19. Especificamente, as descrições foram organizadas em CNNs especializadas, uso de CNNs consolidadas e, por fim, análise de características.

3.1 CNNs Especializadas

O processo de análise de imagens radiográficas por meio do uso de CNNs é um tema amplamente explorado no âmbito de processamento de imagens, com aplicações importantes no estudo de imagens de COVID-19. Neste contexto, no estudo realizado por Priyansh Kedia; Anjum; Rahul Katarya (2021) foi apresentada uma Rede Neural Convolucional denominada CoVNet-19. Esse modelo foi obtido por meio da utilização de várias técnicas, como *transfer learning* e *ensemble* de modelos, proporcionando uma acurácia de 99,71% para um conjunto de imagens radiográficas torácicas. A investigação envolveu as classes COVID e *Non-COVID*. Também, a estratégia apresentada por Ashour et al. (2021) envolveu um *ensemble* de modelos. Mas, o *ensemble* foi realizado explorando modelos baseados em *bag-of-features*. A escolha desse tipo de modelo ocorreu considerando variações significativos nas orientações espaciais das

imagens analisadas. Essa proposta conseguiu fornecer uma acurácia de 98,60% na classificação de radiográficas da região do tórax. Por fim, o estudo realizado por Deb et al. (DEB et al., 2022) utilizou como estratégia o *ensemble* de vários modelos consolidados pré-treinados, fundamentados nas redes VGGNet, GoogleNet, DenseNet, e NASNet. O modelo obtido foi então usado como entrada em uma rede *fully connected* para classificar as imagens de interesse. Essa proposta obteve uma acurácia de 98,58%.

3.2 CNNs Consolidadas

Apesar da existência de vários estudos que propuseram redes específicas para solucionar o problema de classificação em questão, outros projetos também abordaram o uso de redes já consolidadas, como no caso do estudo proposto por Walvekar et al. (2020). Neste estudo, foi utilizado o modelo de neural ResNet-50, pré-treinada na base *ImageNet*, utilizando a estratégia de *transfer learning*. A base de imagens utilizada para o treinamento da rede era composta por uma série de imagens de fontes públicas (COHEN; MORRISON; DAO, 2020), totalizando 359 de radiografias da região pulmonar que apontavam a presença de uma pneumonia causada ou não pela COVID-19, totalizando assim duas classes sobre análise. Neste trabalho também foi utilizada uma estratégia conhecida como *Data augmentation*, estratégia essa que possibilita expandir uma base de imagens pequena a partir do conjunto de imagens utilizado, para isso, são novas imagens são criadas a partir de pequenas variações nas imagens já existentes, por processos como rotação e espelhamento. Esse estudo obteve como resultado uma acurácia de 96,23% e uma medida-F de 0,9637.

O estudo proposto por Shamila Ebenezer et al. (2022) envolveu a rede EfficientNet-b0 com o uso de imagens aprimoradas via algoritmos de Laplace e transformada de Wavelet, entre outros. O objetivo principal deste estudo era de verificar o impacto que esses aprimoramentos nas imagens causariam para o treinamento da rede completa.

Essa abordagem forneceu uma acurácia de 94,56% avaliando imagens radiográficas torácicas com duas classes, sendo elas: infectado por Covid-19 e não infectado por Covid-19.

Por fim, o estudo realizado por Hemdan; Shouman; Karar (2020), propôs um *framework* com múltiplas redes neurais consolidadas, como VGG19, DenseNet121, ResNetV2, entre outras. O objetivo principal por trás da criação deste *framework* é a concepção de uma ferramenta que consiga treinar e avaliar múltiplos modelos de rede neurais simultaneamente, a fim identificar qual modelo se torna mais performático sobre o conjunto de imagens analisadas. Os melhores resultados obtidos foram por meio do uso das redes VGG19 e DenseNet121, em que ambos obtiveram uma acurácia de 90,00% em conjunto de imagens composto por duas classes, sendo elas: Positivo para Covid e negativo para Covid.

3.3 Análise de Características

Como apresentado nas seções anteriores, vários estudos adotaram como a principal abordagem o uso de modelos de CNNs já conhecidos, ou então, optaram por criar modelos completamente novos e especializados para este tipo de classificação. Porém, foram poucos os estudos que optaram por realizar uma análise mais profunda das características das CNNs, fato esse que motivou o desenvolvimento deste projeto.

O estudo realizado por Tuncer; Dogan; Ozyurt (2020) teve como proposta a implementação de um método responsável por realizar a geração de *features* denominado como *Residual Exemplar Local Binary Pattern* (ResExLBP). As *features* obtidas foram ranqueadas via algoritmo Relief e classificadas com múltiplos classificadores, como SVM, árvores de decisão, entre outros. Essa proposta conquistou 100% de acurácia por meio do classificador SVM, avaliando imagens radiográficas da região do tórax separadas em duas classes: Covid-19 e *healthy*.

O estudo proposto por Rajpal et al. (2021) utilizou o modelo ResNet-50 com in-

tuito de extrair um subconjunto de características mais relevantes, considerando os 2048 atributos presentes na camada *avg_pool*. Os autores selecionaram e avaliaram manualmente um grupo de 252 *features*. Essas 252 *features* são então processadas pelo algoritmo *Principal Component Analysis* (PCA), que após o processamento, seleciona um novo subconjunto contendo apenas os 64 atributos mais importantes para o processo de classificação. Por fim, esse conjunto foi novamente reduzido após ser utilizado com entrada em uma rede *feed forward*, que selecionou apenas 16 características. O modelo forneceu uma acurácia de 94,40% para classificar um total de quatro classes, sendo elas: pneumonia viral; pneumonia bacteriana; COVID-19 e não infectado.

3.4 Considerações Sobre os Trabalhos Relacionados

Neste capítulo, foram apresentados estudos que desenvolveram técnicas baseadas em CNNs especializadas, CNNs consolidadas e por análise de características. Ca abordagem indicou resultados relevantes na análise de imagens radiográficas no contexto de Covid-19, sumarizados nas Tabelas 3.1, 3.2 e 3.3.

Tabela 3.1: Sumarização dos trabalhos correlatos, abordando a estratégia utilizada e as acurácias conquistadas em cada contexto de imagens radiográficas de COVID-19.

Referência	Abordagem	ACC
(KEDIA; ANJUM; KATARYA, 2021)	<i>CoVNet-19, Ensemble learning e Transfer learning</i>	99,71%
(ASHOUR et al., 2021)	<i>Bag of features e Ensemble</i>	98,60%
(DEB et al., 2022)	<i>Multi model ensemble architecture</i>	98,58%

Tabela 3.2: Sumarização dos trabalhos correlatos, abordando o uso de CNNs Consolidadas

Referência	Abordagem	ACC
(WALVEKAR et al., 2020)	<i>ResNet-50</i>	96,23%
(Shamila Ebenezer et al., 2022)	<i>EfficientNet-b0, image enchancement</i>	94,56%
(HEMDAN; SHOUMAN; KARAR, 2020)	<i>DenseNet-121, VGG19</i>	90,00%

Observando os resultados apontados previamente, a técnica que obteve os melhores resultados foi a de análise de características, descrita por Tuncer; Dogan; Ozyurt

Tabela 3.3: Sumarização dos trabalhos correlatos, abordando o uso de Análise de Características

Referência	Abordagem	ACC
(TUNCER; DOGAN; OZYURT, 2020)	<i>ResExLBP, RelieF, SVM</i>	<i>100%</i>
(RAJPAL et al., 2021)	<i>Handpicked features, ResNet-50</i>	<i>94,40%</i>

(2020). A acurácia foi de 100% com o algoritmo SVM. Uma nota é que esse tipo de abordagem permite definir modelos com um número reduzido de características, com resultados relevantes, e que podem contribuir com a compreensão do conjunto de imagens em questão. Os estudos que optaram por desenvolver CNNs especializadas obtiveram resultados igualmente satisfatórios, em especial, os resultados obtidos pela rede CovNet-19 (KEDIA; ANJUM; KATARYA, 2021), alcançando uma acurácia 99,71%. Por fim, mas não menos importante, os estudos que optaram explorar diretamente as CNNs consolidadas, indicaram resultados inferiores em comparação aos outros modelos. Nesse caso, o melhor resultado foi conquistado via ResNet-50 (RAJPAL et al., 2021), uma acurácia de 96,23%.

Capítulo 4

Metodologia


Neste capítulo são apresentadas informações detalhadas sobre os métodos e estratégias que embasaram este projeto, tais como detalhes sobre os modelos de CNNs utilizados, composição dos vetores de *deep learned features*, processo para a ranqueamento dos atributos mais relevantes, classificadores e métricas utilizadas para avaliar os resultados obtidos.

4.1 Estruturação do Método: Visão Geral

O método proposto foi estruturado em três etapas. A primeira etapa consiste na definição do processo de extração de *deep learned features* e contexto de aplicação, contemplando descrições sobre os modelos de Redes Neurais Convolucionais utilizados para explorar imagens radiográficas de COVID-19, bem como as indicações das camadas com os números de atributos correspondentes. A segunda etapa apresenta o processo proposto para a composição e seleção dos atributos mais relevantes para a distinção de imagens radiográficas de COVID-19. A terceira etapa apresenta o processo de análise dos atributos por meio de dois experimentos. Um experimento foi realizado para definir predições a partir de classificadores aplicados individualmente em cada conjunto de *deep learned features*. Outro experimento envolveu um processo

de combinação das predições, por meio de um *ensemble* de classificadores. A Figura 4.1 apresenta um diagrama esquemático do método proposto, e os detalhes de cada fase estão nas seções seguintes.

Figura 4.1: Diagrama esquemático do método proposto.



Fonte: Elaborada pelo autor.

4.2 Etapa 1: Definição do processo de extração de *deep learned features* e contexto de aplicação

As imagens de COVID-19 foram analisadas por meio de três modelos de aprendizado profundo. As arquiteturas escolhidas foram a *Residual Neural Network* com 50 camadas (ResNet-50), *Dense Convolutional Neural Network* com 201 camadas (DenseNet-201) e *EfficientNet baseline* (EfficientNet-b0). A descrição dos modelos utilizados estão nas seções 2.2.1, 2.2.2 e 2.2.3, respectivamente.

4.2.1 Camadas selecionadas para análise

Neste projeto, os atributos foram coletados a partir das redes ResNet-50, DenseNet-201 e EfficientNet-b0 pré-treinadas na base ImageNet (DENG et al., 2009). A estratégia utilizada neste projeto considerou definições indicadas no estudo apresentado por Santos; Ponti (2019), em que os descritores convolucionais das camadas iniciais da rede conseguiram fornecer informações locais da imagem sob análise, tais como baixos níveis de formas, bordas e cores. Já os descritores fornecidos pelas últimas camadas tendem a fornecer descritores globais. Dessa forma, os atributos convolucionais fornecidos pelas redes foram isolados por meio de uma estratégia que permite armazenar as saídas das camadas em estruturas de dados auxiliares. Os valores armazenados nessas estruturas foram utilizados como entrada para o método de seleção de atributos, capaz de identificar os subconjuntos mais relevantes e generalizáveis. Neste estudo, a camada *avg_pool* de cada rede foi selecionada para a análise, por conter possíveis contribuições de informações locais e globais das imagens. Na Tabela 4.1 são indicados os totais de características presentes em cada camada para cada uma das redes.

Tabela 4.1: Número de características da camada *avg_pool* das redes analisadas

Rede	Nº de características
ResNet-50	2048
DenseNet-201	1920
EfficientNet-b0	1280

4.2.2 Base de Dados


A proposta apresentada neste projeto explorou as imagens radiográficas de COVID-19 fornecida por uma base pública (COHEN et al., 2020). Essa base é composta por imagens coletadas de diversas fontes públicas, e não infringe a confidencialidade dos pacientes. As fontes utilizadas pelos autores foram os *websites*:

- *Radiopaedia* (<<https://radiopaedia.org>>)
- *The Italian Society of Medical and Interventional Radiology* (<<https://sirm.org/la-radiologia-medica/>>)
- *Figure1* (<<https://figure1.com>>)

É importante destacar que esta base é considerada dinâmica, portando, a quantidade de amostras presentes em cada classe, assim como os tipos de imagens, são atualizadas constantemente. A versão utilizada neste estudo foi obtida em 2020, compondo um total de 2040 imagens divididas em duas classes: saudável com 1602 amostras e COVID-19 com 438 exemplos. Vale ressaltar que as amostras pertencentes a classe "saudável" são de pessoas que foram devidamente testadas como não portadoras da COVID-19.

As imagens são representativas de regiões segmentadas, em que é possível observar apenas os pulmões do paciente. É importante destacar que as imagens possuem tamanhos variados, portanto, durante a etapa de treinamento das camadas *fully connected* dos modelos analisados, essas imagens foram redimensionadas para um tamanho de 224 *pixels* de altura e 224 *pixels* de largura. A Figura 4.2 ilustra alguns exemplos das imagens radiográficas presentes na base.

Figura 4.2: Exemplos de imagens de COVID-19 de uma base pública (COHEN et al., 2020)



Fonte: Elaborado pelo autor.

4.3 Etapa 2: Composição e seleção dos conjuntos de *deep learned features*

Os atributos convolucionais obtidos a partir da etapa 1 foram utilizados na etapa 2 a fim de classificar as imagens radiográficas de COVID-19. Para tanto, as camadas ilustradas na Tabela 4.1 foram representadas por matrizes n -dimensionais nomeadas $M_i[\dots]$, em que i representa uma das camadas que está sob investigação. Cada coluna presente em uma matriz M_i foi organizada sequencialmente em um vetor de atributos $V_i[\dots]$, em que o número de elementos em M_i é igual ao número de elementos V_i . É importante destacar que a ordem das *deep features* presentes em cada matriz M_i foi preservada, viabilizando a reconstrução de cada matriz por meio dos valores de cada V_i e da dimensão correspondente de M_i . Após a construção dos vetores V_i , foi utilizada uma estratégia para selecionar as *deep features* mais relevantes. Para isso, o algoritmo Relief (KIRA; RENDELL, 1992a) foi utilizado para realizar o processo de ranqueamento das características presentes em V_i , a fim de, posteriormente, identificar a melhor combinação dentre os descritores disponíveis em cada subconjunto. Foi considerado um ponto de corte com os 250 atributos mais bem ranqueados em cada composição (RIBEIRO et al., 2019). De forma geral, cada conjunto V_i foi distribuído

em subconjuntos S em função de m , em que m é o número de *deep features* em cada subconjunto, conforme indicado pela Equação 4.1. O número limitado a 250 *deep features* foi estabelecido para obter soluções com um número reduzido de atributos, além de minimizar a presença de *overfitting*. Dessa forma, cada subconjunto S_m foi definido a partir dos m elementos melhor ranqueados em cada V_i . A proposta desse projeto consiste em um processo iterativa a fim de definir a camada e as *deep features* correspondentes mais relevantes.

$$m \in \{10 \leq m \leq 250, \frac{m}{10} \in \mathbb{N}\}. \quad (4.1)$$

4.4 Etapa 3: Análises e extração de conhecimento

Esta etapa foi realizada a partir de dois tipos de experimentos. Um experimento teve o objetivo de investigar a capacidade discriminativa dos vetores de *deep learned features* por meio de diferentes classificadores, de diferentes categorias, aplicados individualmente. Os classificadores utilizados foram: baseados em função (Seção 2.5.1), com o SVM e SMO; baseados em *lazy learning* (Seção 2.5.2), com o LWL e IBk; baseados em árvores de decisão (Seção 2.5.3), RaF e RaT (DUDA; HART; STORK, 2012). O objetivo dessa análise foi obter modelos capazes de fornecer os melhores desempenhos, com o menor número de atributos e favorecer o entendimento do contexto explorado. Os desempenhos dos classificadores foram posteriormente analisados individualmente, buscando destacar a combinação que forneceu os melhores resultados. Vale ressaltar que cada classificador analisou as 250 *deep learned features* em conjuntos organizados a cada dez atributos.

O segundo experimento foi realizado com o intuito de completar as análises indicadas previamente nessa seção. Esse experimento foi direcionado para verificar o poder discriminativo de cada conjunto de *deep learned features* por meio de um processo de combinação de predições. Para isso, foi realizado um *ensemble* dos classificadores uti-

lizados no primeiro experimento por meio do uso da abordagem de fusão em nível de pontuação. Esse tipo de análise, permite explorar os pontos fortes dos classificadores utilizados (LUMINI; NANNI, 2017). De forma análoga ao primeiro experimento, as 250 *deep features* foram analisadas em conjuntos organizados a cada dez descritores.

Por fim, para garantir a significância dos resultados obtidos por cada um dos experimentos, uma série de métricas foram utilizadas para avaliar o desempenho dos resultados obtidos. As métricas utilizadas foram: Acurácia, medida-F, curva ROC e AUC.

4.5 Ferramentas e Ambiente de Desenvolvimento

Tanto o algoritmo responsável pela obtenção dos vetores de *deep learned features*, quanto os algoritmos para a exploração dos modelos ResNet, DenseNet e EfficientNet, foram desenvolvidos utilizando a linguagem *Python*. Em especial, para a exploração dos modelos, foi utilizado o *framework Pytorch* (PYTORCH, 2022), que possui os modelos ResNet-50 (PYTORCH..., a), DenseNet-201 (PYTORCH..., b) e EfficientNet-b0 (PYTORCH..., c) previamente codificados e treinados na base *ImageNet*. Vale ressaltar que todos os modelos fornecidos pelo *Pytorch* foram minimamente modificados para atender as especificações originais apresentadas pelos autores (HE et al., 2016; HUANG et al., 2016; TAN; LE, 2020).

Para realizar os testes de desempenho com a rede completa, o *framework Pytorch Ignite* (PYTORCH...,) também foi utilizado, sendo ele responsável por realizar o treinamento da última camada *fully connected* dos modelos analisados, além de auxiliar na obtenção das métricas de desempenho utilizadas por este estudo. Vale ressaltar que os parâmetros de treinamento para a camada *fully connected* de cada modelo foram padronizados seguindo as especificações apresentadas por (HE et al., 2016), essa etapa é importante para manter a consistência dos resultados entre os modelos.

A execução da proposta foi realizada em um notebook com processador Intel Core

i5-10210U de 2.11GHz, 16 GB de memória RAM (Com 15.8 GB usáveis pelo sistema), placa de vídeo NVIDIA MX 110 e sistema operacional Windows 11.

Por fim, foi utilizado o pacote de software Weka 3 (WEKA..., a) para a realizar a classificação dos vetores de *deep learned features*, além da obtenção de todas as métricas utilizadas por este estudo.

Capítulo 5


Resultados

Neste capítulo, os resultados conquistados estão descritos a partir do estudo desenvolvido no contexto de imagens radiográficas pulmonares de COVID-19. Os destaques são as informações sobre os desempenhos obtidos com as diferentes composições de vetores de *deep learned features*, combinando a estratégia de associação de classificadores (*ensemble* e aplicados individualmente). Por fim, o melhor resultado é então comparado ao fornecido pela aplicação direta do modelo CNN e algumas informações são apresentadas para fornecer uma visão geral sobre a relevância do resultado.

5.1 Principais combinações entre vetores de deep learned features e estratégias de classificação

A partir da aplicação da metodologia proposta no Capítulo 4, foram realizados dois experimentos utilizando as *deep learned features*, camada *avg_pool*, dos modelos ResNet-50, DenseNet-201 e EfficientNet-b0. Dessa forma, considerando a acurácia como métrica, na Figura 5.1 estão ilustrados os resultados conquistados com a aplicação do *ensemble* de classificadores.

Figura 5.1: Valores de acurácias (%) em função dos vetores com dimensões de 10 a 250 *deep learned features* por *transfer learning* e um *ensemble* de classificadores, considerando a camada avg_pool da ReseNet-50, DenseNet-201 e EfficientNet-b0.




Fonte: Elaborado pelo autor.

Observando os resultados obtidos a partir das diferentes composições de *deep learned features* em um *ensemble* de classificadores, nota-se que o modelo DenseNet-201 foi o que apresentou o melhor resultado neste experimento, em que, com um conjunto de 210 *deep learned features*, foi observada uma acurácia de 97,89%. Neste caso, a medida-F foi de 0,979, com uma AUC de 0,9941. Esses resultados são interessantes e indicam uma importante contribuição da metodologia proposta, visto que foi possível identificar uma combinação de técnicas capaz de fornecer uma solução aceitável com apenas 10,94% do conjunto inicial de descritores, evitando a presença de modelo com *overfitting*. Por fim, é válido ressaltar o desempenho expresso via métrica AUC (0,9941), indicando que esta combinação possui uma capacidade de distinção muito próxima ao ideal.

O segundo experimento foi realizado com uma combinação de *deep learned features* com os classificadores do *ensemble* aplicados separadamente: SVM; SMO;

LWL; IBK; RaF; e RaT. Considerando a acurácia como métrica para indicar o poder discriminativo de cada associação (*deep learned features*, nas Figuras 5.2, 5.3 e 5.4 são ilustrados os desempenhos obtidos para os modelos ResNet-50, DenseNet-201 e EfficientNet-b0, respectivamente.


Figura 5.2: Valores de acurácias (%) em função de diferentes composições de vetores de *deep learned features* por *transfer learning* e classificadores, explorando a camada *avg_pool* da rede ResNet-50



Fonte: Elaborado pelo autor.


Analisando os resultados apresentados na Figura 5.2, referente ao modelo ResNet-50, a combinação do classificador SMO com 200 *deep learned features* foi a que apresentou o melhor resultado para este modelo, fornecendo uma acurácia de 94,17%, medida-F de 0,9410 e 0,9056 de AUC. Em relação ao exposto na Figura 5.3, modelo DenseNet-201, a combinação do classificador SMO com 210 *features* foi a que apresentou o melhor resultado entre todos os testes realizados, com uma acurácia de 98,38%, medida-F de 0,984 e AUC de 0,9814. Por fim, mas não menos importante, na Figura 5.4 (modelo EfficientNet-b0), a melhor combinação também foi com o classificador SMO, mas neste caso, usou um número menor de atributos (150 *features*). A

Figura 5.3: Valores de acurácias (%) em função de diferentes composições de vetores de *deep learned features* por *transfer learning* e classificadores, explorando a camada *avg_pool* da rede DenseNet-201



Fonte: Elaborado pelo autor.

Figura 5.4: Valores de acurácias (%) em função de diferentes composições de vetores de *deep learned features* por *transfer learning* e classificadores, explorando a camada *avg_pool* da rede EfficientNet-b0



Fonte: Elaborado pelo autor.

acurácia foi de 97,16%, medida-F de 0,972 e AUC de 0,9603. Uma nota importante é que o classificador SMO esteve presente no melhor resultado em cada categoria de *deep learned features*: ResNet-50; DenseNet-201; EfficientNet-b0. Este fato indicou um comportamento padrão no quesito classificador.

Para complementar esse processo de análise dos resultados, na Tabela 5.1 é apresentado um resumo contendo os cinco melhores resultados dentro todos os testes realizados.

Tabela 5.1: Resumo das cinco melhores associações de técnicas para a classificação de imagens radiográficas de COVID-19, com as indicações das métricas de acurácia, medida-F e AUC.

Posição	Modelo	Total de Features	Classificador	ACC	medida-F	AUC
1°	DenseNet-201	210	SMO	98,38%	0,984	0,9814
2°	DenseNet-201	210	Ensemble	97,89%	0,979	0,9941
3°	ResNet-50	200	Ensemble	97,70%	0,977	0,9932
4°	ResNet-50	200	SMO	97,65%	0,977	0,9684
5°	EfficientNet-b0	250	Ensemble	97,59%	0,970	0,9882


Da Tabela 5.1, observa-se que na primeira posição está uma solução via classificador aplicado individualmente. Entretanto, a estratégia de *ensemble* aparece em três das cinco melhores combinações observadas neste estudo. Nas duas primeiras posições, as soluções foram conquistadas com o mesmo conjunto de atributos: 210 *deep learned features*. Também, em termos de acurácia, a diferença é menos de 1% entre essas duas soluções. A segunda melhor combinação se destaca pela taxa de AUC (0,9941), superando o resultado obtido via melhor combinação individual, com a vantagem de se utilizar um *ensemble* de classificadores.

5.2 Discussão sobre os resultados obtidos

Para contextualizar outras contribuições deste estudo, o melhor resultado, segundo a métrica acurácia (Tabela 5.1), foi observado frente aos melhores resultados das redes ResNet-50, DenseNet-201 e EfficientNet-b0, todas aplicadas diretamente para

classificar os mesmos conjuntos de imagens. Vale ressaltar que as redes utilizadas nessa verificação foram pré-treinadas na base ImageNet e, para isso, foi necessário realizar o treinamento da última camada *fully connected* de cada rede, a fim de contemplar o número de classes sob análise (Saudável e COVID-19). O treinamento da última camada *fully connected* foi realizado com um total de 50 *epochs* seguindo as especificações apresentadas por (HE et al., 2016). As métricas de desempenho coletadas a partir da rede completa foram: acurácia, medida-F e *loss*. Na Figura 5.5 estão os desempenhos desses experimentos com os valores de acurácia em relação a cada *epoch*. O melhor resultado foi via rede DenseNet-201, *epoch* 33, com uma acurácia de 96,57%, *loss* de 0,12 e medida-F de 0,94. Entretanto, esse desempenho é menor que os fornecidos pelas combinações aqui desenvolvidas, sumarizadas na Tabela 5.1, informação essa que fundamenta outra importante contribuição deste trabalho.

Figura 5.5: Valores de acurácias (%) obtidos com a aplicação das redes ResNet-50, DenseNet-201 e EfficientNet-b0, explorando classificações com até 50 *epochs*.



Fonte: Elaborado pelo autor.

Por fim, a relevância do melhor resultado também foi observada em relação aos trabalhos relacionados (Capítulo 3). Vale ressaltar que as técnicas utilizadas pelos trabalhos correlatos utilizaram bases de imagens diferentes da que foi utilizada neste

projeto, além de estratégias de comparações distintas. Esses fatos não permitem uma comparação direta entre as abordagens, mas possibilita uma visão ilustrativa de enquadramento do modelo a partir de alguns trabalhos importantes nesta área. Na Tabela 5.2 estão detalhados alguns resultados dessa visão geral.

Tabela 5.2: Visão ilustrativa de trabalhos correlatos direcionados para a classificação de imagens radiográficas pulmonares de COVID-19.

Referência	Abordagem	ACC	Medida-F
(TUNCER; DOGAN; OZYURT, 2020)	<i>ResExLBP, Relief, SVM</i>	100%	-
(KEDIA; ANJUM; KATARYA, 2021)	<i>CoVNet-19, Ensemble learning e Transfer learning</i>	99,71%	0,99
(ASHOUR et al., 2021)	<i>Bag of features e Ensemble</i>	98,60%	0,98
(DEB et al., 2022)	<i>Multi model ensemble architecture</i>	98,58%	0,95
Proposto	<i>Transfer learning, DenseNet-201, Relief e SMO</i>	98,38%	0,98
(WALVEKAR et al., 2020)	<i>ResNet-50</i>	96,23%	0,96
(Shamila Ebenezer et al., 2022)	<i>EfficientNet-b0, image enhancement</i>	94,56%	0,93
(RAJPAL et al., 2021)	<i>Handpicked features, ResNet-50</i>	94,40%	0,97
(HEMDAN; SHOUMAN; KARAR, 2020)	<i>DenseNet-121, VGG19</i>	90,00%	0,90

Observando a Tabela 5.2, percebe-se que a principal combinação aqui proposta conseguiu obter resultados dentre os principais trabalhos disponíveis na literatura. Mesmo que o resultado obtido seja menos expressivo que os apresentados em alguns métodos (TUNCER; DOGAN; OZYURT, 2020; KEDIA; ANJUM; KATARYA, 2021; ASHOUR et al., 2021; DEB et al., 2022), a vantagem da metodologia proposta é a apresentação de uma solução capaz de obter bons resultados por meio do uso de um conjunto reduzido de atributos, simplificando a definição de cada modelo e tornando o conhecimento mais compreensível aos especialistas que atuam nesta área.

Capítulo 6

Conclusões

Neste trabalho, foi proposto um estudo detalhado das *deep learned features* por *transfer learning*, via camada *avg_poll* presente nos modelos de redes ResNet-50, DenseNet-201 e EfficientNet-b0. Os experimentos permitiram analisar e identificar as melhores combinações, inclusive conhecer o melhor conjunto de *deep learned features* para o processo de classificação e reconhecimento de padrões de imagens de COVID-19. O conjunto reduzido de atributos foi obtido com o uso de uma estratégia fundamentada no algoritmo *ReliefF*, com a utilização de vários classificadores e de um *ensemble* destes. Esse tipo de combinação e as informações coletadas a partir dos nossos experimentos são contribuições importantes deste estudo. Por exemplo, as duas principais combinações foram obtidas da DenseNet-201, envolvendo o mesmo conjunto de atributos: 210 *deep learned features*. Este total de atributos representa apenas 10,94% da quantidade inicial de descritores. No teste com o classificador aplicado individualmente, o algoritmo SMO foi o responsável por fornecer o melhor resultado, uma acurácia de 98,38%. No teste com o *ensemble* de classificadores, o resultando foi uma acurácia de 97,89%. Estes desempenhos são praticamente similares.

Quando algumas comparações foram verificadas em relação ao uso completo das arquiteturas, notamos que as soluções obtidas com nosso estudo superaram os desempenhos fornecidos pelas redes no mesmo conjunto de imagens, confirmando a impor-

tância da nossa proposta. Por fim, no que tange a visão ilustrativa em relação aos trabalhos correlatos, o estudo aqui apresentado conseguiu fornecer modelos com desempenhos dentre os disponíveis na literatura, contribuindo com informações e uma combinação explorando um número reduzido de atributos apreendidos por *transfer learning*. Portanto, acreditamos que essas informações são relevantes para os especialistas interessados na investigação de técnicas direcionadas para o processo de classificação de imagens de COVID-19.

Para trabalhos futuros, pretende-se explorar diferentes arquiteturas de redes convolucionais e realizar o uso combinado com descritores fundamentados em técnicas fractais, além da elaboração de técnicas para destacar os atributos mais bem ranqueados nos mapas de ativação (*class activation mapping*).

6.0.1 Divulgação e Apresentação

Miguel, P. L; Neves, L. A. Investigação de Deep Learned Features via Residual Neural Network: Um Estudo Aplicado em Imagens de COVID-19, XXXIII Congresso de Iniciação Científica da Unesp (2021).

Referências

AFFONSO, C.; ROSSI, A. L. D.; VIEIRA, F. H. A.; FERREIRA, A. C. P. de L. et al. Deep learning for biological image classification. *Expert Systems with Applications*, Elsevier, v. 85, p. 114–122, 2017.

AHA, D.; KIBLER, D. Instance-based learning algorithms. *Machine Learning*, v. 6, p. 37–66, 1991.

AHA, D. W. Lazy learning. In: _____. *Lazy Learning*. USA: Kluwer Academic Publishers, 1997. p. 7–10. ISBN 0792345843.

ALI, K.; SHAIKH, Z. A.; KHAN, A. A.; LAGHARI, A. A. Multiclass skin cancer classification using efficientnets – a first step towards preventing skin cancer. *Neuroscience Informatics*, v. 2, n. 4, p. 100034, 2022. ISSN 2772-5286. Artificial Intelligence in Brain Informatics. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2772528621000340>>.

ASHOUR, A. S.; EISSA, M. M.; WAHBA, M. A.; ELSAWY, R. A.; ELGNAINY, H. F.; TOLBA, M. S.; MOHAMED, W. S. Ensemble-based bag of features for automated classification of normal and covid-19 cxr images. *Biomedical Signal Processing and Control*, v. 68, p. 102656, 2021. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809421002536>>.

ATKESON, C.; MOORE, A.; SCHAAAL, S. Locally weighted learning. *AI Review*, 1996.

Bhanu Mahesh, D.; Satyanarayana Murty, G.; Rajya Lakshmi, D. Optimized local weber and gradient pattern-based medical image retrieval and optimized convolutional neural network-based classification. *Biomedical Signal Processing and Control*, v. 70, p. 102971, 2021. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809421005681>>.

BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001.

CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. *Computers & Electrical Engineering*, Elsevier, v. 40, n. 1, p. 16–28, 2014.

CHAUHAN, T.; PALIVELA, H.; TIWARI, S. Optimization and fine-tuning of den-net model for classification of covid-19 cases in medical imaging. *International Journal of Information Management Data Insights*, v. 1, n. 2, p. 100020, 2021.

ISSN 2667-0968. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2667096821000136>>.

CHOI, J.; CHO, S.; CHUNG, J. W.; KIM, N. Video recognition of simple mastoidectomy using convolutional neural networks: Detection and segmentation of surgical tools and anatomical regions. *Computer Methods and Programs in Biomedicine*, v. 208, p. 106251, 2021. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260721003254>>.

COHEN, J. P.; MORRISON, P.; DAO, L. Covid-19 image data collection. *arXiv 2003.11597*, 2020. Disponível em: <<https://github.com/ieee8023/covid-chestxray-dataset>>.

COHEN, J. P.; MORRISON, P.; DAO, L.; ROTH, K.; DUONG, T. Q.; GHASSEMI, M. Covid-19 image data collection: Prospective predictions are the future. *arXiv 2006.11988*, 2020. Disponível em: <<https://github.com/ieee8023/covid-chestxray-dataset>>.

DASH, M.; LIU, H. Feature selection for classification. *Intelligent data analysis*, IOS Press, v. 1, n. 3, p. 131–156, 1997.

DEB, S. D.; JHA, R. K.; JHA, K.; TRIPATHI, P. S. A multi model ensemble based deep convolution neural network structure for detection of covid19. *Biomedical Signal Processing and Control*, v. 71, p. 103126, 2022. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809421007230>>.

DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. In: IEEE. *2009 IEEE conference on computer vision and pattern recognition*. [S.l.], 2009. p. 248–255.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. [S.l.]: John Wiley & Sons, 2012.

ELGENDY, M. *Advanced CNN Architectures*. 2020. <<https://livebook.manning.com/book/grokking-deep-learning-for-computer-vision/chapter-5/v-3/34>>. Online; acesso: 30-10-2020.

FAWCETT, F. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006.

FLAKE, G. W.; LAWRENCE, S. Efficient svm regression training with smo. *Machine Learning*, v. 46, n. 1, p. 271–290, Jan 2002. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1023/A:1012474916001>>.

FRANK, E.; HALL, M.; PFAHRINGER, B. Locally weighted naive bayes. In: *19th Conference in Uncertainty in Artificial Intelligence*. [S.l.]: Morgan Kaufmann, 2003. p. 249–256.

- GHOLAMALINEZHAD, H.; KHOSRAVI, H. Pooling methods in deep neural networks, a review. *CoRR*, abs/2009.07485, 2020. Disponível em: <https://arxiv.org/abs/2009.07485>.
- GNANA, D. A. A.; BALAMURUGAN, S. A. A.; LEAVLINE, E. J. Literature review on feature selection methods for high-dimensional data. *Int. J. Comput. Appl.*, v. 136, n. 1, p. 9, 2016.
- GONZALEZ, R.; WOODS, R. *Digital Image Processing*. Pearson, 2018. ISBN 9780133356724. Disponível em: <https://books.google.com.br/books?id=0F05vgAACAAJ>.
- GREENSPAN, H.; GINNEKEN, B. V.; SUMMERS, R. M. Eguest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique. *IEEE Transactions on Medical Imaging*, v. 35, n. 5, p. 1153—1159, 2016.
- GUYON, I.; GUNN, S.; NIKRAVESH, M.; ZADEH, L. A. *Feature extraction: foundations and applications*. [S.l.]: Springer, 2008. v. 207.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.
- HEMDAN, E. E.-D.; SHOUMAN, M. A.; KARAR, M. E. *COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images*. 2020.
- HINTON, G. E. Learning multiple layers of representation. *Trends in Cognitive Sciences*, v. 11, n. 10, p. 428–434, 2007. ISSN 1364-6613. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364661307002173>.
- HOCHREITER, S. The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty Fuzziness and Knowledge-Based Systems*, p. 107–116, 1998.
- HUANG, G.; LIU, Z.; MAATEN, L. van der; WEINBERGER, K. Q. Densely connected convolutional networks. *arXiv*, 2016. Disponível em: <https://arxiv.org/abs/1608.06993>.
- IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*, 2015.
- JAIN, A.; MAO, J.; MOHIUDDIN, K. Artificial neural networks: A tutorial. *Computer*, v. 29, n. 3, p. 31–44, 1996.
- KAMALOV, F.; RAJAB, K.; CHERUKURI, A. K.; ELNAGAR, A.; SAFARALIEV, M. Deep learning for covid-19 forecasting: State-of-the-art review. *Neurocomputing*, v. 511, p. 142–154, 2022. ISSN 0925-2312. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0925231222010918>.

KARLIK, B.; OLGAC, A. V. Performance analysis of various activation functions in generalized mlp architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, v. 1, n. 4, p. 111–122, 2011.

KEDIA, P.; ANJUM; KATARYA, R. Covnet-19: A deep learning model for the detection and analysis of covid-19 patients. *Applied Soft Computing*, v. 104, p. 107184, 2021. ISSN 1568-4946. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494621001071>.

KIRA, K.; RENDELL, L. The feature selection problem: Traditional methods and a new algorithm. In: *AAAI*. [S.l.: s.n.], 1992.

KIRA, K.; RENDELL, L. A. A practical approach to feature selection. In: *Machine Learning Proceedings 1992*. [S.l.]: Elsevier, 1992. p. 249–256.

KONG, L.; CHENG, J. Classification and detection of covid-19 x-ray images based on densenet and vgg16 feature fusion. *Biomedical Signal Processing and Control*, v. 77, p. 103772, 2022. ISSN 1746-8094. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809422002944>.

KONONENKO, I. Estimating attributes: Analysis and extensions of relief. In: BERGADANO, F.; RAEDT, L. D. (Ed.). *Machine Learning: ECML-94*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1994. p. 171–182. ISBN 978-3-540-48365-6.

KONONENKO, I.; ŠIMEC, E.; ROBNIK-ŠIKONJA, M. Overcoming the myopia of inductive learning algorithms with relief. *Applied Intelligence*, Springer, v. 7, n. 1, p. 39–55, 1997.

KRIZHEVSKY I. SUTSKEVER, G. E. H. A. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, p. 1097–1105, 2012.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436, 2015.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Ieee, v. 86, n. 11, p. 2278–2324, 1998.

LIASHCHYNSKYI, P.; LIASHCHYNSKYI, P. *Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS*. arXiv, 2019. Disponível em: <https://arxiv.org/abs/1912.06059>.

LUMINI, A.; NANNI, L. Overview of the combination of biometric matchers. *Information Fusion*, Elsevier, v. 33, p. 71–85, 2017.

MA, Y.; KLABJAN, D. Convergence analysis of batch normalization for deep neural nets. *arXiv preprint arXiv:1705.08011*, 2017.

MIDDYA, A. I.; ROY, S. Spatio-temporal variation of covid-19 health outcomes in india using deep learning based models. *Technological Forecasting and Social Change*, v. 183, p. 121911, 2022. ISSN 0040-1625. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0040162522004334>>.

MINISTÉRIO da Saúde, “Coronavirus (covid-19)”. 2020. <<https://coronavirus.saude.gov.br/sobre-a-doenca>>. Acesso em: 15-05-2020.

NAMATÊVS, I. Deep convolutional neural networks: Structure, feature extraction and training. *Information Technology and Management Science*, Sciendo, v. 20, n. 1, p. 40–47, 2017.

NANNI, L.; GHIDONI, S.; BRAHNAM, S.; LIU, S.; ZHANG, L. Ensemble of hand-crafted and deep learned features for cervical cell classification. *Deep Learners and Deep Learner Descriptors for Medical Applications*, Springer, p. 117—135, 2020.

OPEN Genus IQ. <<https://iq.opengenus.org/pooling-layers/>>. Acesso em: 16/07/2022.

OTÁLORA, S.; CRUZ-ROA, A.; AREVALO, J.; ATZORI, M.; MADABHUSHI, A.; JUDKINS, A. R.; GONZÁLEZ, F.; MÜLLER, H.; DEPEURSINGE, A. Combining unsupervised feature learning and riesz wavelets for histopathology image representation: Application to identifying anaplastic medulloblastom. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, p. 581—588, 2015.

PATEL, H.; PRAJAPATI, P. Study and analysis of decision tree based classification algorithms. *International Journal of Computer Sciences and Engineering*, v. 6, p. 74–78, 10 2018.

PEDRINI, H.; SCHWARTZ, W. R. *Análise de imagens digitais: Princípios, algoritmos e aplicações*. 1. ed. [S.l.]: Cengage, 2008. v. 1.

PLATT, J. Fast training of support vector machines using sequential minimal optimization. In: SCHOELKOPF, B.; BURGESS, C.; SMOLA, A. (Ed.). *Advances in Kernel Methods - Support Vector Learning*. MIT Press, 1998. Disponível em: <<http://research.microsoft.com/~jplatt/smo.html>>.

PSALTIS, D.; SIDERIS, A.; YAMAMURA, A. A. A multilayered neural network controller. *IEEE control systems magazine*, IEEE, v. 8, n. 2, p. 17–21, 1988.

PYTORCH. *Pytorch*. 2022. Acesso em: 22-07-2022. Disponível em: <<https://pytorch.org/>>.

PYTORCH Ignite. <<https://pytorch.org/ignite/index.html>>. Acesso em: 23-07-2022.

PYTORCH Resnet 50. <https://pytorch.org/hub/pytorch_vision_resnet/>. Acesso em: 22-07-2022.

PYTORCH Resnet 50. <https://pytorch.org/hub/pytorch_vision_densenet/>. Acesso em: 22-07-2022.

PYTORCH Resnet 50. <https://pytorch.org/hub/nvidia_deeplearningexamples_efficientnet/>. Acesso em: 22-07-2022.

RAHMAN, M. F.; ZHUANG, Y.; TSENG, T.-L. B.; POKOJOVY, M.; MCCAFFREY, P.; WALSER, E.; MOEN, S.; VO, A. Improving lung region segmentation accuracy in chest x-ray images using a two-model deep learning ensemble approach. *Journal of Visual Communication and Image Representation*, v. 85, p. 103521, 2022. ISSN 1047-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1047320322000657>>.

RAJPAL, S.; LAKHYANI, N.; SINGH, A. K.; KOHLI, R.; KUMAR, N. Using handpicked features in conjunction with resnet-50 for improved detection of covid-19 from chest x-ray images. *Chaos, Solitons Fractals*, v. 145, p. 110749, 2021. ISSN 0960-0779. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960077921001028>>.

RIBEIRO, M. G.; NEVES, L. A.; NASCIMENTO, M. Z. d.; ROBERTO, G. F.; MARTINS, A. M.; TOSTA, T. A. A. Classification of colorectal cancer based on the association of multidimensional and multiresolution features. *Expert Systems With Applications*, Elsevier, v. 120, p. 262—278, 2019.

SANTOS, F. Pereira dos; PONTI, M. A. Alignment of local and global features from multiple layers of convolutional neural network for image classification. p. 241–248, 2019.

SARWINDA, D.; PARADISA, R. H.; BUSTAMAM, A.; ANGGIA, P. Deep learning in image classification using residual network (resnet) variants for detection of colorectal cancer. *Procedia Computer Science*, v. 179, p. 423–431, 2021. ISSN 1877-0509. 5th International Conference on Computer Science and Computational Intelligence 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050921000284>>.

Shamila Ebenezer, A.; Deepa Kanmani, S.; SIVAKUMAR, M.; Jeba Priya, S. Effect of image transformation on efficientnet model for covid-19 ct image classification. *Materials Today: Proceedings*, v. 51, p. 2512–2519, 2022. ISSN 2214-7853. International Conference on Advances in Materials Science. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785321078469>>.

SHARMA, S. Activation functions in neural networks. *Towards Data Science*, v. 6, 2017.

SHEHAB, L. H.; FAHMY, O. M.; GASSER, S. M.; EL-MAHALLAWY, M. S. An efficient brain tumor image segmentation based on deep residual networks (resnets). *Journal of King Saud University - Engineering Sciences*, v. 33, n. 6, p. 404–412, 2021. ISSN 1018-3639. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1018363920302506>>.

SONG, Y.; REN, S.; LU, Y.; FU, X.; WONG, K. K. Deep learning-based automatic segmentation of images in cardiac radiography: A promising challenge. *Computer Methods and Programs in Biomedicine*, v. 220, p. 106821, 2022. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260722002036>>.

SU, H.; ZHAO, D.; ELMANNAI, H.; HEIDARI, A. A.; BOUROUIS, S.; WU, Z.; CAI, Z.; GUI, W.; CHEN, M. Multilevel threshold image segmentation for covid-19 chest radiography: A framework using horizontal and vertical multiverse optimization. *Computers in Biology and Medicine*, v. 146, p. 105618, 2022. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482522004103>>.

SUGENO, A.; ISHIKAWA, Y.; OHSHIMA, T.; MURAMATSU, R. Simple methods for the lesion detection and severity grading of diabetic retinopathy by image processing and transfer learning. *Computers in Biology and Medicine*, v. 137, p. 104795, 2021. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482521005898>>.

TAN, M.; LE, Q. V. Efficientnet: Rethinking model scaling for convolutional neural networks. 2020.

TUNCER, T.; DOGAN, S.; OZYURT, F. An automated residual exemplar local binary pattern and iterative relief based covid-19 detection method using chest x-ray image. *Chemometrics and Intelligent Laboratory Systems*, v. 203, p. 104054, 2020. ISSN 0169-7439. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169743920301970>>.

URBANIAK, I.; WOLTER, M. Quality assessment of compressed and resized medical images based on pattern recognition using a convolutional neural network. *Communications in Nonlinear Science and Numerical Simulation*, v. 95, p. 105582, 2021. ISSN 1007-5704. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1007570420304123>>.

VAPNIK, V. Pattern recognition using generalized portrait method. *Automation and remote control*, v. 24, p. 774–780, 1963.

VU, T. H.; MOUSAVI, H. S.; MONGA, V.; RAO, A. U. K.; RAO, G. Histopathological image classification using discriminative feature-oriented dictionary learning. *CoRR*, abs/1506.05032, 2015. Disponível em: <<http://arxiv.org/abs/1506.05032>>.

WALVEKAR; SANIKA; SHINDE; SWATI, D. Detection of covid-19 from ct images using resnet50. *2nd International Conference on Communication Information Processing*, 2020. Disponível em: <<https://ssrn.com/abstract=3648863>>.

WANG, K.; JIANG, P.; MENG, J.; JIANG, X. Attention-based densenet for pneumonia classification. *IRBM*, 2021. ISSN 1959-0318. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S195903182100141X>>.

WANG, S.-H.; ZHANG, Y.-D. Densenet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification. *ACM Trans. Multimedia Comput. Commun. Appl.*, Association for Computing Machinery, New York, NY, USA, v. 16, n. 2s, jun 2020. ISSN 1551-6857. Disponível em: <https://doi.org/10.1145/3341095>.

WANG, Y.; HARGREAVES, C. A. A review study of the deep learning techniques used for the classification of chest radiological images for covid-19 diagnosis. *International Journal of Information Management Data Insights*, v. 2, n. 2, p. 100100, 2022. ISSN 2667-0968. Disponível em: <https://www.sciencedirect.com/science/article/pii/S266709682200043X>.

WEKA 3: Machine Learning Software in Java. <https://www.cs.waikato.ac.nz/~ml/weka/>. Acesso em: 22-07-2022.

WEKA 3: RandomTree classifier. <https://weka.sourceforge.io/doc.dev/weka/classifiers/trees/RandomTree.html>.

XING, W.; HE, W.; LI, X.; CHEN, J.; CAO, Y.; ZHOU, W.; SHEN, Q.; ZHANG, X.; TA, D. Early severity prediction of bpd for premature infants from chest x-ray images using deep learning: A study at the 28th day of oxygen inhalation. *Computer Methods and Programs in Biomedicine*, v. 221, p. 106869, 2022. ISSN 0169-2607. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169260722002516>.

YU, X.; DONG, H. Ptl-cfs based deep convolutional neural network model for remote sensing classification. *Computing*, v. 100, n. 3, p. 773–785, 2018.

YUAN, G.-X.; HO, C.-H.; LIN, C.-J. Recent advances of large-scale linear classification. *Proceedings of the IEEE*, v. 100, n. 9, p. 2584–2603, 2012.

ZHOU, S. K.; GREENSPAN, H.; SHEN, D. *Deep learning for medical image analysis*. [S.l.]: Academic Press, 2017.

ZHUANG, F.; QI, Z.; DUAN, K.; XI, D.; ZHU, Y.; ZHU, H.; XIONG, H.; HE, Q. *A Comprehensive Survey on Transfer Learning*. arXiv, 2019. Disponível em: <https://arxiv.org/abs/1911.02685>.