



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

Thales Ricardo de Souza Lopes

Uso de Otimização Binária de Lobos
Cinza com Deep Learned Features para
Classificar Imagens Radiográficas de
COVID-19

São José do Rio Preto
2023

Thales Ricardo de Souza Lopes

Uso de Otimização Binária de Lobos Cinza com Deep Learned Features para Classificar Imagens Radiográficas 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
2023**

L864u

Lopes, Thales Ricardo de Souza

Uso de otimização binária de lobos cinza com deep learned features para classificar imagens radiográficas de covid-19 / Thales Ricardo de Souza Lopes. -- São José do Rio Preto, 2023

72 p. : il., tabs.

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. Aprendizado do computador. 3. COVID-19 (Doença). 4. Processamento de imagens. 5. Inteligência artificial Aplicações médicas. 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.

Thales Ricardo de Souza Lopes

Uso de Otimização Binária de Lobos Cinza com Deep Learned Features para Classificar Imagens Radiográficas 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. Geraldo Francisco Donega Zafalon

UNESP – Câmpus de São José do Rio Preto

Prof. Dr. Leandro Alves Neves

UNESP – Câmpus de São José do Rio Preto

Orientador

Prof. Dr. Rodrigo Capobianco Guido

UNESP – Câmpus de São José do Rio Preto

**São José do Rio Preto
29 de Novembro de 2023**

Dedico esse trabalho a toda minha família, especialmente a minha mãe que foi a pessoa que mais me apoiou e me deu forças para chegar até aqui. Agreço também aos amigos que fiz durante essa jornada e me acompanharam durante toda a graduação.

Agradecimentos

Primeiramente agradeço a minha família por todo o apoio, principalmente a minha mãe, irmã e namorada que forneceram todo o apoio, emocional e financeiro, para que eu pudesse concluir minha formação.

Agradeço imensamente a todos os professores que fizeram parte de minha formação e me passaram seu conhecimento para que eu me tornasse um cientista da computação e, em especial, ao Prof. Dr. Leandro Alves Neves que foi com quem tive mais contato e me ajudou a evoluir muito como pessoa e como aluno, e me orientou durante todos os desafios da iniciação científica.

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

"Sonhos determinam o que você quer. Ação determina o que você conquista."

- Aldo Novak

Resumo

Nesse trabalho, é apresentado um método fundamentado em *deep learning* por *transfer learning* para classificar e reconhecer padrões em imagens radiográficas pulmonares, representativas das classes saudáveis e COVID-19. Para tanto, foram exploradas *deep learned features* das redes AlexNet, *Residual Neural Network*, DenseNet e EfficientNet, treinadas na base ImageNet. As *deep learned features* foram analisadas de diferentes camadas, tais como *max_pooling_3* da AlexNet, com 9216 valores, *avg_pool* da ResNet-50, com 2048 descritores, a *avg_pool* da DenseNet-201, com 1920 atributos e, por fim, a camada *avg_pool* da EfficientNet-b0, com 1280 características. Os atributos foram avaliados por meio de um processo com dois estágios de seleção: ranqueamento de cada entrada por meio do algoritmo ReliefF, aplicando um limiar para reduzir o número de possíveis combinações; aplicação de uma estratégia de seleção *wrapper*, baseado em comportamento animal, *Binary Grey Wolf Optimizer* (bGWO), a fim de encontrar as melhores combinações existentes em cada subconjunto de atributos. O poder discriminativo de cada solução foi definido explorando dez classificadores com diferentes heurísticas. Como resultado, a melhor combinação ocorreu a partir da camada *avg_pool* da rede Densenet, classificador SMO e usando apenas 27 atributos. Essa associação forneceu uma acurácia de 97,60%, medida F de 0,976 e uma AUC de 0,967. Além disso, essa solução representa uma redução de aproximadamente 98,59% do conjunto inicial de características que levou a uma taxa de acurácia mais elevada quando comparada com o desempenho da aplicação direta da Rede Neural Convolutiva com um custo computacional reduzido. Adicionalmente, acreditamos que os detalhes apresentados aqui podem contribuir com a comunidade interessada nos temas aqui explorados, fundamentando o desenvolvimento de modelos direcionados para o diagnóstico de imagens pulmonares de COVID-19.

Palavras-chave: COVID-19, imagens radiográficas, reconhecimento de padrões, *deep learned features*, ReliefF, bGWO.

Abstract

In this work, a method based on deep learning by transfer learning is presented to perform the classification and pattern recognition in pulmonary radiographic images, representative of healthy classes and COVID-19. Thus, deep learned features from the AlexNet, Residual Neural Network, DenseNet and EfficientNet, trained on the ImageNet dataset, will be explored. The deep learned features was analyzed from different layers, such as max_pooling_3 from AlexNet, with 9216 values, avg_pool from ResNet-50, with 2048 descriptors, the avg_pool of DenseNet-201, with 1920 attributes and, finally, the layer avg_pool of EfficientNet-b0, with 1280 features. The attributes was evaluated through a two-stage selection process: ranking each entry with the ReliefF algorithm and applying a threshold to reduce the number of possible combinations; application of a selection strategy wrapper, based on animal behavior, binary gray wolf optimizer, in order to find the best combinations in each subset of attributes. The discriminative power of each solution was defined by exploring ten classifiers with different heuristics. As a result, the best association occurred from the avg_pool layer of the Densenet network, SMO classifier and using only 27 attributes. This association provided an accuracy of 97.60%, an F measure of 0.976, and an AUC of 0.967. Furthermore, this solution represents a reduction of approximately 98.59% of the initial set of features which led to a higher accuracy rate when compared to the performance of the direct application of the Convolutional Neural Network with a reduced computational cost. Additionally, we believe the details presented here can contribute to the community interested in the issues explored here, supporting the development of models aimed at the diagnosis of pulmonary images of COVID-19.

Keywords: *COVID-19, radiographic images, pattern recognition, deep learned features, ReliefF, bGWO.*

Lista de Figuras

2.1	Ilustração da arquitetura clássica de uma CNN.	21
2.2	Exemplo de uma operação de <i>max-pooling</i>	22
2.3	Ilustração da arquitetura da rede neural residual ResNet-50 que será explorada neste trabalho.	25
2.4	Ilustração de um bloco residual.	26
2.5	Ilustração da arquitetura da rede neural convolucional AlexNet na qual as primeiras camadas definem a extração de <i>deep learned features</i> . . .	27
2.6	Ilustração de um <i>Dense Block</i> presente na arquitetura da CNN DenseNet. . .	28
2.7	Ilustração da arquitetura da rede neural DenseNet-201.	29
2.8	Ilustração da arquitetura da rede neural EfficientNet-b0.	30
2.9	Visão esquemática tridimensional de posicionamentos iniciais dos lobos em relação à presa, melhor solução.	33
4.1	Ilustração do método proposto contemplando as fases: 1) Extração de características (<i>deep learned features</i>); 2) Ranqueamento e seleção de características (<i>deep learned features</i>); e, 3) Classificação.	47
4.2	Exemplos de amostras dos contextos de imagens exploradas neste projeto: (A) Covid-19; (B) Saudável.	48
5.1	Taxas médias de acurácias obtidas a partir de diferentes classificadores, camadas e total de <i>deep learned features</i>	54

Lista de Tabelas

3.1	Resumo dos melhores resultados para os trabalhos utilizando estratégia de análise de características.	44
3.2	Resumo dos melhores resultados para os trabalhos utilizando estratégias baseadas em CNNs consolidadas.	44
3.3	Resumo dos melhores resultados para os trabalhos utilizando estratégias baseadas em CNNs especializadas.	44
5.1	Total de <i>deep learned features</i> selecionadas pelo algoritmo bGWO dentre as mais bem ranqueadas pelo ReliefF, considerando o intervalo de 10 a 100 atributos e diferentes camadas utilizadas no processo de investigação.	55
5.2	Resultados obtidos com cada classificador para a solução que forneceu a maior média de acurácia na camada <i>avg_pool</i> da CNN Resnet-50. .	56
5.3	Resultados conquistados por cada classificador para a solução com a maior média de acurácia na camada <i>max_pooling_3</i> da CNN Alexnet. .	56
5.4	Resultados obtidos com cada classificador para a solução que forneceu a maior média de acurácia na camada <i>avg_pool</i> da CNN Densenet. . .	57
5.5	Resultados obtidos com cada classificador para a solução que forneceu a maior média de acurácia na camada <i>avg_pool</i> da CNN Efficientnet. .	57
5.6	Principais resultados na classificação de imagens pulmonares de COVID-19 na literatura.	58

Lista de Abreviações

ACC Acurácia

AUC *Area Under Curve*

bGWO *Binary Grey Wolf Optimizer*

CAD *Computer-Aided Diagnosis*

CLAHE *Contrast limited adaptive histogram equalization*

CNN Rede Neural Convolucional

FN Falso Negativo

FP Falso Positivo

IBk *Instance Based k*

K* *kStar*

LRN *Local Response Normalization*

OMS Organização Mundial da Saúde

PCA Principal Component Analysis

Prec Precisão

Rec *Recall*

ReLU Rectified Linear Activation Function

ReLU *Rectified Linear Unit*

RNA Redes Neurais Artificiais

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	18
1.2	Objetivos	19
1.3	Organização do trabalho	19
2	Fundamentação Teórica	20
2.1	Redes Neurais Convolucionais	20
2.1.1	Camadas convolucionais	21
2.1.2	Camadas de <i>pooling</i>	21
2.1.3	Funções de ativação	22
2.1.4	Camadas totalmente conectadas (<i>Fully Connected Layers</i>)	22
2.1.5	Problema do Gradiente de Fuga	23
2.1.6	O Problema do Sobreajuste (<i>Overfitting</i>)	23
2.1.7	Transferência de Aprendizado	24
2.2	Modelos de CNNs	24
2.2.1	Especificação da CNN ResNet	24
2.2.2	Especificação da CNN AlexNet	26
2.2.3	Especificação da CNN DenseNet	26
2.2.4	Especificação da CNN EfficientNet	28
2.3	Extração de Características	30
2.4	Redução do conjunto de características utilizando o algoritmo ReliefF	31

2.5	Seleção de características utilizando o Algoritmo de Otimização Binário de Lobos Cinza	32
2.6	Abordagens para Classificação de Características	33
2.6.1	Baseados em função	34
2.6.2	Baseados em <i>Lazy Learning</i>	34
2.6.3	Baseados em Árvore de Decisão	35
2.6.4	Baseados no teorema de Bayes	36
2.6.5	Baseados em Meta-Aprendizado	36
2.7	Métricas para Avaliação de Desempenho	37
3	Revisão Bibliográfica	40
3.1	Análise de características	40
3.2	CNNs Consolidadas	41
3.3	CNNs Especializadas	43
3.4	Considerações Sobre os Trabalhos Relacionados	44
4	Metodologia	46
4.1	Estruturação do Método: Visão Geral	46
4.1.1	Base de Dados	47
4.2	Fase 1: Extração de características (<i>deep learned features</i>)	48
4.3	Fase 2: Ranqueamento e seleção das <i>deep learned features</i>	50
4.4	Fase 3: Classificação e Avaliação de Desempenho	51
4.5	Ferramentas e Ambiente de Desenvolvimento	52
5	Resultados	53
5.1	Indicações das melhores combinações	53
6	Conclusões	60
6.1	Contribuições Obtidas	61

6.2	Divulgação e Menção Honrosa	61
	Referências	62

Capítulo 1

Introdução

A análise de padrões e extração de informações em imagens biomédicas é um tema desafiador. Nesse cenário, a utilização de técnicas de aprendizado profundo (*deep learning*) se tornou uma estratégia importante ao permitir reconhecer padrões de forma eficiente e automática, auxiliando especialistas no estudo e diagnóstico de doenças (ZERDOUMI et al., 2018).

O aprendizado profundo pode ser entendido como modelos computacionais compostos por inúmeras camadas de processamento para representar os dados com níveis de abstrações. Isso é possível explorando os conceitos presentes nas Redes Neurais Artificiais (RNA) (HEATON, 2017). As RNAs podem ser utilizadas para descobrir estruturas complexas em grandes conjuntos de dados. Apesar de exploradas desde 1970, o custo computacional para treinar as redes foi um dos principais limites impostos para sua utilização. Porém, com a crescente capacidade de processamento dos computadores, a aplicação de um tipo específico de RNA do tipo *feed-forward*, conhecido como Rede Neural Convolucional (CNN), permitiu avanços significativos na área de reconhecimento de padrões (LECUN; BENGIO; HINTON, 2015a). De maneira complementar, a partir das propostas apresentadas por (HINTON, 2007; LE, 2013), o treinamento de redes neurais convolucionais tornou-se viável, pois a principal estratégia apresentada para a redução das taxas de erros de classificação, especialmente

em problemas complexos, foi aumentar significativamente o número de camadas (profundidade) que define a arquitetura de uma rede. Essa prática tornou-se comum em diversas aplicações de redes neurais convolucionais, como as redes treinadas na base de imagens nomeada de ImageNet (DENG et al., 2009).

Para o reconhecimento de padrões em imagens, as redes neurais convolucionais transformam os dados brutos (pixels da imagem) em informações representadas por meio de conjuntos de características (*deep learned features*), a partir dos quais o subsistema de aprendizagem, muitas vezes um classificador, detecta ou classifica os padrões nas imagens de entrada (LECUN; BENGIO; HINTON, 2015a). Neste contexto, os valores dos pixels de uma imagem são usados por um modelo CNN a fim de determinar as *deep features* mais relevantes durante um processo convolucional, processo que envolve várias camadas. Em suma, as características aprendidas nas primeiras camadas de uma rede buscam, geralmente, identificar a presença de bordas em locais específicos na imagem, por exemplo. As camadas intermediárias visam identificar padrões de arranjos particulares de bordas, independentemente de pequenas variações. As últimas camadas são destinadas para observar aspectos em combinações maiores, além de definir objetos como combinações dessas partes (SANTOS; PONTI, 2019).

É importante ressaltar que aumentar a profundidade de uma rede neural convolucional gera dificuldades na etapa de treinamento, pois a multiplicação sucessiva de pesos presentes em cada camada produz um gradiente de fuga extremamente pequeno e, como consequência, as características extraídas (*deep learned features*) não são significativamente distintas para favorecer a etapa de classificação por estarem fortemente ligados as amostras da etapa de treinamento (HOCHREITER, 1998). Como resultado, o desempenho de uma rede neural convolucional pode saturar ou degradar rapidamente à medida que sua profundidade aumenta (ZHENG; YANG; TIAN, 2017). Por esta razão, explorar *deep learned features* de redes com um número relativamente pequeno de camadas é um tema desafiador e extremamente relevante para as áreas de proces-

samento gráfico, análise de imagens e aprendizado de máquina, caracterizando uma das justificativas que direciona o projeto aqui proposto. Adicionalmente, estudos presentes na literatura evidenciam que modelos obtidos a partir de associações de redes neurais convolucionais com diferentes tipos de classificadores podem apresentar resultados iguais ou melhores que os fornecidos por redes neurais convolucionais muito profundas. Um bom exemplo é a categoria de modelos baseados em *deep learned features* por *transfer learning*. No *transfer learning*, as camadas totalmente conectadas e de saída são removidas da CNN previamente treinada em um conjunto de exemplos (NANNI et al., 2020). Esses fatos completam as justificativas que fundamentam nossa proposta. Com isso, a saída produzida pelas camadas convolucionais e de *pooling* é entendida como um vetor de características (também nomeadas como atributos convolucionais ou *deep learned features*), que podem ser aplicados para investigar o conjunto de teste.

Neste contexto, uma motivação para o desenvolvimento da investigação aqui proposta é que, apesar dos avanços envolvendo modelos computacionais direcionados para investigações de padrões em imagens, uma dificuldade comumente enfrentada na área de diagnóstico médico é a avaliação da gravidade de achados anormais, principalmente quando diferentes opiniões ocorrem entre os especialistas. Esse fato motiva o desenvolvimento e aplicação de sistemas conhecidos como *Computer-Aided Diagnosis* (CAD) para apoiar os especialistas no estudo e tomadas de decisões (TAKAHASHI; KAJIKAWA, 2017), como o indicado em nosso estudo. Esses sistemas consideram diferentes etapas, tais como extração, análise e seleção de características das imagens, bem como a interpretação e reconhecimento de possíveis padrões. Outra motivação comumente observada em propostas de sistemas CAD, que também caracteriza nossa investigação, é o de definir as melhores estratégias para os mais diferentes contextos, tais como na investigação de COVID-19 (MAO et al., 2019; HEMDAN; SHOU-MAN; KARAR, 2020; ABBAS; ABDELSAMEA; GABER, 2020; BARSTUGAN;

OZKAYA; OZTURK, 2020).

1.1 Justificativas e Motivação

A COVID-19 é uma doença causada pelo coronavírus SARS-CoV-2, que pode apresentar um quadro clínico variando de infecções assintomáticas a quadros respiratórios graves (CHOI, 2021) e em 30 de janeiro de 2020 foi definido como um problema mundial de saúde pela Organização Mundial da Saúde (OMS) e, além disso, devido a sua disseminação internacional também se tornou um problema econômico (TOMAR; GUPTA, 2020). Assim, a análise de imagens pulmonares podem contribuir para o desenvolvimento de sistemas de apoio ao diagnóstico de COVID-19, fatos que também motivam a investigação aqui proposta. Neste cenário, foi observada uma concentração de esforços para apoiar o diagnóstico de COVID-19, inclusive por meio da classificação de imagens radiográficas e tomográficas (MAO et al., 2019; ABBAS; ABDEL-SAMEA; GABER, 2020; BARSTUGAN; OZKAYA; OZTURK, 2020), assim como a utilização de métodos de *deep learning* por *transfer learning* para analisar atributos convolucionais de uma CNN aplicada, inclusive por meio de uma meta-heurística e classificadores externos à rede (HEMDAN; SHOUMAN; KARAR, 2020; JIN et al., 2021; APOSTOLOPOULOS; TZANI, 2020; APOSTOLOPOULOS; AZNAOURIDIS; TZANI, 2020). Porém, a utilização de algoritmos bioinspirados não foram totalmente explorados neste tipo de investigação, como é o algoritmo de otimização binária de lobos cinza, do inglês *Binary Grey Wolf Optimizer*, mesmo indicando os melhores resultados na seleção de atributos em comparação com outras abordagens (WAHAB; NEFTI-MEZIANI; ATYABI, 2015a). Por fim, este tipo de investigação permite fornecer modelos computacionais mais otimizados e podem embasar sistemas CAD direcionados para a classificação e reconhecimento de padrões de COVID-19. Esses fatos completam as principais motivações para o desenvolvimento deste trabalho.

1.2 Objetivos

Neste projeto foi explorado *deep learned features* por *transfer learning* a fim de definir a melhor associação entre atributos, meta-heurística e classificadores externos a uma rede CNN, com o propósito de apresentar informações para o desenvolvimento de sistemas CAD direcionados ao reconhecimento de padrões de imagens de COVID-19. Especificamente, buscou-se:

- Aplicar modelos de CNN em imagens de COVID-19 e obter as *deep learned features* que representam as classes de imagens sob investigação;
- Selecionar as *deep learned features* mais relevantes, por meio de uma meta-heurística, a fim de identificar um subconjunto de características que maximize a classificação. A meta-heurística é a fundamentada no algoritmo bGWO;
- Aplicar classificadores reconhecidos da área de inteligência artificial para identificar as melhores combinações (atributos e de quais modelos, técnica de seleção de características e classificador), com o melhor desempenho no contexto de imagens de COVID-19.

1.3 Organização do trabalho

No Capítulo 2 podem ser encontrados os principais conceitos que fundamentam esse trabalho. Nele são explanados temas como Redes Neurais Convolucionais, extração e seleção de características e, além disso, métodos para classificação e avaliação de desempenho. No Capítulo 3 são apresentados alguns trabalhos correlatos que ajudam a fundamentar todo o método proposto e embasam a metodologia utilizada. Uma descrição completa do método é apresentada no Capítulo 4. No Capítulo 5 são apresentados os resultados parciais obtidos via aplicação da metodologia proposta. Por fim, no Capítulo 6 são apresentadas as conclusões obtidas nesse trabalho.

Capítulo 2

Fundamentação Teórica

Este capítulo fornece os conceitos essenciais para a compreensão do projeto. Aqui são descritos tópicos como redes neurais convolucionais, o processo de extração, classificação e seleção de características, além de métricas comumente usadas para avaliar modelos de aprendizado de máquina.


2.1 Redes Neurais Convolucionais

As Redes Neurais Convolucionais, do inglês Convolutional Neural Networks, foram desenvolvidas para o processamento de dados estruturados em vetores, como uma imagem colorida, composta de três vetores de duas dimensões, um para cada banda de cor, e vem sendo utilizadas amplamente para diversas tarefas de análise como classificação de imagens, detecção de faces e segmentação de imagens (LECUN; BENGIO; HINTON, 2015b). Uma CNN é composta basicamente por camadas de convolução, camadas de *pooling*, uma função de ativação e as camadas totalmente conectadas. Uma estrutura básica de uma CNN pode ser observada na Figura 2.1.

As camadas de convolução atuam como filtros nas imagens com o intuito de extrair as características das imagens. Essas características passam então para as camadas de *pooling*, responsáveis por diminuir a dimensionalidade dos dados, preservando as ca-

racterísticas mais importantes (BHARADIYA, 2023). A função de ativação é utilizada para definir quais características devem ser passadas adiante pela rede utilizando uma função não-linear, onde a mais conhecida é a função ReLU (*rectified linear activation function*) (LECUN; BENGIO; HINTON, 2015b). As últimas camadas são formadas por camadas totalmente conectadas, que utilizam as imagens filtradas de alto nível para traduzi-las em uma das categorias (BHARADIYA, 2023).

Figura 2.1: Ilustração da arquitetura clássica de uma CNN.



Fonte: Adaptada de (BHARADIYA, 2023).

2.1.1 Camadas convolucionais


As camadas convolucionais são o principal componente das CNNs e são responsáveis por extrair características da matriz de entrada utilizando núcleos de aprendizado (*Kernels*) que formam os mapas de características. As camadas convolucionais mais iniciais extraem características primárias, como bordas, cantos e texturas. Características mais complexas são extraídas nas últimas camadas (NAMATEVS, 2017).

2.1.2 Camadas de *pooling*

As camadas de *pooling* são normalmente inseridas após as camadas convolucionais para diminuir os parâmetros da rede, mantendo somente os dados mais relevan-

tes (GHOLAMALINEZHAD; KHOSRAVI, 2020). As camadas de *pooling* são uma peça chave para a redução da dimensionalidade dos dados em uma CNN, diminuindo a complexidade computacional e também ajudando para a redução do problema de *overffiting*. Um dos operadores mais utilizados para o *pooling* é o *max-pooling*, cujo objetivo é selecionar o maior valor em um subconjunto do mapa de características (Figura 2.2).

Figura 2.2: Exemplo de uma operação de *max-pooling*.



Fonte: Adaptada de (GHOLAMALINEZHAD; KHOSRAVI, 2020).

2.1.3 Funções de ativação

As funções de ativação são funções matemáticas com o intuito de atribuir ou não relevância as informações dos neurônios de uma rede neural e são comuns a qualquer arquitetura de CNN (KARLIK; OLGAC, 2011). A função mais utilizada é a função ReLU (Equação 2.1) ao oferecer um bom desempenho a um pequeno custo computacional. Sua função é ativar somente neurônios que obtiveram entradas positivas.

$$\text{ReLU}(x) = \max(0, x). \quad (2.1)$$

2.1.4 Camadas totalmente conectadas (*Fully Connected Layers*)

As camadas totalmente conectadas, do inglês *Fully Connected Layers*, são as últimas camadas de uma CNN e são camadas de uma dimensão totalmente conectadas as

camadas anteriores e as próximas, ou seja, cada neurônios está conectado a todos da camada anterior e da próxima (NAMATEVS, 2017).

2.1.5 Problema do Gradiente de Fuga

Uma das estratégias utilizadas para aumentar o desempenho das Redes Neurais Convolucionais foi aumentar o número de camadas (profundidade da rede), assim ela poderia aprender mais sobre as imagens e oferecer melhores resultados. Apesar desse tipo de abordagem ter sido eficiente até certo ponto, existem problemas atrelados a aumentar o número de camadas de uma CNN, e um deles é o problema do gradiente de fuga.

O gradiente de fuga (HOCHREITER, 1998) é o problema onde as camadas mais iniciais da rede aprendem mais lentamente do que as camadas mais posteriores, o que pode fazer o desempenho da rede diminuir, pois as primeiras camadas acabam limitando o aprendizado das demais, já que elas não possuem informações suficientes para o aprendizado. Em CNNs muito profundas o problema é ainda mais agravado, pois muitas camadas são prejudicadas.

2.1.6 O Problema do Sobreajuste (*Overfitting*)

O *overfitting* é um problema comum em métodos de aprendizado de máquina e acontece durante o treinamento do modelo e, quando isso ocorre, torna o modelo muito especializado ao conjunto de dados de treino e ao ser exposto a dados reais o modelo falha em obter uma boa desempenho (ACEñA et al., 2022). Um modelo de CNN bem treinado diminuirá os erros de generalização e, por consequência, o modelo se torna generalizado.

Existem diversas formas de evitar ou pelo menos minimizar o *overfitting*, sendo algumas delas o *Dropout* e o *Batch Normalization*. O *Dropout* usa um cálculo de probabilidade para desativar aleatoriamente os alguns neurônios da rede com o intuito

de reduzir a dependência entre os neurônios (ZHOU; GREENSPAN; SHEN, 2017). Já o *Batch Normalization* visa aplicar uma normalização nos pesos calculados após a saída de uma camada da rede e utilizar esses valores normalizados no processo de *back-propagation* (IOFFE; SZEGEDY, 2015; MA; KLABJAN, 2017).

2.1.7 Transferência de Aprendizado

A transferência de aprendizado, do inglês *transfer learning*, é o conceito da utilização de um aprendizado já consolidado como entrada para uma nova construção de conhecimento de um novo modelo, e vem sendo amplamente utilizada para o treinamento eficiente de CNNs (ZHUANG et al., 2019).

Essa prática oferece várias vantagens e uma delas é a velocidade de treinamento do modelo. Iniciando o treinamento de uma CNN com as camadas reforçadas com um aprendizado prévio, obtido do modelo anterior, diminui a possibilidade de problemas de *overfitting* e Gradiente de fuga.

2.2 Modelos de CNNs


Existem diversos tipos de Redes Neurais Convolucionais e cada uma utiliza diferentes estratégias de classificação e reconhecimento de padrões. Para esse trabalho foram escolhidos modelos de CNNs amplamente conhecidos, a ResNet (Seção 2.2.1), AlexNet (Seção 2.2.2), DenseNet (Seção 2.2.3) e a EfficientNet (Seção 2.2.4). Nessa seção serão descritos os modelos utilizados juntamente com suas especificações técnicas.

2.2.1 Especificação da CNN ResNet

O uso da ResNet foi a partir de modelo com 50 camadas (ResNet-50) (HE et al., 2016). Em suma, esse modelo consistiu em quatro blocos, cada um com camadas de

convolução e blocos residuais. O primeiro bloco possui nove camadas de convolução e três blocos residuais. O segundo bloco tem 12 camadas de convolução e quatro blocos residuais. O terceiro bloco possui seis blocos residuais e 18 camadas de convolução. O quarto bloco possui a mesma quantidade de camadas de convolução e blocos que residuais que o bloco 1 (RAHHAL et al., 2018). Nessa arquitetura, as camadas receberam valores resultantes das funções de ativação ReLU e os valores de entrada dessas funções. Assim, a arquitetura ResNet-50 utilizou *identity shortcut connection* contendo normalização de lotes para saltar grupos de camadas, permitindo minimizar questões envolvendo *overfitting* e o problema do gradiente de fuga. Além disso, a primeira camada de convolução da rede foi constituída com *kernel* de 7×7 e um *stride* igual a 2, seguido de uma camada de *max_pooling* de *kernel* 3×3 e um *stride* de 2. As próximas camadas da rede foram definidas com *kernels* de 1×1 , 3×3 e 1×1 em cada bloco, por exemplo. Por fim, as imagens utilizadas como entradas respeitaram o padrão exigido pela arquitetura, sendo de 224×224 pixels. Um resumo da arquitetura da ResNet-50 utilizada neste estudo está na Figura 2.3.


Figura 2.3: Ilustração da arquitetura da rede neural residual ResNet-50 que será explorada neste trabalho.



Fonte: Adaptada de (ALI et al., 2021).

É importante destacar que a ResNet usa a estratégia de “conexão de atalhos de identidade”, que pula uma ou mais camadas. Essa estrutura é denominada bloco residual e pode ser observada na Figura 2.4.

Figura 2.4: Ilustração de um bloco residual.



Fonte: (HE et al., 2016).

2.2.2 Especificação da CNN AlexNet


O modelo AlexNet possui camadas de *pooling* após o primeiro, segundo e quinto blocos, finalizando a parte de extração de *deep learned features* da CNN. A primeira camada de convolução foi com um *kernel* de 11×11 e um *stride* igual a 4. A segunda camada foi definida com um *kernel* de 5×5 e *stride* igual 1. As três últimas camadas de convolução foram com *kernels* de 3×3 e *stride* igual a 1. As camadas de *pooling* utilizaram *max_pooling* com *kernel* de 3×3 e *stride* de 2. As camadas responsáveis pela classificação foram as totalmente conectadas, com o uso de camadas de normalização, função de ativação ReLU e *dropout*, taxa de 50% (0,5). Os detalhes dessa arquitetura estão disponíveis em (KRIZHEVSKY; SUTSKEVER; HINTON, 2012b).

As imagens fornecidas como entradas foram de 227×227 pixels, seguindo o padrão requerido pela rede. A arquitetura dessa rede, assim como a dimensão dos *kernels* e *strides* de cada camada estão ilustrados na Figura 2.5.

2.2.3 Especificação da CNN DenseNet

A DenseNet é um dos modelos que apresentou resultados relevantes na classificação de imagens médicas e utiliza uma abordagem inovadora para explorar as conexões

Figura 2.5: Ilustração da arquitetura da rede neural convolucional AlexNet na qual as primeiras camadas definem a extração de *deep learned features*.




Fonte: Adaptada de (KRIZHEVSKY; SUTSKEVER; HINTON, 2012a).

entre as camadas convolucionais (CHAUHAN; PALIVELA; TIWARI, 2021; KONG; CHENG, 2022; WANG et al., 2021). Esse modelo explora que ao adicionar conexões entre as camadas iniciais e finais de uma CNN é possível aumentar a profundidade da rede e alcançar uma maior acurácia (HUANG et al., 2016). Dessa maneira, o modelo DenseNet utiliza conexões entre todas as camadas, o que caracteriza os *Dense Blocks* (Figura 2.6) presentes na arquitetura dessa rede. É possível calcular a quantidade de conexões presentes na rede por meio da Equação 2.2, onde L é a quantidade total de camadas da rede.

$$L = \frac{L(L+1)}{2} \quad (2.2)$$

Muitos modelos foram desenvolvidos baseado na arquitetura DenseNet, tais como DenseNet-121, DenseNet-129, entre outros. O número após o nome da rede indica a quantidade de camadas presentes no modelo. Para esse trabalho foi escolhido o modelo DenseNet-201 com 201 camadas de profundidade e o modelo esquemático da arquitetura completa pode ser observado na Figura 2.7.

Figura 2.6: Ilustração de um *Dense Block* presente na arquitetura da CNN DenseNet.

Fonte: (CHAHAR et al., 2020).


2.2.4 Especificação da CNN EfficientNet

O modelo EfficientNet foi proposto em 2019 e possui menos parâmetros e uma taxa de assertividade alta quando comparado com modelos clássicos de CNN (SU; WANG, 2020). A ideia para a composição dessa arquitetura foi encontrar um equilíbrio entre profundidade (d), largura (w) e resolução (r) que oferecesse o melhor desempenho, baseado na relação demonstrada na Equação 2.3:

$$\begin{aligned} d &= \alpha^\phi, w = \beta^\phi, r = \gamma^\phi, \\ \alpha^2 \cdot \beta^2 \cdot \gamma^2 &\approx 2, \\ \alpha &\geq 1, \beta \geq 1, \gamma \geq 1, \end{aligned} \tag{2.3}$$

em que α , β e γ são calculados a partir de um método chamado *grid search* (LIASHCHYNSKYI; LIASHCHYNSKYI, 2019). A partir dessa metodologia foi possível obter uma arquitetura com uma alta taxa de acurácia, chegando a 84,3% de assertividade na base de imagens da ImageNet, com tamanho total da arquitetura da rede


Figura 2.7: Ilustração da arquitetura da rede neural DenseNet-201.



Fonte: (CHAHAR et al., 2020).

reduzido e treinamento mais rápido quando comparado a outros modelos de CNN. A arquitetura da EfficientNet-b0 está ilustrada na Figura 2.8.

Figura 2.8: Ilustração da arquitetura da rede neural EfficientNet-b0.



Fonte: Adaptada de (SU; WANG, 2020).

2.3 Extração de Características

A tarefa de classificar imagens em diferentes grupos conforme o conteúdo delas é uma tarefa desafiadora devido à alta dimensionalidade dos dados envolvidos nesse tipo de informação. Uma imagem é uma composição de uma quantidade enorme de pixels que frequentemente contêm uma quantidade significativa de informação redundante ou irrelevante que dificulta a classificação. A tarefa de extrair as características

visa transformar informação crua em informação relevante para a classificação, reduzindo enormemente a dimensionalidade dos dados e leva a uma melhor desempenho do sistema classificador (FAN et al., 2022).

As características de uma imagem são normalmente organizadas em um vetor de características, onde cada componente desse vetor representa um descritor associado ao padrão buscado. Esses padrões podem ser obtidos a partir de diversas métricas definidas, como: textura, comprimentos de formas, níveis de bordas, entre outros (GONZALEZ; WOODS, 2018). Nesse trabalho foram utilizadas *Deep Learned Features* para a formação dos vetores de características. Elas foram obtidas a partir das *deep features* retiradas de uma camada convolucional de uma CNN.

A partir desse contexto, vários métodos podem ser aplicados para obter uma redução na dimensionalidade desses vetores, buscando manter somente características que tenham uma relevância para a tarefa de classificação.

2.4 Redução do conjunto de características utilizando o algoritmo ReliefF

O algoritmo ReliefF (ROBNIK-SIKONJA; KONONENKO, 2003) é uma extensão do algoritmo Relief. Conforme descrito por (ROBNIK-SIKONJA; KONONENKO, 2003), a ideia principal do algoritmo é atribuir pesos as características com base na correlação entre atributos e rótulos de classe (WEI; WANG; LIANG, 2021). O ReliefF usa os k vizinhos mais próximos de instâncias selecionadas aleatoriamente para avaliar uma característica sob análise, servindo para tratar conjuntos de dados incompletos. Assim, o ReliefF seleciona uma instância $\mathbf{R}_i$ do conjunto de treinamento $D = \{(\mathbf{x}_n, y_n)\}_{n=1}^N$, e k vizinhos próximos de $\mathbf{R}_i$ e $NH_{t,t} = 1, \dots, k$, são selecionados da mesma classe de $\mathbf{R}_i$. Adicionalmente, k vizinhos próximos de $\mathbf{R}_i$, $NM_{t,t} = 1, \dots, k$, são selecionados de classes diferentes de $\mathbf{R}_i$. O peso de cada característica j em cada

iteração é atualizado conforme a Equação:

$$W_j = W_j - \frac{\sum_{t=1}^k dif(j, \mathbf{R}_i, \mathbf{NH}_t)}{m \times k} + \frac{\sum_{C \neq classe(\mathbf{R}_i)} \left[\frac{P(C)}{1 - P(classe(\mathbf{R}_i))} \sum_{t=1}^k dif(j, \mathbf{R}_i, \mathbf{NM}_t(C)) \right]}{m \times k}, j = 1, 2, \dots, I, (2.4)$$

em que m é o número de amostras de instâncias aleatórias, $P(C)$ é a probabilidade anterior da classe C (obtido do conjunto de treinamento) e I é o número total de características.


Para garantir que a soma dos pesos de todas as classes diferentes é igual a 1, utiliza-se $1 - P(classe(\mathbf{R}_i))$ para dividir a probabilidade para cada peso (ROBNIK-SIKONJA; KONONENKO, 2003).

2.5 Seleção de características utilizando o Algoritmo de Otimização Binário de Lobos Cinza

O Algoritmo de Otimização Binário de Lobos Cinza simula o procedimento de caça de uma matilha de lobos cinza. Em uma matilha, existe uma hierarquia composta pelo lobo alfa (líder), lobos betas (subordinados dos alfas e auxiliam nas tomadas de decisões ditadas pelo alfa) e lobos deltas (subordinados aos alfas e betas). Os lobos ômegas são submissos a todos os outros lobos. No modelo matemático, a melhor solução é chamada de alfa, a segunda melhor de beta e a terceira melhor de delta. A caça é guiada por alfa, beta e delta. Os ômegas se movem conforme os líderes para realizar o cerco da presa. As posições iniciais de lobos candidatos são definidas de forma arbitrária. Os três melhores candidatos foram escolhidos de acordo com uma função de aptidão (*fitness*), que foi avaliada conforme o poder de classificação das soluções da iteração atual. Nesse caso, o algoritmo *k-nearest neighbors* foi o método interno do bGWO para definir a relevância de classificação. Em cada iteração, as posições dos lobos foram atualizadas conforme a posição do lobo alfa, por meio

do processo de *crossover*. Um exemplo ilustrativo de posicionamentos dos lobos em relação à presa está na Figura 2.9, em que a presa (melhor solução) está no centro do espaço de soluções, e os lobos devem se aproximar da presa por meio de somas vetoriais. Detalhes foram descritos em (CHANTAR et al., 2020).

Figura 2.9: Visão esquemática tridimensional de posicionamentos iniciais dos lobos em relação à presa, melhor solução.



Fonte: (CHANTAR et al., 2020).

2.6 Abordagens para Classificação de Características

A avaliação de um conjunto de características se dá a partir do uso de métodos que conseguem medir a efetividade desse conjunto para classificar os objetos de estudo. Ao classificar e selecionar características que são mais relevantes é possível obter um modelo mais assertivo e eficiente nessa tarefa e, juntamente a isso, utilizar algoritmos classificadores para medir o desempenho do método. Nesse trabalho foram utilizados dez algoritmos para a classificação, utilizando divergentes abordagens.

2.6.1 Baseados em função

Classificadores baseados em função utilizam as características de um objeto dadas de entrada para classificar ele em uma das possíveis classes definidas. Isso é feito a partir da construção de um modelo linear que tenta dividir os objetos de estudo maximizando a distância dos pontos no espaço de características. Nesse trabalho foram utilizados os classificadores *Logistic* e *Sequential Minimal Optimization*:

- *Logistic*

O algoritmo *Logistic* utiliza como base a implementação do algoritmo *Logistic Regression*, sendo um modelo generalizado de regressão linear que utiliza uma função sigmoide para classificação (LI; LI; JIANG, 2023). Nesse modelo em específico é utilizada a regularização *Ridge* para lidar com pesos de instâncias como proposto por (CESSIE; HOUWELINGEN, 1992).

- *Sequential Minimal Optimization*

O algoritmo *Sequential Minimal Optimization* (SMO), proposto por (PLATT, 1998), se baseia na abordagem de classificação do algoritmo *Support Vector Machine* (SVM) com a característica de dividir o problema em problemas menores, evitando a resolução de funções quadráticas, aumentando a eficiência do algoritmo (YU; LI; LIU, 2023).

2.6.2 Baseados em *Lazy Learning*

A abordagem de *Lazy Learning* se baseia em realizar a classificação somente quando é obtido o conjunto de testes, caracterizando o “atraso” desse tipo de algoritmo (AHA, 1997). Para essa classe de algoritmos foram escolhidos o *kStar* e o *Instance Based k*:

- *kStar* (K*)

O algoritmo K^* (CLEARY; TRIGG, 1995) é um classificador que utiliza uma função de similaridade para relacionar as instâncias de treinamento, assim dividindo os elementos em classes. Esse algoritmo se difere de outros baseados em instância, pois utiliza uma função de distância baseada em entropia.

- *Instance Based k (IBk)*

O algoritmo IBk (AHA; KIBLER, 1991) utiliza a abordagem *k-nearest neighbours*. O algoritmo busca pelos k vizinhos mais próximos da característica em análise, assim formando grupos que representam as classes, e utiliza esses grupos para classificação e avaliação do modelo formado.

2.6.3 Baseados em Árvore de Decisão

Classificadores baseados em Árvore de Decisão utilizam estruturas de árvore para classificação, onde os nós representam as características, os galhos representam as decisões e as folhas representam as classes (PATEL; PRAJAPATI, 2018). Nesse trabalho foram escolhidos os algoritmos *Random Tree* e *Random Forest*:

- *Random Tree*

O algoritmo *Random Tree* cria uma árvore de decisão baseado no valor de k características aleatórias, onde o nó raiz representa a característica mais relevante para a classificação. A partir disso, a árvore é construída a partir do restante das características e o modelo é avaliado (FRANK; HALL; WITTEN, 2016).

- *Random Forest*

O algoritmo *Random Forest* utiliza a mesma abordagem do algoritmo *Random Tree*, mas nesse caso são utilizadas diversas árvores de decisão. Isso é feito para minimizar problemas de *overfitting* e aumentar a eficiência de classificação (BREIMAN, 2001).

2.6.4 Baseados no teorema de Bayes

Esses classificadores utilizam o teorema de Bayes como base para a classificação. O teorema de Bayes descreve a probabilidade de um evento ocorrer e essa família de classificadores utiliza isso para minimizar os erros de classificação a partir das combinações de características (LI et al., 2022). Nesse trabalho os classificadores foram escolhidos os algoritmos *NaiveBayes* e *BayesNet*:

- *NaiveBayes*

O algoritmo *NaiveBayes* assume que todas as características são independentes umas das outras e utiliza o algoritmo de Bayes para classificação, buscando maximizar a probabilidade posteriormente. O objetivo do algoritmo é calcular a probabilidade condicional de cada atributo baseado no conjunto de treinamento (LI et al., 2022).

- *BayesNet*

O algoritmo *BayesNet*, ou *Bayesian network*, também utiliza o teorema de Bayes para a classificação, mas o seu diferencial está em que ele constrói um modelo baseado em um grafo direcionado para classificação, onde cada nó representa uma característica e as arestas representam as relações entre elas. Assim, para cada nó é calculada a probabilidade condicional (ABDAR et al., 2020).

2.6.5 Baseados em Meta-Aprendizado

Algoritmos de Meta-Aprendizado são caracterizados por utilizar combinações de algoritmos onde eles otimizam reciprocamente em busca de obter melhores resultados. Para a classificação de características são utilizados algoritmos de *Boosting*. Nesse tipo de abordagem, os algoritmos são treinados hierarquicamente de modo a aprender o problema de classificação, ou seja, aprender a como classificar (ZHANG; FANG, 2007). Foram escolhidos os algoritmos *LogitBoost* e *Rotation Forest*:

- *LogitBoost*

O algoritmo *LogitBoost* utiliza a construção de “classificadores fracos” como um fator principal para classificação, no qual a cada iteração um preditor individual deles é treinado. São formadas árvores de decisão com o intuito de dividir o espaço de características em sub-regiões. Ao fim é feito um *ensemble* desses classificadores (CAO et al., 2021).

- *Rotation Forest*

O algoritmo *Rotation Forest* é um algoritmo que usa a combinação de algoritmos de árvores de decisão, utilizando a rotação do espaço de características como estratégia para o treinamento do *ensemble* de classificadores. Essa estratégia torna esse classificador mais poderoso em relação a outros classificadores de *ensemble* (JUEZ-GIL et al., 2021).

2.7 Métricas para Avaliação de Desempenho

O processo de avaliação com cada algoritmo de classificação foi realizado a partir da estratégia de *cross-validation k-fold*, com $k = 10$, e métricas comumente disponíveis na literatura, tais como acurácia (ACC), medida F e área sob a curva ROC, do inglês *Area Under Curve* (AUC) (CHIU, 2012).

A acurácia é a métrica mais utilizada para analisar o resultado de um processo de classificação ao permitir quantificar a efetividade geral do classificador, sendo calculada pela divisão entre a soma das classificações corretas, positivas e negativas, pela soma de todas as classificações (SOKOLOVA; LAPALME, 2009). Para tanto, são considerados os valores de:

- **Verdadeiro Positivo (VP)**, quando uma instância é positiva e classificada como positiva;

- **Verdadeiro Negativo (VN)**, quando uma instância é negativa e classificada como negativa;
- **Falso Positivo (FP)**, quando uma instância é negativa e classificada como positiva;
- **Falso Negativo (FN)**, quando uma instância é positiva e classificada como negativa.

Assim, a taxa de ACC é dada por, conforme descrito em (HAEGEMANS; SNOECK; LEMAHIEU, 2016):

$$ACC = \frac{VP + VN}{VP + VN + FP + FN}. \quad (2.5)$$

Complementarmente, a medida F representa a média harmônica entre Precisão (Prec), Equação 2.6, e sensibilidade/Recall (Rec), Equação 2.7, permitindo indicar a qualidade do modelo (SASAKI; FELLOW, 2007; LATOUR, 2021). Assim, caso Prec seja zero, condição em que nenhuma amostra da classe é classificada corretamente, a medida F também assumirá valor zero. O mesmo raciocínio é aplicado a Rec, além de permitir conhecer o total de amostras corretas dentre todas as amostras positivas. Logo, a Medida F, também chamada de *F1 score*, é definida via Equação 2.8.

$$Prec = \frac{VP}{VP + FP}. \quad (2.6)$$

$$Rec = \frac{VP}{VP + FN}. \quad (2.7)$$

$$MedidaF = 2 \times \frac{Prec \times Rec}{Prec + Rec}. \quad (2.8)$$

Por fim, a curva ROC é dada em termos de sensibilidade ou Rec (Equação 2.7) e especificidade (Equação 2.9). A especificidade indica a taxa de amostras negativas classificadas corretamente como negativas. A partir dessas métricas, um gráfico *Receiver Operating Characteristic* (ROC) pode ser compreendido como uma representação gráfica entre 1–especificidade (eixo x) e sensibilidade (eixo y). Assim, uma AUC pode assumir valores entre 0 e 1. Uma curva AUC dada por uma linha diagonal entre os pontos (0,0) e (1,1) indica que o classificador possui capacidade discriminativa aleatória. Valores de AUC maiores que 0,5 indicam classificadores com alguma habilidade de discriminação. Uma curva ROC com área 1 define uma classificação perfeita (FAWCETT, 2006).

$$especificidade = \frac{VN}{VN + FP}. \quad (2.9)$$

Capítulo 3

Revisão Bibliográfica

Neste capítulo são apresentados trabalhos relacionados a proposta de utilização de Redes Neurais Convolucionais para a classificação de COVID-19. Aqui são descritos diversos trabalhos com metodologias diferentes para a classificação de COVID-19, sendo elas: análise de características, focando em trabalhos que obtiveram vetores de características de formas variadas e submeteram elas a algum tipo de análise; CNNs Consolidadas, onde são apresentados trabalhos que fazem o uso de Redes Neurais Convolucionais bem estabelecidas para a classificação de imagens representativas dessa doença; e por fim, CNNs Especializadas, onde são descritos trabalhos que apresentaram novas arquiteturas para a classificação de COVID-19.

3.1 Análise de características

O estudo de Rajpal et.al. (RAJPAL et al., 2021) propôs a estratégia de *transfer learning* para a obtenção e seleção de características da CNN ResNet-50 pré-treinada na ImageNet. A metodologia se dividiu em três fases, onde a primeira fase foi destinada à obtenção das *deep features* da camada *avg_pool* da rede, formando um vetor com 2048 características. Após isso, foram selecionadas manualmente 252 características, um processo chamado de *handpicked*, onde os autores avaliaram o desempenho das

features e mantiveram somente as que demonstraram um melhor desempenho para a classificação. Esse subconjunto de características foi dado de entrada para o algoritmo *Principal Component Analysis* (PCA), que fez a seleção das mais relevantes, restando assim somente um conjunto de 64 *deep features*. Esse subconjunto foi submetido também a uma seleção, mas dessa vez por meio de uma rede neural *feed forward*, que selecionou um conjunto final de 16 características. Essa metodologia foi capaz de alcançar uma acurácia de 94,40% para classificação de uma base de dados composta de quatro classes: pneumonia viral; pneumonia bacteriana; COVID-19 e não infectado.

Para a seleção de características, Singh et.al (SINGH et al., 2021) utilizaram técnicas de extração de características e classificação com diversos classificadores. Os vetores de características foram obtidos a partir dos níveis de luminância de imagens radiográficas pulmonares de COVID-19. A base de imagens foi composta por 219 imagens de COVID-19, 1341 imagens de pulmões saudáveis e 1345 imagens representativas de pneumonia viral. A base de imagens no padrão de cores RGB foi pré-processada e alterada para imagens de 8 bits em níveis de cinza com dimensões de 100×100 pixels. O método alcançou uma acurácia de 99.65% utilizando o algoritmo *Hybrid Social Group Optimization* para a redução do espaço de características juntamente com o classificador *Support Vector Machine*.

3.2 CNNs Consolidadas

O uso de CNNs pré-treinadas vem sendo amplamente explorado para a classificação de doenças, principalmente quando as bases de dados possuem poucas imagens. Nesse sentido, o trabalho proposto por Abraham e Nair (ABRAHAM; NAIR, 2020) visou na utilização de um *ensemble* de CNNs pré-treinadas na ImageNet (DENG et al., 2009) juntamente com o classificador *BayesNet* para a classificação de COVID-19 a partir de imagens de raio-x. Foram utilizadas cinco CNNs, sendo elas a Squeezenet, Darknet-53, MobilenetV2, Xception e Shufflenet. A saída da camada totalmente

conectada de cada rede, com 1000 valores, foi combinada com as das demais redes formando matrizes de tamanho $n \times 1000 \times m$, onde n é o número de imagens de entrada e m é a quantidade de CNNs utilizadas. O método foi aplicado para duas bases de dados públicas, onde a primeira era composta de 453 imagens de COVID-19 e 497 imagens de ausência de COVID-19. Nessa base o método obteve uma AUC de 0.963 e uma acurácia de 91.16%. A segunda base de imagens foi composta com 71 imagens de COVID-19 e 7 imagens de ausência da doença, alcançando um desempenho de 0.911 de AUC e uma acurácia de 97.44%.

O trabalho proposto por Kathamuthu et.al. (KATHAMUTHU et al., 2023) realizou o treinamento de diversas CNNs com o intuito de verificar o desempenho de cada uma na classificação de COVID-19. Foram utilizadas as arquiteturas DenseNet-121, ResNet-50, Inception V3, Exception, VGG16 e VGG19 para o treinamento de duas classes: COVID-19 e ausência de COVID-19. Os resultados das classificações foram avaliados a partir de diversas métricas, como acurácia, medida F e AUC, e o modelo que obteve os melhores resultados foi a VGG16, com uma acurácia de 98%.

A utilização de algoritmos de pré-processamento para a melhora de desempenho de uma CNN foi apresentada por Ebenezer et.al. (Shamila Ebenezer et al., 2022). Nesse trabalho foram utilizadas diversos algoritmos de pré-processamento de imagens para verificar os efeitos que o tratamento nas imagens tomográficas de COVID-19 podiam causar ao treinamento de uma CNN. Para isso, foram montadas bases de imagens utilizando os algoritmos de transformada de Laplace, transformada de Wavelet, correção gama adaptativa e equalização de histograma de contraste adaptativa, do inglês *Contrast limited adaptive histogram equalization* (CLAHE). A CNN EfficientNet foi treinada utilizando essas bases pré-processadas e o algoritmo que forneceu o melhor desempenho foi o CLAHE, proporcionando uma acurácia de 94.56%, precisão de 95%, *recall* de 91% e medida F de 93%.

3.3 CNNs Especializadas

Apesar do uso de CNNs pré-treinadas juntamente com técnicas de *transfer learning* oferecerem bons resultados, alguns autores investigaram maneiras de construir modelos de CNN especializadas na classificação de COVID-19, ou seja, arquiteturas voltadas especialmente para obter o melhor desempenho nessa tarefa. O trabalho de Islam et.al (ISLAM et al., 2022) propôs a arquitetura de CNN chamada de “COV-RadNet” para a detecção de COVID-19 em imagens radiográficas pulmonares em meio a outros tipos de doenças como pneumonia viral, opacidade pulmonar e pulmões saudáveis. Para isso foi utilizada uma base de imagens radiográficas pulmonares contendo imagens representativas dessas quatro classes e foram utilizadas técnicas de *data augmentation* para ampliar a base de imagens. Foi utilizado a abordagem de transferência de aprendizado utilizando quatro modelos de CNN pré-treinadas para auxiliar o treinamento da CNN proposta, sendo elas: VGG16, VGG19, ResNet-152 e ResNet-101. O modelo proposto foi capaz de alcançar 97% de acurácia para as quatro classes da base de imagens, 99.5% de acurácia ao classificar entre COVID-19, pneumonia viral e saudável e, por fim, 99.72% de acurácia ao classificar somente entre COVID-19 e pulmões saudáveis.

Nesse mesmo sentido, o trabalho proposto por Kedia et.al (KEDIA; ANJUM; KATARYA, 2021) apresentou um modelo de CNN especializada para a classificação de imagens radiográficas torácicas de COVID-19, utilizando técnicas de *transfer learning* e *ensemble* de modelos a partir das CNNs VGG19 e DenseNet121, ambas pré-treinadas na base de imagens da ImageNet. Essa metodologia alcançou 99.71% de acurácia na classificação entre duas classes: COVID-19 e ausência de COVID-19.

3.4 Considerações Sobre os Trabalhos Relacionados

Neste capítulo, foram sumarizados trabalhos que fizeram o uso de técnicas baseadas em análise de características, CNNs consolidadas e CNNs especializadas. Essas abordagens utilizaram diferentes técnicas e metodologias, mas obtendo resultados relevantes para o contexto de classificação de COVID-19, especialmente utilizando imagens tomográficas pulmonares. Um resumo dos melhores resultados obtidos desses trabalhos podem ser observados nas Tabelas 3.1, 3.2 e 3.3.

Tabela 3.1: Resumo dos melhores resultados para os trabalhos utilizando estratégia de análise de características.

Referência	Abordagem	ACC
(SINGH et al., 2021)	<i>HSGO e SVM</i>	99,65%
(RAJPAL et al., 2021)	<i>handpicked features, PCA, feed forward neural network</i>	94,40%

Tabela 3.2: Resumo dos melhores resultados para os trabalhos utilizando estratégias baseadas em CNNs consolidadas.

Referência	Abordagem	ACC
(KATHAMUTHU et al., 2023)	<i>VGG16</i>	98,00%
(ABRAHAM; NAIR, 2020)	<i>Ensemble de características</i>	97,44%
(Shamila Ebenezer et al., 2022)	<i>Pré-processamento, CLAHE e EfficientNet</i>	94,56%

Tabela 3.3: Resumo dos melhores resultados para os trabalhos utilizando estratégias baseadas em CNNs especializadas.

Referência	Abordagem	ACC
(ISLAM et al., 2022)	<i>COV-RadNet</i>	99,72%
(KEDIA; ANJUM; KATARYA, 2021)	<i>CovNet-19</i>	99,71%

A partir dos resultados dos trabalhos apresentados nesse capítulo é possível observar o sucesso das técnicas de *transfer learning* e *deep learning* para a classificação de COVID-19, principalmente para estratégias utilizando CNNs especializadas, em que houve os destaques de desempenho e, mais especificamente, no trabalho descrito por Islam et.al.(ISLAM et al., 2022) que obteve uma acurácia de 99.72%. Para abordagens utilizando análise de características foram observados resultados tão relevantes quanto

os anteriores, chegando a 99.65% de acurácia, como mostrou o trabalho proposto por Singh et.al(SINGH et al., 2021). Vale notar que esse tipo de estratégia tem a vantagem da redução do espaço de características com resultados tão relevantes quanto outras estratégias. Por fim, trabalhos utilizando estratégias baseadas em CNNs consolidadas também obtiveram bons resultados, como no trabalho feito por Kathamuthu et.al(ABRAHAM; NAIR, 2020) que alcançou uma acurácia de 98%.

Capítulo 4

Metodologia


Neste capítulo, o método proposto e as informações das imagens utilizadas para realizar os experimentos são apresentados com detalhes, além das métricas utilizadas para avaliar o poder discriminativo de cada combinação de técnicas. Também, o conjunto de pacotes de software e o ambiente de desenvolvimento para a execução de cada teste são indicados ao final desse capítulo.

4.1 Estruturação do Método: Visão Geral

O método foi estruturado em três fases principais: extração de *deep learned features* das imagens radiográficas pulmonares de COVID-19; ranqueamento e seleção de *deep learned features*; classificação e identificação das melhores combinações. A primeira fase visou organizar e definir os vetores de *deep learned features* obtidos de redes neurais convolucionais. A segunda fase explorou o uso combinado do algoritmo ReliefF (ROBNIK-SIKONJA; KONONENKO, 2003) com o método evolutivo bGWO (WAHAB; NEFTI-MEZIANI; ATYABI, 2015b), estratégia para identificar as *features* mais relevantes no processo de classificação das imagens COVID-19. Por fim, na terceira fase, cada conjunto de *deep learned features* foi analisado coletando os desempenhos conquistados com relevantes algoritmos de classificação. Um resumo

do método proposto está na Figura 4.1 e os detalhes de cada fase estão nas próximas seções.

Figura 4.1: Ilustração do método proposto contemplando as fases: 1) Extração de características (*deep learned features*); 2) Ranqueamento e seleção de características (*deep learned features*); e, 3) Classificação.




Fonte: Elaborada pelo autor.

4.1.1 Base de Dados

O método foi aplicado em imagens radiográficas de COVID-19 de domínio público, conforme informações descritas por (COHEN; MORRISON; DAO, 2020). Essa base foi constituída a partir de diversas fontes públicas e não infringe a confidencialidade dos pacientes, conforme destacado em (COHEN; MORRISON; DAO, 2020). As fontes utilizadas pelos autores foram os websites: Radiopaedia.org, The Italian

Society of Medical and Interventional Radiology e Figure1.com. A base é composta por 2040 imagens, sendo que 438 delas são de pulmões com COVID-19 e 1602 de pulmões saudáveis. Os detalhes estão disponíveis em (COHEN; MORRISON; DAO, 2020) e alguns exemplos de imagens estão ilustrados na Figura 4.2.

Figura 4.2: Exemplos de amostras dos contextos de imagens exploradas neste projeto: (A) Covid-19; (B) Saudável.



Fonte: (COHEN; MORRISON; DAO, 2020).

4.2 Fase 1: Extração de características (*deep learned features*)

A primeira fase está relacionada com a definição de *deep learned features* das distintas redes convolucionais. Para tanto, a análise das imagens de COVID-19 por meio do aprendizado profundo ocorreu aplicando os modelos AlexNet, ResNet-50, DenseNet-201 e EfficientNet-b0 (KRIZHEVSKY; SUTSKEVER; HINTON, 2012a; HE et al., 2016), pré-treinados na base ImageNet (HE et al., 2016), caracterizando o processo de *transfer learning*. Neste projeto, esses modelos foram escolhidos observando diferentes princípios de arquiteturas de CNN, bem como o sucesso já con-

quistado nos mais diferentes tipos de imagens. O uso dessas arquiteturas por meio de *transfer learning* permite investigar as melhores associações para minimizar situações de *overfitting* ou custos computacionais com a etapa de treinamento total da rede, por exemplo. O modelo AlexNet consiste em cinco camadas convolucionais, três camadas de *pooling*, duas camadas totalmente conectadas e uma camada *softmax* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012b). Essa arquitetura utilizou esquemas de regularização *dropout* e *Rectified Linear Unit* (ReLU) para reduzir *overfitting*, bem como *Local Response Normalization* (LRN) para minimizar o problema do gradiente de fuga. Adicionalmente, desde a vitória da rede AlexNet na competição ILSVRC2012 (KRIZHEVSKY; SUTSKEVER; HINTON, 2012a), a arquitetura *Residual Neural Network* ou ResNet (HE et al., 2016) tem sido avaliada como um dos trabalhos mais inovadores em visão computacional, por garantir o treinamento da rede com centenas ou até milhares de camadas sem incorrer no problema do gradiente de fuga. Além disso, o modelo EfficientNet pôde alcançar grandes resultados a partir de sua estratégia de balanceamento de abordagens de otimização para a formação de uma rede eficiente e precisa, sendo relevante também no âmbito de aplicação para classificação de imagens médicas (TAN; LE, 2020). Por fim, foi utilizado o modelo DenseNet, que utiliza uma abordagem inovadora de conexões entre as camadas, capaz de obter resultados significativos para a classificação de imagens médicas (CHAUHAN; PALIVELA; TIWARI, 2021; KONG; CHENG, 2022; WANG et al., 2021).

É importante destacar que as escolhas das camadas foram a partir da proposta descrita por (SANTOS; PONTI, 2019). Dentre as camadas selecionadas para o processo de investigação (*max_pooling2d_1*, *activation_4_relu*, *activation_48_relu*, *activation_49_relu* e *avg_pool*), a camada *avg_pool* foi a que se destacou em termos de desempenhos. Essa condição também foi apontada por (SANTOS; PONTI, 2019), mesmo em um contexto totalmente diferente do explorado em nossa estratégia, com a indicação de que as *deep learned features* fornecidas pelas últimas camadas estão as-

sociados com descritores globais e que podem ser mais pertinentes para um processo de classificação. Logo, a camada *avg_pool*, foi escolhida para ser investigada em detalhes no contexto de imagens radiográficas de COVID-19 para os modelos ResNet-50, DenseNet-201 e EfficientNet-b0, com 2048, 1920 e 1280 descritores obtidos dessa camada para cada rede, respectivamente. Em relação ao modelo AlexNet, as *deep learned features* aqui explorados foram da camada *max_pooling_3*, com 9216 valores.

4.3 Fase 2: Ranqueamento e seleção das *deep learned features*

Os vetores de *deep learned features* obtidos na fase 1 foram analisados aplicando um processo com dois estágios de seleção de atributos, a fim de diminuir a dimensionalidade do espaço de *deep learned features* e identificar a melhor combinação dentre os descritores disponíveis em cada subconjunto (HSU; HSIEH; LU, 2011; MENGDI et al., 2018; CANDELERO et al., 2020). O primeiro estágio consiste em ranquear cada entrada por meio do algoritmo ReliefF (ROBNIK-SIKONJA; KONONENKO, 2003) e aplicar um limiar para reduzir o número de possíveis combinações. Os limiares testados foram definidos a partir de 10 *deep learned features* mais bem ranqueadas, com incrementos de 10 atributos, conforme sugerido por (RIBEIRO et al., 2019). O maior conjunto será limitado em 100 *deep learned features* (RIBEIRO et al., 2019).

A partir disso, o segundo estágio será direcionado para encontrar as melhores combinações existentes em cada subconjunto reduzido, via seleção *wrapper* com a meta-heurística bGWO, baseado em comportamento animal, mais especificamente, na estratégia de caça de lobos cinzentos (EMARYA; ZAWBAAB; HASSANIENA, 2016). Essa estratégia forneceu os melhores resultados na seleção de atributos em comparação com outros métodos (WAHAB; NEFTI-MEZIANI; ATYABI, 2015b).

4.4 Fase 3: Classificação e Avaliação de Desempenho

O poder discriminativo de cada solução foi realizado explorando dez classificadores com diferentes estratégias, tais como os baseados em: árvores de decisão, com o algoritmo *Random Tree*, que constrói uma árvore a partir de k atributos escolhidos aleatoriamente em cada nó, e o algoritmo *Random Forest*, que constrói uma floresta com árvores aleatórias; *Lazy Learning*, com o algoritmo *IBk*, que utiliza os k vizinhos mais próximos para classificação, e o algoritmo k^* , no qual a classe de uma instância de teste é baseada na similaridade obtida em relação às instâncias de treinamento, usando o princípio de vizinho mais próximo fundamentado em entropia; baseados em função, com o algoritmo *SMO*, que usa a otimização sequencial mínima para treinar um classificador de vetores de suporte, e o algoritmo *Logistic*, que utiliza um modelo de regressão logística multinomial e regularização *Ridge*; baseado na teoria de Bayes, com o algoritmo *NaiveBayes*, no qual os valores de precisão do estimador numérico são escolhidos com base na análise dos dados de treinamento, e o algoritmo *Bayes-Net*, que utiliza vários algoritmos de busca e medidas de qualidade para o processo de classificação; meta-aprendizado, com o algoritmo *LogitBoost*, que realiza regressão logística aditiva e pode lidar com problemas de múltiplas classes, e o algoritmo *Rotation Forest*, que usa subespaços aleatórios e componentes principais para criar um *ensemble* de árvores de decisão. A utilização dos dez classificadores se deu a partir do pacote *Weka* (FRANK; HALL; WITTEN, 2016). O processo de avaliação com cada algoritmo de classificação foi realizado a partir da estratégia de *cross-validation k-fold*, com $k = 10$, e métricas comumente disponíveis na literatura, tais como acurácia, medida F e área sob a curva ROC (AUC) (CHIU, 2012).

4.5 Ferramentas e Ambiente de Desenvolvimento

A implementação do método foi realizada considerando diferentes pacotes de software. Os algoritmos das redes AlexNet, ResNet-50, DenseNet-201 e EfficientNet-b0 foram implementados em linguagem *Python*, via biblioteca *Pytorch*. A plataforma *Weka* versão 3.8.4 foi utilizada a coleta de resultados das medidas de acurácia, medida F e AUC, a partir da execução da fase 3 da estratégia aqui descrita. Adicionalmente, a validação da melhor combinação será por meio de comparações de desempenhos com resultados coletados de trabalhos correlatos e dos fornecidos pelas redes AlexNet, ResNet-50, DenseNet-201 e EfficientNet-b0 (aplicação da arquitetura completa de cada rede), exploradas também via linguagem *Python* e biblioteca *Pytorch*. A execução da proposta foi realizada em um notebook com processador Intel Core i5-9300H de 2,4GHz, 8 GB de memória RAM e placa de vídeo NVIDIA GeForce 1050.

Capítulo 5


Resultados

Neste capítulo, os resultados obtidos via aplicação da metodologia proposta são apresentados com as informações das principais combinações obtidas no contexto de imagens radiográficas pulmonares de COVID-19. Além disso, os resultados obtidos por meio da aplicação direta de cada rede também são indicados, a fim de proporcionar uma visão geral sobre a relevância da metodologia aqui investigada.

5.1 Indicações das melhores combinações

A metodologia proposta foi aplicada sobre o conjunto de imagens radiográficas de COVID-19, conforme descrições apresentadas no Capítulo 2. Na Figura 5.1 são indicadas as médias das acurácias, calculadas entre os dez classificadores utilizados para o processo de distinção de *deep learned features*, para cada camada definida no processo de investigação e considerando vetores com números distintos de *deep learned features*, conforme nossa proposta. Os melhores resultados foram definidos combinando classificador e métodos para selecionar as *deep learned features* mais relevantes dentre as mais bem posicionadas. Os ranqueamentos das *deep learned features* foram determinados por meio do algoritmo ReliefF e posteriormente selecionados pelo algoritmo bGWO.

Figura 5.1: Taxas médias de acurácias obtidas a partir de diferentes classificadores, camadas e total de *deep learned features*.



Fonte: Elaborado pelo autor.

A partir dos resultados apresentados previamente (Figura 5.1), nota-se que a melhor combinação observada para a CNN ResNet-50 via *avg_pool* conseguiu fornecer uma acurácia média de 93,93%, explorando 100 atributos. Para a CNN EfficientNet foi observado uma acurácia média de 94,39% utilizando 90 características da camada *avg_pool*. Esse taxa de acurácia é menor do que o melhor desempenho observado com os atributos da camada *max_pooling_3* da CNN AlexNet, com 94,92% e explorando 90 *deep learned features*. Por fim, a maior acurácia média foi observada na camada *avg_pool* da CNN Densenet, com 95,42% utilizando 30 *deep learned features*. A partir disso, é possível ilustrar a quantidade exata de *deep learned features* que foram selecionadas pelo algoritmo bGWO para conquistar cada solução apresentada na Figura 5.1. Esse resultado está na Tabela 5.1, com as indicações dos totais de atributos obtidos no segundo estágio de seleção e que proporcionaram as melhores soluções.

Observando os resultados apresentados na Tabela 5.1, é possível verificar que a melhor combinação com a camada *avg_pool* usou somente 27 *deep learned features* das 30 mais bem ranqueadas por meio do algoritmo ReliefF, indicado o potencial da

Tabela 5.1: Total de *deep learned features* selecionadas pelo algoritmo bGWO dentre as mais bem ranqueadas pelo ReliefF, considerando o intervalo de 10 a 100 atributos e diferentes camadas utilizadas no processo de investigação.

Total de <i>deep learned features</i> ranqueadas pelo ReliefF	Total de <i>deep learned features</i> selecionadas pelo bGWO			
	avg_pool (ResNet-50)	max_pooling_3 (AlexNet)	avg_pool (Densenet)	avg_pool (Efficientnet)
10	9	7	10	9
20	9	12	20	18
30	23	19	27	27
40	17	23	32	35
50	28	29	39	44
60	28	32	44	52
70	34	33	52	61
80	41	38	58	68
90	42	40	67	74
100	51	44	73	82

metodologia desenvolvida com dois estágios de seleção de atributos. Considerando esse cenário, é importante destacar que a melhor solução foi conquistada com um conjunto relevante de atributos, reduzindo em aproximadamente 98,59% o total de descritores inicialmente disponíveis na camada. Essa é uma importante contribuição da metodologia aqui proposta.

Por fim, para identificar o classificador que se destacou em cada melhor resultado, nas Tabelas 5.2 e 5.3 estão os valores das métricas acurácia, medida F e AUC. Considerando a taxa de acurácia como referência, o desempenho mais relevante em cada teste foi destacado em negrito. Nota-se que os classificadores *Logistic* e SMO forneceram os maiores valores de acurácias nas camadas *avg_pool* e *max_pooling_3*, respectivamente. Destes, a menor acurácia foi de 95,98% (com classificador *Logistic*) e a maior foi de 97,60% (27 atributos da camada *avg_pool* com o classificador SMO), indicando, portanto, a melhor combinação observada via nossa proposta. Nesse caso, a medida F foi de 0,976 e uma AUC de 0,967, permitindo verificar a qualidade dos resultados.

Para verificar a relevância da melhor solução obtida com nossa proposta, as redes Alexnet, Resnet-50, Efficientnet e Densenet foram aplicadas diretamente (aplicação da arquitetura completa de cada rede) sobre a base de imagens radiográficas de COVID-19 a fim de identificar suas capacidades discriminativas. Para tanto, as redes foram treinadas com 50 épocas, sendo que as *Fully Connected Layers* foram ajustadas para

Tabela 5.2: Resultados obtidos com cada classificador para a solução que forneceu a maior média de acurácia na camada *avg_pool* da CNN Resnet-50.

Classificador	Acurácia	Medida F	AUC
Random Tree	90,44%	0,904	0,850
Random Forest	95,69%	0,957	0,985
IBk	95,83%	0,958	0,925
kStar	92,55%	0,921	0,969
Logit Boost	92,50%	0,924	0,969
Rotation Forest	95,39%	0,954	0,984
SMO	95,34%	0,959	0,938
Logistic	96,03%	0,960	0,987
Naive Bayes	92,55%	0,928	0,976
Bayes Net	92,40%	0,927	0,974
Média	93,93%	0,939	0,956

Tabela 5.3: Resultados conquistados por cada classificador para a solução com a maior média de acurácia na camada *max_pooling_3* da CNN Alexnet.

Classificador	Acurácia	Medida F	AUC
Random Tree	91,62%	0,915	0,868
Random Forest	96,13%	0,961	0,989
IBK	96,32%	0,963	0,932
kStar	89,95%	0,890	0,976
Logit Boost	95,78%	0,957	0,984
Rotation Forest	96,32%	0,963	0,986
SMO	97,35%	0,974	0,961
Logistic	96,81%	0,968	0,988
Naive Bayes	94,12%	0,943	0,978
Bayes Net	94,80%	0,949	0,985
Média	94,92%	0,948	0,965

Tabela 5.4: Resultados obtidos com cada classificador para a solução que forneceu a maior média de acurácia na camada *avg_pool* da CNN Densenet.

Classificador	Acurácia	Medida F	AUC
Random Tree	94,95%	0,949	0,924
Random Forest	97,11%	0,971	0,993
IBk	96,47%	0,964	0,938
kStar	84,12%	0,849	0,960
Logit Boost	96,37%	0,964	0,989
Rotation Forest	97,11%	0,971	0,992
SMO	97,60%	0,976	0,967
Logistic	97,30%	0,973	0,993
Naive Bayes	96,52%	0,966	0,992
Bayes Net	96,67%	0,967	0,992
Média	95,42%	0,955	0,974

Tabela 5.5: Resultados obtidos com cada classificador para a solução que forneceu a maior média de acurácia na camada *avg_pool* da CNN Efficientnet.

Classificador	Acurácia	Medida F	AUC
Random Tree	90,00%	0,900	0,853
Random Forest	95,34%	0,953	0,987
IBk	94,75%	0,947	0,912
kStar	94,02%	0,939	0,975
Logit Boost	92,94%	0,929	0,969
Rotation Forest	94,80%	0,948	0,983
SMO	95,88%	0,959	0,940
Logistic	95,98%	0,960	0,986
Naive Bayes	94,61%	0,947	0,980
Bayes Net	95,59%	0,957	0,987
Média	94,39%	0,944	0,957

somente duas saídas, com o propósito de distinguir as classes COVID-19 e Saudável. Nesse cenário, os melhores resultados foram acurácias de 94,00% (Resnet-50), 95,59% (Alexnet), 79,66% (Densenet) e 74,02% (Efficientnet), indicando desempenhos menores do que o conquistado com a melhor solução obtida com a execução da nossa proposta: 97,60% explorando somente 27 atributos da camada *avg_pool* e com o uso combinado de ReliefF, bGWO e classificador SMO. Esse fato indica outra importante contribuição desse estudo, além de evidenciar que foi possível definir resultados relevantes por meio de *transfer learning*.

Por fim, é importante verificar se os resultados obtidos também estão entre os disponíveis na literatura direcionada para esse tipo de aplicação. Técnicas envolvendo estratégias distintas têm sido exploradas para investigar padrões em imagens radiográficas de COVID-19, com testes realizados diferentes bases e números de classes. No entanto, nenhum deles explorou o modelo de associações apresentado em nosso trabalho. Assim, uma visão geral ilustrativa é importante para mostrar a qualidade do nosso estudo, como indicada na Tabela 5.6.

Tabela 5.6: Principais resultados na classificação de imagens pulmonares de COVID-19 na literatura.

Referência	Abordagem	Acurácia
(ISLAM et al., 2022)	<i>COV-RadNet</i>	99,72%
(KEDIA; ANJUM; KATARYA, 2021)	<i>CovNet-19</i>	99,71%
(SINGH et al., 2021)	<i>HSGO e SVM</i>	99,65%
(KATHAMUTHU et al., 2023)	<i>VGG16</i>	98,00%
Proposto	Densenet, ReliefF, bGWO e SMO	97,60%
(ABRAHAM; NAIR, 2020)	<i>Ensemble de características</i>	97,44%
(Shamila Ebenezer et al., 2022)	<i>Pré-processamento, CLAHE e EffitientNet</i>	94,56%
(RAJPAL et al., 2021)	<i>handpicked features, PCA, feed forward neural network</i>	94,40%

Mesmo que não seja possível realizar uma comparação direta entre todas as estratégias, visto que as bases de imagens e técnicas utilizadas nos trabalhos disponíveis na literatura são diferentes, este tipo de indicação mostra que a metodologia proposta foi capaz de fornecer resultados dentre os disponíveis na literatura (Shamila Ebenezer et al., 2022; RAJPAL et al., 2021). É importante destacar que, apesar da nossa proposta fornecer, em alguns casos, taxas de acurácias menores em comparação aos valores

indicados por outras propostas (ISLAM et al., 2022; KEDIA; ANJUM; KATARYA, 2021; SINGH et al., 2021; KATHAMUTHU et al., 2023; ABRAHAM; NAIR, 2020) a vantagem apresentada está em utilizar poucos atributos, simplificando a construção do modelo para classificar possíveis padrões, além de tornar o conhecimento mais compreensível aos especialistas. Estes fatos são contribuições importantes para a comunidade interessada no estudo e desenvolvimento de modelos baseados no uso combinado de estratégias *deep learned*, via *transfer learning* para o reconhecimento de padrões de COVID-19 a partir de imagens radiográficas pulmonares.

Capítulo 6

Conclusões

Neste trabalho, foi proposto um estudo detalhado envolvendo o uso combinado de estratégias *deep learned features*, via *transfer learning* para classificar imagens radiográficas pulmonares de COVID-19. Os atributos foram obtidos das redes Alexnet, Resnet-50, Densenet e Efficientnet. A avaliação de cada subconjunto de *deep learned features* foi por meio da aplicação do uso combinado de ReliefF e bGWO. Os resultados foram vetores com um número reduzido de atributos, os quais foram testados por diferentes classificadores. Assim, a melhor combinação foi identificada combinando 27 *deep learned features* da camada *avg_pool* da CNN Densenet com o classificador SMO, o que produziu uma acurácia de 97,60%, medida F de 0,976 e uma AUC de 0,967. É importante destacar que essa melhor solução representa um conjunto relevante de atributos, reduzindo em aproximadamente 98,59% o total de descritores inicialmente disponíveis na camada, indo de 1920 características para somente 27. Essa é uma importante contribuição da metodologia aqui proposta, comprovada na comparação com as acurácias fornecidas pelas redes AlexNet (95,59%), ResNet-50 (94,00%), Densenet (79,66%) e Efficientnet (74,02%). Na visão geral em relação aos desempenhos fornecidos por trabalho correlatos, foi possível depreender que nossa proposta indicou resultados interessantes, com desempenhos intermediários aos disponíveis na literatura especializada. Apesar disso, acreditamos que uma contribuição do trabalho

foi detalhar as informações e condições dos melhores resultados, fato que colabora para o desenvolvimento de modelos computacionais mais compreensíveis e eficientes no contexto de detecção e reconhecimento de padrões de imagens radiográficas de COVID-19.

Para trabalhos futuros, podem ser estudadas outras arquiteturas de redes, incluir mais algoritmos bioinspirados e desenvolver uma metodologia para identificar as principais *deep learned features* nas regiões geradas via *Gradient-weighted Class Activation Mapping (Grad-CAM)* e *local interpretable model-agnostic explanations (LIME)*. Também, é interessante explorar as soluções por meio de um *ensemble* de classificadores.

6.1 Contribuições Obtidas

As principais contribuições obtidas com o desenvolvimento do projeto foram: a) definições de modelos baseados no uso combinado de estratégias *deep learned*, via *transfer learning*, para o reconhecimento de padrões de COVID-19 em imagens radiográficas pulmonares; b) identificação da melhor associação para distinguir imagens representativas das classes saudável e COVID-19, com detalhes sobre as combinações entre classificador, método de seleção e tipos de *deep learned features*.

6.2 Divulgação e Menção Honrosa

- Lopes, T.; Neves, L. A. Deep learned features por transfer learning: uma análise baseada na otimização binária de lobos cinza para estudar imagens de COVID-19, XXXIII Congresso de Iniciação Científica da Unesp (CIC), 2021;

- Recebimento de Menção Honrosa: dentre os mais de 2500 trabalhos de Iniciação Científica, este trabalho foi selecionado como um dos 250 melhores para compor a 2ª fase do XXXIII e recebeu a menção honrosa por essa realização.

Referências

ABBAS, A.; ABDELSAMEA, M. M.; GABER, M. M. Classification of covid-19 in chest x-ray images using detrac deep convolutional neural network. *Applied Intelligence*, 2020.

ABDAR, M.; ZOMORODI-MOGHADAM, M.; ZHOU, X.; GURURAJAN, R.; TAO, X.; BARUA, P. D.; GURURAJAN, R. A new nested ensemble technique for automated diagnosis of breast cancer. *Pattern Recognition Letters*, v. 132, p. 123–131, 2020. ISSN 0167-8655. Multiple-Task Learning for Big Data (MTL4BD). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167865518308766>>.

ABRAHAM, B.; NAIR, M. S. Computer-aided detection of covid-19 from x-ray images using multi-cnn and bayesnet classifier. *Biocybernetics and Biomedical Engineering*, v. 40, n. 4, p. 1436–1445, 2020. ISSN 0208-5216. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0208521620300954>>.

ACEÑA, V.; Martín de Diego, I.; R. Fernández, R.; M. Moguerza, J. Minimally overfitted learners: A general framework for ensemble learning. *Knowledge-Based Systems*, v. 254, p. 109669, 2022. ISSN 0950-7051. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950705122008450>>.

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, L.; ALNAJJAR, F.; JASSMI, H.; GOCHOO, M.; KHAN, W.; SERHANI, M. Performance evaluation of deep cnn-based crack detection and localization techniques for concrete structures. *Sensors*, v. 21, p. 1688, 03 2021.

APOSTOLOPOULOS, I.; AZNAOURIDIS, S.; TZANI, M. Extracting possibly representative covid-19 biomarkers from x-ray images with deep learning approach and image data related to pulmonary diseases. *Journal of Medical and Biological Engineering*, v. 40, 05 2020.

APOSTOLOPOULOS, I.; TZANI, M. Covid-19: Automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Australasian physical engineering sciences in medicine / supported by the Australasian College of*

Physical Scientists in Medicine and the Australasian Association of Physical Sciences in Medicine, v. 43, 03 2020.

BARSTUGAN, M.; OZKAYA, U.; OZTURK, S. *Coronavirus (COVID-19) Classification using CT Images by Machine Learning Methods*. 2020.

BHARADIYA, J. Convolutional neural networks for image classification. *International Journal of Innovative Research in Science Engineering and Technology*, v. 8, p. 673, 05 2023.

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

CANDELERO, D.; ROBERTO, G. F.; NASCIMENTO, M. Z. do; ROZENDO, G. B.; NEVES, L. A. Selection of cnn, haralick and fractal features based on evolutionary algorithms for classification of histological images. In: *2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. [S.l.]: IEEE, 2020. p. 2709–2716.

CAO, M.-T.; NGUYEN, N.-M.; CHANG, K.-T.; TRAN, X.-L.; HOANG, N.-D. Automatic recognition of concrete spall using image processing and metaheuristic optimized logitboost classification tree. *Advances in Engineering Software*, v. 159, p. 103031, 2021. ISSN 0965-9978. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0965997821000600>.

CESSIE, S. L.; HOUWELINGEN, J. C. V. Ridge estimators in logistic regression. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, [Wiley, Royal Statistical Society], v. 41, n. 1, p. 191–201, 1992. ISSN 00359254, 14679876. Disponível em: <http://www.jstor.org/stable/2347628>.

CHAHAR, V.; JAISWAL, A.; GIANCHANDANI, N.; SINGH, D.; KAUR, M. Classification of the covid-19 infected patients using densenet201 based deep transfer learning. *Journal of biomolecular Structure Dynamics*, v. 39, 07 2020.

CHANTAR, H.; MAFARJA, M.; ALSAWALQAH, H.; HEIDARI, A. A.; ALJARAH, I.; FARIS, H. Feature selection using binary grey wolf optimizer with elite-based crossover for arabic text classification. *Neural Computing and Applications*, v. 32, 08 2020.

CHAUHAN, T.; PALIVELA, H.; TIWARI, S. Optimization and fine-tuning of densenet 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>.

CHIU, D. Book review: "pattern classification", r. o. duda, p. e. hart and d. g. stork, second edition. *International Journal of Computational Intelligence and Applications*, v. 01, 01 2012.

CHOI, Y. Covid-19 disease and treatment of covid-19. *Biomedical Journal of Scientific Technical Research*, v. 39, 10 2021.

- CLEARY, J. G.; TRIGG, L. E. K*: An instance-based learner using an entropic distance measure. In: *12th International Conference on Machine Learning*. [S.l.: s.n.], 1995. p. 108–114.
- COHEN, J. P.; MORRISON, P.; DAO, L. *COVID-19 Image Data Collection*. 2020.
- DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; LI, F.-F. Imagenet: a large-scale hierarchical image database. In: . [S.l.: s.n.], 2009. p. 248–255.
- EMARYA, E.; ZAWBAAB, H. M.; HASSANIENA, A. E. Binary grey wolf optimization approaches for feature selection. *Neurocomputing*, Elsevier, p. 371–381, 2016.
- FAN, Q.; BI, Y.; XUE, B.; ZHANG, M. Genetic programming for feature extraction and construction in image classification. *Applied Soft Computing*, v. 118, p. 108509, 2022. ISSN 1568-4946. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494622000527>.
- FAWCETT, T. Introduction to roc analysis. *Pattern Recognition Letters*, v. 27, p. 861–874, 06 2006.
- FRANK, E.; HALL, M. A.; WITTEN, I. H. The weka workbench. online appendix for "data mining: Practical machine learning tools and techniques". *Morgan Kaufmann, Fourth Edition*, 2016.
- 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>.
- GONZALEZ, R.; WOODS, R. *Digital Image Processing*. Pearson, 2018. ISBN 9780133356724. Disponível em: <https://books.google.com.br/books?id=0F05vgAACAAJ>.
- HAEGEMANS, T.; SNOECK, M.; LEMAHIEU, W. Towards a precise definition of data accuracy and a justification for its measure. In: . [S.l.: s.n.], 2016.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 770–778.
- HEATON, J. Ian goodfellow, yoshua bengio, and aaron courville: Deep learning: The mit press, 2016, 800 pp, isbn: 0262035618. *Genetic Programming and Evolvable Machines*, v. 19, 10 2017.
- 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. Learning multiple layers of representation. *Trends in cognitive sciences*, v. 11, p. 428–34, 11 2007.

HOCHREITER, S. The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, v. 6, p. 107–116, 04 1998.

HSU, H.; HSIEH, C. W.; LU, M. Hybrid feature selection by combining filters and wrappers. *Expert Systems with Applications*, v. 38, n. 7, p. 8144–8150, 2011.

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.

ISLAM, M. K.; HABIBA, S. U.; KHAN, T. A.; TASNIM, F. Cov-radnet: A deep convolutional neural network for automatic detection of covid-19 from chest x-rays and ct scans. *Computer Methods and Programs in Biomedicine Update*, v. 2, p. 100064, 2022. ISSN 2666-9900. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666990022000155>>.

JIN, W.; DONG, S.; DONG, C.; YE, X. A hybrid ensemble model for differential diagnosis between covid-19 and common viral pneumonia by chest x-ray radiograph. *Computers in Biology and Medicine*, v. 131, p. 104252, 02 2021.

JUEZ-GIL, M.; ARNAIZ-GONZÁLEZ, Á. Alvar; RODRÍGUEZ, J. J.; LÓPEZ-NOZAL, C.; GARCÍA-OSORIO, C. Rotation forest for big data. *Information Fusion*, v. 74, p. 39–49, 2021. ISSN 1566-2535. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1566253521000634>>.

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.

KATHAMUTHU, N. D.; SUBRAMANIAM, S.; LE, Q. H.; MUTHUSAMY, S.; PANCHAL, H.; SUNDARARAJAN, S. C. M.; ALRUBAIE, A. J.; ZAHRA, M. M. A. A deep transfer learning-based convolution neural network model for covid-19 detection using computed tomography scan images for medical applications. *Advances in Engineering Software*, v. 175, p. 103317, 2023. ISSN 0965-9978. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0965997822002186>>.

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>>.

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>>.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. Imagenet classification with deep convolutional neural networks. *Neural Information Processing Systems*, v. 25, 01 2012.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105.

LATOUR, M. Analyse de sentiments dans les textes économiques : un exemple d’application chez reportlinker. 04 2021.

LE, Q. Building high-level features using large scale unsupervised learning. In: . [S.l.: s.n.], 2013. p. 8595–8598.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436–44, 05 2015.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.

LI, L.; ZHOU, Z.; BAI, N.; WANG, T.; XUE, K.-H.; SUN, H.; HE, Q.; CHENG, W.; MIAO, X. Naive bayes classifier based on memristor nonlinear conductance. *Microelectronics Journal*, v. 129, p. 105574, 2022. ISSN 0026-2692. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0026269222002038>>.

LI, W.; LI, C.; JIANG, L. Learning from crowds with robust logistic regression. *Information Sciences*, v. 639, p. 119010, 2023. ISSN 0020-0255. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025523005959>>.

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>>.

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

MAO, Z.; SU, Y.; XU, G.; WANG, X.; HUANG, Y.; YUE, W.; SUN, L.; XIONG, N. Spatio-temporal deep learning method for adhd fmri classification. *Information Sciences*, vol. 499, pp. 1–11, 2019.

MENGDI, L.; LIANCHENG, X.; JING, Y.; JIE, H. A feature gene selection method based on relieff and pso. In: *2018 10th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA)*. [S.l.]: IEEE, 2018. p. 298–301.

NAMATEVS, I. Deep convolutional neural networks: Structure, feature extraction and training. *Information Technology and Management Science*, v. 20, 12 2017.

NANNI, L.; GHIDONI, S.; BRAHNAM, S.; LIU, S.; ZHANG, L. Ensemble of hand-crafted and deep learned features for cervical cell classification. In: _____. [S.l.: s.n.], 2020. p. 117–135. ISBN 978-3-030-42748-1.

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.

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>.

RAHHAL, M. M. A.; BAZI, Y.; ABDULLAH, T.; MEKHALFI, M. L.; ALHICHRI, H.; ZUAIR, M. Learning a multi-branch neural network from multiple sources for knowledge adaptation in remote sensing imagery. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 10, n. 12, p. 1890, 2018.

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.

ROBNIK-SIKONJA, M.; KONONENKO, I. Theoretical and empirical analysis of relief and rrelief. *Machine Learning*, v. 53, p. 23–69, 10 2003.

SANTOS, F. P. dos; PONTI, M. A. Alignment of local and global features from multiple layers of convolutional neural network for image classification. In: IEEE. *2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. [S.l.], 2019. p. 241–248.

SASAKI, Y.; FELLOW, R. The truth of the f-measure, manchester: Mib-school of computer science. *University of Manchester*, p. 25, 2007.

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>.

SINGH, A.; KUMAR, A.; MAHMUD, M.; KAISER, M. S.; KISHORE, A. Covid-19 infection detection from chest x-ray images using hybrid social group optimization and support vector classifier. *Cognitive Computation*, p. 1–13, 03 2021.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, Elsevier, v. 45, p. 427–437, 2009.

SU, C.; WANG, W. Concrete cracks detection using convolutional neuralnetwork based on transfer learning. *Mathematical Problems in Engineering*, v. 2020, p. 1–10, 10 2020.

TAKAHASHI, R.; KAJIKAWA, Y. Computer-aided diagnosis: A survey with bibliometric analysis. *International journal of medical informatics*, vol. 101, pp. 58–67, 2017.

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

TOMAR, A.; GUPTA, N. Prediction for the spread of covid-19 in india and effectiveness of preventive measures. *Science of The Total Environment*, v. 728, p. 138762, 2020. ISSN 0048-9697. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0048969720322798>.

WAHAB, M. N. A.; NEFTI-MEZIANI, S.; ATYABI, A. A comprehensive review of swarm optimization algorithms. *PloS one*, Public Library of Science, v. 10, n. 5, p. e0122827, 2015.

WAHAB, M. N. A.; NEFTI-MEZIANI, S.; ATYABI, A. A comprehensive review of swarm optimization algorithms. *PLOS ONE*, Public Library of Science, v. 10, n. 5, p. 1–36, 05 2015. Disponível em: <https://doi.org/10.1371/journal.pone.0122827>.

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>.

WEI, W.; WANG, D.; LIANG, J. Accelerating ReliefF using information granulation. *International Journal of Machine Learning and Cybernetics*, Springer Science and Business Media LLC, apr 2021. Disponível em: <https://doi.org/10.1007/2Fs13042-021-01334-4>.

YU, L.; LI, S.; LIU, S. Fast support vector machine training via three-term conjugate-like smo algorithm. *Pattern Recognition*, v. 139, p. 109478, 2023. ISSN 0031-3203. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0031320323001784>.

ZERDOUMI, S.; SABRI, A.; KAMSIN, A.; HASHEM, I.; GANI, A.; HAKAK, S.; AL-GARADI, M.; CHANG, V. Image pattern recognition in big data: taxonomy and open challenges: survey. *Multimedia Tools and Applications*, v. 77, 04 2018.

ZHANG, G.; FANG, B. Logitboost classifier for discriminating thermophilic and mesophilic proteins. *Journal of Biotechnology*, v. 127, n. 3, p. 417–424, 2007. ISSN 0168-1656. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168165606006316>.

ZHENG, L.; YANG, Y.; TIAN, Q. Sift meets cnn: A decade survey of instance retrieval. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 40, n. 5, p. 1224–1244, 2017.

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>>.