

ANDRÉ L. JELLER SELLETI

**UMA ANÁLISE SOBRE O DESEMPENHO DE  
TÉCNICAS DE SELEÇÃO DE ATRIBUTOS  
NOS CENÁRIOS DE CLASSIFICAÇÃO PLANA  
E HIERÁRQUICA PARA A TAREFA DE  
DETECÇÃO DE COVID-19 A PARTIR DE  
IMAGENS DE RAIOS X**

Curitiba - PR, Brasil

2022



# Agradecimentos

Gostaria de agradecer primeiramente a Deus por me permitir chegar até aqui através das oportunidades que tem me dado desde minha graduação e por me permitir passar por este tempo de mestrado e pandemia junto com minha família. Assim agradeço meu pai Jean Carlos Selleti, minha mãe Sirley Simone Jeller Selleti, minha irmã Lais Jeller Selleti e meus avós Nelson Jeller e Edna Grangeiro Jeller que apesar das dificuldades estiveram presentes em todos os momentos me apoiando e incentivando a chegar até o fim desta etapa.

Também gostaria de agradecer meu professor, amigo e orientador Carlos N. Silla Jr por em todas as reuniões e conversas me ajudar e mostrar o caminho necessário para se chegar ao fim deste percurso, ao suporte da PUCPR e PPGIa por meio de recursos e professores, e a CAPES que incentivou e financiou diretamente esta pesquisa, desde sua concepção, por meio do Edital 07/2020 – BOLSA CAPES DE MESTRADO Referente: Edital CAPES de Seleção Emergencial – Programa Estratégico Emergencial de Prevenção e Combate a Surtos, Endemias, Epidemias e Pandemias.



# Resumo

Para ajudar na triagem de pacientes infectados pela covid-19 durante a pandemia dos anos 2020 a 2022, muitas frentes de pesquisa foram iniciadas e entre elas a análise de imagens de raios X por ela afetar principalmente os pulmões. Neste meio, ao se descobrir viável a detecção do vírus através destas imagens, a aplicação do aprendizado de máquina para este fim se tornou um ponto de interesse. Assim, em um cenário incerto de pandemia em que a criação e distribuição de vacinas demandou um certo tempo, o isolamento de pessoas infectadas foi a melhor recomendação a ser seguida, o que resultou em mais uma oportunidade para que a área da tecnologia pudesse colaborar com a área da saúde através da criação e/ou aprimoramento de métodos para a detecção da infecção e triagem destas pessoas. Uma vez que nos deparamos com este problema de triagem e distinção entre diferentes grupos de pessoas, o uso de técnicas de aprendizado de máquina através da classificação de imagens de raios X foi escolhido por requerer equipamentos mais baratos e acessíveis. Com isso, o presente trabalho busca otimizar a detecção do coronavírus (e outras patologias pulmonares) em imagens de raios X utilizando técnicas de aprendizado de máquina supervisionado através do uso de quatro métodos de seleção de atributos aplicados a oito tipos de dados extraídos dessas imagens. Tendo os dados provenientes de uma pesquisa prévia realizada por Pereira et al. (2020) em que se buscou atingir um melhor desempenho através da investigação de técnicas de reamostragem, este trabalho buscou reduzir o custo computacional ao analisar seu impacto nos dois cenários de classificação apresentados por Pereira, sendo eles Plano e Hierárquico. Desta forma, finalizando com 2.832 experimentos ao combinar todas as técnicas, quantidade de atributos e cenários de classificação, os resultados foram analisados de forma a comparar o desempenho geral (cenário macro) e o desempenho da classificação exclusiva do coronavírus (cenário covid). Sendo possível concluir de que ao se utilizar da seleção de atributos, é possível melhorar o desempenho de classificadores na tarefa de classificação e detecção do coronavírus (e outras patologias), independente do tipo de dado extraído (das imagens), em ambos os cenários de classificação ao obter resultados melhores e compatíveis com o estado da arte dependendo do cenário de análise.

**Palavras-chave:** seleção de atributos, Covid-19, imagens de raios X, aprendizado de máquina.



# Abstract

To assist in screening of patients infected with covid-19 during the pandemic from 2020 to 2022, many research fronts were initiated, including the analysis of X-ray images, as the virus primarily affects the lungs. In this context, as the detection of the virus through these images became viable, the application of machine learning for this purpose became a point of interest. That way, in an uncertain pandemic scenario where the creation and distribution of vaccines took some time, isolating infected individuals was the best recommendation, leading to another opportunity for the technology sector to collaborate with healthcare through the creation and/or improvement of methods for infection detection and screening of those peoples. Given the challenge of screening and distinguishing between different groups of people, the use of machine learning techniques through the classification of X-ray images was chosen due to the requirement for cheaper and more accessible equipment. Therefore, this study aims to optimize the detection of the coronavirus (and other lung pathologies) in five well known classifiers using four feature selection methods applied to eight types of data extracted from these images. Using data from a previous study made by Pereira et al. (2020), which sought to achieve better performance through sampling techniques, this work aimed not only to reduce computational costs but also to analyze their impact on the two classification scenarios presented by Pereira, namely Plan and Hierarchical. Thus, concluding with 2,832 experiments combining all techniques, attribute quantities, and classification scenarios, the results were analyzed to compare overall performance (macro scenario) and the performance of only coronavirus classification (covid scenario). It is possible to conclude that using feature selection can improve the performance of classifiers in the task of classification and detection of coronavirus (and other pathologies), regardless of the type of extracted data (from images), in both classification scenarios, achieving both better and compatible results with the state of the art depending on the analysis scenario.

**Keywords:** feature selection, covid-19, x-ray images, machine learning.





# Lista de ilustrações

Figura 1 – Exemplo Seleção Filter . . . . .	28
Figura 2 – Exemplo Seleção Wrapper . . . . .	31
Figura 3 – Exemplo de dois indivíduos e seus cromossomos em um AG] . . . . .	32
Figura 4 – Exemplo de Cross-Over em um Algoritmo Genético . . . . .	33
Figura 5 – Exemplo das abordagens de classificação. . . . .	34
Figura 6 – Exemplo LCPN Adaptado de (SILLA; FREITAS, 2011) - Pontilhado representa os <i>classificadores</i> , enquanto os nós em preto os <i>nós-internos</i> e os azuis os <i>nós-folhas</i> . . . . .	37
Figura 7 – Exemplo LCL Adaptado de (SILLA; FREITAS, 2011) - Pontilhado representa os <i>classificadores</i> , enquanto os nós em preto os <i>nós-internos</i> e os azuis os <i>nós-folhas</i> . . . . .	38
Figura 8 – Exemplo LCN Adaptado de (SILLA; FREITAS, 2011) - Pontilhado representa os <i>classificadores</i> , enquanto os nós em preto os <i>nós-internos</i> e os azuis os <i>nós-folhas</i> . . . . .	39
Figura 9 – Exemplo Global Adaptado de (SILLA; FREITAS, 2011) . . . . .	40
Figura 10 – Exemplo de DT . . . . .	41
Figura 11 – Exemplo de KNN . . . . .	41
Figura 12 – Exemplos adaptados de (Phil Kim, 2017) . . . . .	42
Figura 13 – Exemplo de RF . . . . .	43
Figura 14 – Exemplo de SVM adaptado de (DUDA; HART; STORK, 2012) . . . . .	44
Figura 15 – Calculando Precision . . . . .	45
Figura 16 – Calculando Recall . . . . .	46
Figura 17 – Fluxograma da metodologia utilizada . . . . .	59
Figura 18 – Hierarquia presente na base RYDLS com contagem de amostras. . . . .	60
Figura 19 – Detalhamento da organização da RYDLS . . . . .	62
Figura 20 – Demonstração da Base RYDLS após Pré-Processamento . . . . .	63
Figura 21 – Metodologia Utilizada nas Abordagens de Seleção . . . . .	64
Figura 22 – Metodologia Utilizada na Etapa de Treinamento . . . . .	65
Figura 23 – Metodologia Utilizada na Etapa de Teste . . . . .	66
Figura 24 – Metodologia Visual dos Resultados Salvos . . . . .	67
Figura 25 – Colunas que compõem um experimento . . . . .	72
Figura 26 – Como encontrar um experimento na tabela . . . . .	72
Figura 27 – Composição do Baseline . . . . .	73
Figura 28 – Indicador de ordenação dos resultados do maior para o menor . . . . .	73
Figura 29 – Como os resultados estão organizados/ranqueados . . . . .	73
Figura 30 – Matrizes de confusão - Cenário de Análise Covid . . . . .	86

Figura 31 – Matrizes de confusão - Cenário de Análise Macro . . . . .	87
Figura 32 – Número de Experimentos . . . . .	104

# Lista de tabelas

Tabela 1 – Bases de Dados Utilizadas nos Trabalhos Relacionados . . . . .	51
Tabela 2 – Trabalhos Relacionados - (*) Indica método ou metodologia proposto no mesmo artigo . . . . .	56
Tabela 3 – Siglas e Nome dos Métodos Utilizados nos Trabalhos Relacionados . .	57
Tabela 4 – Contagem de amostras das subdivisões após o pré-processamento . . .	63
Tabela 5 – Versões dos Pacotes/Bibliotecas . . . . .	67
Tabela 6 – Parâmetros dos Filters - (*) indica valores padrão . . . . .	68
Tabela 7 – Parâmetros do Algoritmo Genético . . . . .	69
Tabela 8 – Parâmetros dos Classificadores (PEREIRA et al., 2020) . . . . .	70
Tabela 9 – Descrição das siglas utilizadas nas tabelas de resultados. . . . .	74
Tabela 10 – Resultados - Cenário Covid - Classificação Plana - Seleção Plana . . .	76
Tabela 11 – Resultados - Cenário Macro - Classificação Plana - Seleção Plana . . .	78
Tabela 12 – Resultados - Cenário Covid - Classificação Hierárquica - Seleção Plana	79
Tabela 13 – Resultados - Cenário Macro - Classificação Hierárquica - Seleção Plana	81
Tabela 14 – Resultados - Cenário Covid - Classificação Hierárquica - Seleção Local	82
Tabela 15 – Resultados - Cenário Macro - Classificação Hierárquica - Seleção Local	84
Tabela 16 – Resultados por Extrator - Cenário Covid . . . . .	88
Tabela 17 – Resultados por Extrator - Cenário Macro . . . . .	89
Tabela 18 – Baseline - Todos os Atributos - Cenário Covid (Covid F1) . . . . .	105
Tabela 19 – Baseline - Todos os Atributos - Cenário Macro (Macro Avg) . . . . .	106
Tabela 20 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator BSIF	108
Tabela 21 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator BSIF	108
Tabela 22 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator EQP	109
Tabela 23 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator EQP	109
Tabela 24 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator INCEPTION . . . . .	110
Tabela 25 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator INCEPTION . . . . .	110
Tabela 26 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LBP	111
Tabela 27 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LBP	111
Tabela 28 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LDN	112
Tabela 29 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LDN	112
Tabela 30 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LETRIST . . . . .	113
Tabela 31 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LETRIST . . . . .	113

Tabela 32 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LPQ	114
Tabela 33 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LPQ	114
Tabela 34 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator OBIF	115
Tabela 35 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator OBIF . . . . .	115
Tabela 36 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator BSIF	117
Tabela 37 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator BSIF	117
Tabela 38 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator EQP	118
Tabela 39 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator EQP	118
Tabela 40 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator INCEPTION . . . . .	119
Tabela 41 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator INCEPTION . . . . .	119
Tabela 42 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LBP	120
Tabela 43 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LBP	120
Tabela 44 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LDN	121
Tabela 45 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LDN	121
Tabela 46 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LETRIST . . . . .	122
Tabela 47 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LETRIST . . . . .	122
Tabela 48 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LPQ	123
Tabela 49 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LPQ	123
Tabela 50 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator OBIF	124
Tabela 51 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator OBIF . . . . .	124
Tabela 52 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator BSIF	126
Tabela 53 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator BSIF	126
Tabela 54 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator EQP	127
Tabela 55 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator EQP	127
Tabela 56 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator INCEPTION . . . . .	128
Tabela 57 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator INCEPTION . . . . .	128
Tabela 58 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LBP	129
Tabela 59 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LBP	129
Tabela 60 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LDN	130
Tabela 61 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LDN	130

Tabela 62 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LETRIST . . . . .	131
Tabela 63 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LETRIST . . . . .	131
Tabela 64 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LPQ	132
Tabela 65 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LPQ	132
Tabela 66 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator OBIF	133
Tabela 67 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator OBIF . . . . .	133
Tabela 68 – Melhores cinco resultados do AG para Covid F1 no cenário Plano . . .	135
Tabela 69 – Melhores cinco resultados do AG para Macro Avg no cenário Plano . .	135
Tabela 70 – Melhores resultados do AG para Covid F1 de cada extrator no cenário Plano . . . . .	136
Tabela 71 – Melhores resultados do AG para Macro Avg de cada extrator no cenário Plano . . . . .	136
Tabela 72 – Melhores cinco resultados do AG para Covid F1 no cenário HPlano . .	137
Tabela 73 – Melhores cinco resultados do AG para Macro Avg no cenário HPlano .	137
Tabela 74 – Melhores resultados do AG para Covid F1 de cada extrator no cenário HPlano . . . . .	137
Tabela 75 – Melhores resultados do AG para Macro Avg de cada extrator no cenário HPlano . . . . .	138
Tabela 76 – Melhores cinco resultados do AG para Covid F1 no cenário HLocal . .	138
Tabela 77 – Melhores cinco resultados do AG para Macro Avg no cenário HLocal .	138
Tabela 78 – Melhores resultados do AG para Covid F1 de cada extrator no cenário HLocal . . . . .	139
Tabela 79 – Melhores resultados do AG para Macro Avg de cada extrator no cenário HLocal . . . . .	139
Tabela 80 – Melhores resultados de (PEREIRA et al., 2020) para Covid F1 no cenário Plano . . . . .	143
Tabela 81 – Melhores resultados de (PEREIRA et al., 2020) para Macro Avg no cenário Plano . . . . .	143
Tabela 82 – Melhores resultados de (PEREIRA et al., 2020) para Covid F1 no cenário Hierárquico . . . . .	143
Tabela 83 – Melhores resultados de (PEREIRA et al., 2020) para Macro Avg no cenário Hierárquico . . . . .	143



# Lista de abreviaturas e siglas

<b>% Atributos</b>	Porcentagem de atributos utilizados
<b>ACO</b>	Ant Colony Algorithm
<b>AFS-DF</b>	Adaptive Feature Selection Guided Deep Forest
<b>AG</b>	Algoritmo Genético
<b>ANN</b>	Artificial Neural Network
<b>ANOVA</b>	Analysis Of Variance
<b>ANV</b>	Método que utiliza ANOVA
<b>Baseline</b>	Experimento realizado com todos os atributos
<b>BDE</b>	Binary Differential Evolution
<b>BGWO</b>	Binary Gray Wolf Optimization
<b>BPSO</b>	Binary Particle Swarm Optimization
<b>BSIF</b>	Binarized statistical image features
<b>BSNDO</b>	Binary Simulated Normal Distribution Optimizer
<b>Cenário Covid</b>	Cenário de Análise para valor de F1-Score da classe Covid-19
<b>Cenário Hierárquico</b>	Cenário de Classificação ao utilizar abordagem hierárquica
<b>Cenário Macro</b>	Cenário de Análise para valor de Macro Average F1-Score
<b>Cenário Plano</b>	Cenário de Classificação ao utilizar abordagem plana
<b>CHHO</b>	Chaotic Harris Hawks optimisation Algorithm
<b>CI</b>	Chaotic Initialisation (CI)
<b>CLF</b>	Classificador
<b>Covid F1</b>	F1-Score da classe Covid-19
<b>CPDS</b>	COVID-19 Patients Detection Strategy
<b>DA</b>	Dragonfly Algorithm (DA)

<b>DNN</b>	Deep Neural Network
<b>DT</b>	Decision Tree
<b>EKNN</b>	Enhanced K-Nearest Neighbor
<b>ELM</b>	Extreme Learning Machine
<b>EQP</b>	Elongated quinary patterns
<b>ETC</b>	Extra Tree Classifier
<b>EXT</b>	Extrator
<b>F1</b>	F1-Score
<b>FDEPFGN</b>	Fused Dynamic sized Exemplars based Pyramid Feature Generation Network
<b>FN</b>	Falso Negativo
<b>FP</b>	Falso Positivo
<b>FSXRF</b>	Feature Selection with Explainable Random Forest
<b>Gaussian-NB</b>	Gaussian Naïve Bayes
<b>GC</b>	Global Classifier
<b>GLCM</b>	Gray Level Co-occurrence Matrix
<b>GNDO</b>	Generalized Normal Distribution Optimizer
<b>GRO</b>	Golden Ratio Optimizer
<b>Guided WOA</b>	Guided Whale Optimization Algorithm
<b>GWO</b>	Grey Wolf Optimizer
<b>H-Local</b>	Classificação hierárquica com seleção LCPN
<b>H-Plano</b>	Classificação hierárquica com seleção plana
<b>HFSM</b>	Hybrid Feature Selection Methodology
<b>HHO</b>	Harris Hawks optimisation (HHO)
<b>HLBDA</b>	Hyper Learning Binary Dragonfly Algorithm
<b>IG</b>	Information Gain



<b>INCA</b>	Iterative Neighborhood Component Analysis
<b>INCEPTION</b>	Learned features with inception-V3
<b>IRF</b>	Iterative ReliefF
<b>KNN</b>	k-Nearest Neighbor
<b>KNN 3</b>	k-Nearest Neighbor utilizando 3 vizinhos
<b>KNN 5</b>	k-Nearest Neighbor utilizando 5 vizinhos
<b>LBP</b>	Local binary pattern
<b>LCL</b>	Local Classifier per Level
<b>LCN</b>	Local Classifier Node
<b>LCPN</b>	Local Classifier per Parent Node
<b>LDN</b>	Local directional number
<b>LETRIST</b>	Locally encoded transform feature histogram
<b>LPQ</b>	Local phase quantization
<b>LR</b>	Logistic Regression
<b>Macro Avg</b>	Macro-Average F1-Score
<b>Mavg</b>	Macro-Average F1-Score
<b>MG-ELM</b>	Multi-threaded Genetic feature selection algorithm combined with Extreme Learning Machines
<b>MI</b>	Mutual Information
<b>MLP</b>	Multilayer Perceptron
<b>MRFGRO</b>	Manta Ray Foraging based Golden Ratio Optimizer
<b>MRFO</b>	Manta Ray Foraging Optimizer
<b>mRMR</b>	Minimum Redundancy Maximum Relevance
<b>MS</b>	Método de Seleção
<b>Nº Atributos</b>	Quantidade de atributos utilizados de um total
<b>NB</b>	Naïve Bayesian

<b>NCCLA</b>	New Caledonian Crow Learning Algorithm
<b>NSGA-II</b>	Non-dominated Sorting Genetic Algorithm
<b>OBIF</b>	Oriented basic image features
<b>Plano</b>	Classifica plana com seleção plana
<b>Pr</b>	Precision
<b>PSO</b>	Particle Swarm Optimization
<b>PSO-GuidedWOA</b>	Guided WOA based on Particle Swarm Optimization
<b>RBM</b>	Restricted Boltzmann Machine
<b>Re</b>	Recall
<b>RF</b>	Random Forest
<b>RFE</b>	Recursive Feature Elimination
<b>RT-PCR</b>	Real-time transcriptase-polymerase chain
<b>RYDLS</b>	Base de Dados RYDLS-20
<b>SA</b>	Simulated Annealing
<b>SCA</b>	Sine Cosine Algorithm
<b>SFS</b>	Stochastic Fractal Search
<b>SVM</b>	Support Vector Machine
<b>VP</b>	Verdadeiro Positivo
<b>WOA</b>	Whale Optimization Algorithm
<b>XGBoost</b>	eXtreme Gradient Boosting
<b>XRF</b>	Explainable Random Forest

# Lista de símbolos

$\Upsilon$	Especifica o tipo de grafo na Base
$\Psi$	Rotulação das instancias na Base
$\Phi$	Profundidade dos rótulos na Base
$\Delta$	Tipo de previsão do algoritmo
$\Xi$	Profundidade de previsão do algoritmo
$\Omega$	Estrutura de taxonomia que o algoritmo
$\Theta$	Abordagem do algoritmo
$F_{statistic}$	F-value de ANOVA
$SSQ_b$	Variâncias entre os grupos
$SSQ_w$	Variâncias dentro dos grupos
$MI$	Mutual Information
$p(x, y)$	Propabilidade conjunta
$p(x)q(y)$	Probabilidade Marginal
$x$	Valores de Entrada
$w$	Pesos
$b$	Bias
$\varphi$	Função de ativação



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>23</b>
<b>1.1</b>	<b>Objetivo</b>	<b>24</b>
<b>1.2</b>	<b>Hipótese</b>	<b>25</b>
<b>1.3</b>	<b>Estrutura do Documento</b>	<b>25</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>27</b>
<b>2.1</b>	<b>Seleção de Atributos</b>	<b>27</b>
2.1.1	Métodos Filters	27
2.1.1.1	Análise de Variância (ANOVA)	28
2.1.1.2	Mutual Information (MI)	29
2.1.2	Métodos Wrappers	31
2.1.3	Algoritmo Genético (AG)	32
<b>2.2</b>	<b>Abordagens de Classificação</b>	<b>34</b>
2.2.1	Abordagem de Classificação Plana	34
2.2.2	Abordagem de Classificação Hierárquica	35
2.2.2.1	Local Classifier per Parent Node	37
2.2.2.2	Local Classifier per Level	37
2.2.2.3	Local Classifier per Node	38
2.2.2.4	Global Classifier	39
<b>2.3</b>	<b>Classificadores</b>	<b>40</b>
2.3.1	Decision Tree (DT)	40
2.3.2	k-Nearest Neighbors (KNN)	41
2.3.3	Multilayer Perceptron (MLP)	42
2.3.4	Random Forest (RF)	43
2.3.5	Support Vector Machine (SVM)	44
<b>2.4</b>	<b>Métricas e Análise</b>	<b>45</b>
2.4.1	Precision	45
2.4.2	Recall	46
2.4.3	F1-Score	47
2.4.4	Macro-Avg F1-Score	47
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>49</b>
<b>3.1</b>	<b>Bases de Dados</b>	<b>49</b>
<b>3.2</b>	<b>Artigos Relacionados</b>	<b>52</b>
<b>4</b>	<b>METODOLOGIA</b>	<b>59</b>

<b>4.1</b>	<b>Base de dados RYDLS-20</b>	<b>59</b>
<b>4.2</b>	<b>Pré-processamento</b>	<b>63</b>
<b>4.3</b>	<b>Seleção de Atributos</b>	<b>64</b>
<b>4.4</b>	<b>Treinamento e Classificação</b>	<b>65</b>
<b>4.5</b>	<b>Geração dos Resultados</b>	<b>66</b>
<b>4.6</b>	<b>Ferramentas, Configurações e Versões</b>	<b>67</b>
4.6.1	Métodos Filters e seus Parâmetros	68
4.6.2	Algoritmo Genético e seus Parâmetros	68
4.6.3	Classificadores e seus Parâmetros	69
<b>5</b>	<b>RESULTADOS</b>	<b>71</b>
<b>5.1</b>	<b>Explicando as Tabelas de Resultado</b>	<b>72</b>
<b>5.2</b>	<b>Classificação Plana</b>	<b>75</b>
5.2.1	Melhores Resultados - Cenário Covid	75
5.2.2	Melhores Resultados - Cenário Macro	77
<b>5.3</b>	<b>Classificação Hierárquica</b>	<b>78</b>
5.3.1	Desempenho com Seleção Plana	79
5.3.1.1	Melhores Resultados - Cenário Covid	79
5.3.1.2	Melhores Resultados - Cenário Macro	80
5.3.2	Desempenho com Seleção LCPN	82
5.3.2.1	Melhores Resultados - Cenário Covid	82
5.3.2.2	Melhores Resultados - Cenário Macro	83
<b>5.4</b>	<b>Classificação Plana VS Hierárquica</b>	<b>85</b>
5.4.1	Performance no Cenário Covid	85
5.4.2	Performance no Cenário Macro	86
5.4.3	Performance por Extrator	87
<b>6</b>	<b>CONCLUSÃO</b>	<b>91</b>
	<b>REFERÊNCIAS</b>	<b>95</b>
	<b>APÊNDICE A – NÚMERO DE EXPERIMENTOS</b>	<b>103</b>
	<b>APÊNDICE B – METAS DE BASELINES</b>	<b>105</b>
	<b>APÊNDICE C – RESULTADOS COM SELEÇÃO FILTER</b>	<b>107</b>
<b>C.1</b>	<b>(Plano) Classificação Plana com Seleção Plana</b>	<b>107</b>
C.1.1	Resultados Extrator BSIF	108
C.1.2	Resultados Extrator EQP	109
C.1.3	Resultados Extrator INCEPTION	110
C.1.4	Resultados Extrator LBP	111

C.1.5	Resultados Extrator LDN . . . . .	112
C.1.6	Resultados Extrator LETRIST . . . . .	113
C.1.7	Resultados Extrator LPQ . . . . .	114
C.1.8	Resultados Extrator OBIF . . . . .	115
<b>C.2</b>	<b>(H-Plano) Classificação Hierárquica com Seleção Plana . . . . .</b>	<b>116</b>
C.2.1	Resultados Extrator BSIF . . . . .	117
C.2.2	Resultados Extrator EQP . . . . .	118
C.2.3	Resultados Extrator INCEPTION . . . . .	119
C.2.4	Resultados Extrator LBP . . . . .	120
C.2.5	Resultados Extrator LDN . . . . .	121
C.2.6	Resultados Extrator LETRIST . . . . .	122
C.2.7	Resultados Extrator LPQ . . . . .	123
C.2.8	Resultados Extrator OBIF . . . . .	124
<b>C.3</b>	<b>(H-Local) Classificação Hierárquica com Seleção LCPN . . . . .</b>	<b>125</b>
C.3.1	Resultados Extrator BSIF . . . . .	126
C.3.2	Resultados Extrator EQP . . . . .	127
C.3.3	Resultados Extrator INCEPTION . . . . .	128
C.3.4	Resultados Extrator LBP . . . . .	129
C.3.5	Resultados Extrator LDN . . . . .	130
C.3.6	Resultados Extrator LETRIST . . . . .	131
C.3.7	Resultados Extrator LPQ . . . . .	132
C.3.8	Resultados Extrator OBIF . . . . .	133
	<b>APÊNDICE D – RESULTADOS COM ALGORITMO GENÉTICO . . . . .</b>	<b>135</b>
<b>D.1</b>	<b>(Plano) Classificação Plana com Seleção Plana . . . . .</b>	<b>135</b>
<b>D.2</b>	<b>(H-Plano) Classificação Hierárquica com Seleção Plana . . . . .</b>	<b>136</b>
<b>D.3</b>	<b>(H-Local) Classificação Hierárquica com Seleção LCPN . . . . .</b>	<b>138</b>
	 <b>ANEXOS</b>	 <b>141</b>
	 <b>ANEXO A – METAS DE RESULTADOS . . . . .</b>	 <b>143</b>





# 1 INTRODUÇÃO

Com a COVID-19 sendo reconhecida como uma Emergência de Saúde Pública de Interesse Internacional pela Organização Mundial da Saúde (OMS) em 30 de Janeiro de 2020 (SOHRABI et al., 2020), não demorou muito para que ela começasse a afetar nossos arredores e toda a população mundial, sendo desta forma considerada uma pandemia no dia 11 de março do mesmo ano. Após ser avistado pela primeira vez em Wuhan na China ao final de 2019, muitos estragos foram gerados tanto através do vírus quanto de suas complicações adversas, sendo estimada a morte de 6,37 milhões de pessoas<sup>1</sup> ao redor do mundo segundo o *Our World In Data* dos dias 22/01/20 a 18/07/22<sup>2</sup>.

Durante esse período de pandemia, em que as vacinas ainda se encontravam em fase de pesquisa e desenvolvimento, a melhor recomendação a ser seguida foi rápida triagem e isolamento das pessoas infectadas. Assim evitando que esse vírus se espalhasse ainda mais, cenário o qual apenas começou a mudar ao final de 2020, em que algumas vacinas começaram a se mostrar promissoras e disponíveis para a população<sup>3</sup>. No Brasil, o início da distribuição das vacinas apenas ocorreu em janeiro de 2021<sup>4</sup>, e apesar de largamente distribuída e aplicada, ainda se levou vários meses para que chegasse a todas às pessoas devido sua escassez pela alta demanda global e baixa capacidade de produção.

Assim, neste tempo e contexto, contando também com a falta e difícil acesso a testes de *real-time transcriptase-polymerase chain (RT-PCR)*, método de diagnóstico padrão aceito (CANAYAZ, 2021), muitas pesquisas para ajudar na triagem de pacientes começaram a surgir. Além delas, muitos governos criaram incentivos para tal, como o edital da CAPES 09/2020 focado em projetos "*voltados ao enfrentamento à nova pandemia da COViD-19 e em temas relacionados a endemias e epidemias típicas no país*"<sup>5</sup>, que deu origem à esta pesquisa. Desta forma, com o edital e a pesquisa (PEREIRA et al., 2020) que serviu de base e inspiração para este trabalho, buscamos ajudar na detecção de covid-19 e outras patologias pulmonares através da investigação dos efeitos da aplicação de seleção de atributos em imagens de raios X de tórax, tanto em um cenário de classificação plano quanto hierárquico visto que as diferentes patologias analisadas já se encontram organizadas hierarquicamente.

<sup>1</sup> Mortes cumulativas confirmadas por COVID-19

<sup>2</sup> <<https://ourworldindata.org/covid-deaths>> Acessado em: 19/07/2022

<sup>3</sup> <[https://web.archive.org/web/20211112130445/https://www.who.int/news-room/questions-and-answers/item/coronavirus-disease-\(covid-19\)-vaccines](https://web.archive.org/web/20211112130445/https://www.who.int/news-room/questions-and-answers/item/coronavirus-disease-(covid-19)-vaccines)> Acessado em Setembro/2021

<sup>4</sup> <<https://agenciabrasil.ebc.com.br/saude/noticia/2021-01/vacinas-contracovid-19-comecam-ser-distribuidas>> Acessado em: 20/07/22

<sup>5</sup> <<https://www.gov.br/capes/pt-br/aceso-a-informacao/acoes-e-programas/bolsas/programas-estrategicos/programas-emergenciais/programa-de-combate-as-epidemias/prevencao-e-combate-a-surto-s-endemias-epidemias-e-pandemias-edital-n-09-2020>>

Considerando que vários estudos que aplicam inteligência artificial no diagnóstico de covid-19 utilizaram tomografia computadorizada (CT Scan) e raios X (EL-RASHIDY et al., 2021), um fato a se considerar é o de que algumas máquinas de CT Scan podem custar até milhões de dólares, enquanto uma máquina de raios X pode custar aproximadamente 10 vezes menos (PEREIRA et al., 2020). Com isso, o presente trabalho busca utilizar imagens de raios X de tórax por requerem equipamentos mais facilmente acessíveis (Tayarani N., 2021).

Desta forma, por alguns atributos presentes em base de dados serem conhecidos como informações irrelevantes e redundantes, podendo também afetar negativamente o desempenho do algoritmo de aprendizagem (TOO; MIRJALILI, 2021a), a combinação destas duas abordagens (aprendizado de máquina com seleção de atributos) passa a ser interessante, isso sem contar com o diferencial apresentado por Pereira et al. (2020), ao investigar a detecção de covid-19 nos cenários de classificação plano e hierárquico.

Assim, a contribuição principal deste trabalho para ajudar no processo de triagem de pacientes, é investigar o desempenho de um modelo ao aplicar diferentes técnicas de seleção de atributos à diferentes técnicas de extração de características e em conjunto utilizar diferentes classificadores para realizar classificações tanto no cenário plano quanto hierárquico.

## 1.1 Objetivo

O objetivo principal deste trabalho é investigar como o uso de métodos de seleção de atributos afeta o desempenho de um classificador para a detecção de covid-19 e outras patologias a partir de imagens de raios X de tórax nos cenários de classificação plana e hierárquico. Para atingir esse objetivo são definidos os seguintes objetivos específicos:

- Investigar diferentes métodos e abordagens de seleção de atributos, como Filters e Algoritmo Genético.
- Realizar os testes destes métodos em diferentes tipos de características extraídas a partir das imagens de raios X.
- Organizar os experimentos de forma que seja possível comparar seus resultados ao utilizar métodos de seleção, com os resultados sem o uso destes métodos (baseline).
- Realizar experimentos no cenário de classificação plana e analisar a diferença de performance ao identificar se existe alguma abordagem que resulta em melhores resultados.

- Realizar experimentos no cenários de classificação hierárquica e analisar a diferença de performance ao identificar se existe alguma abordagem que resulta em melhores resultados.
- Comparar o desempenho dos melhores resultados entre os cenários de classificação plano e hierárquico.
- Analisar os melhores resultados de desempenho geral do classificador e de desempenho da classificação exclusiva do coronavírus.

## 1.2 Hipótese

*Hipótese:* A aplicação de métodos de seleção de atributos em diferentes tipos de dados extraídos de imagens de raios X para a tarefa de detecção de covid-19 e outras patologias melhora o desempenho dos modelos de classificação independente do tipo de dados, tanto no cenário de classificação plana quanto hierárquica.

## 1.3 Estrutura do Documento

Este trabalho está organizado em cinco capítulos. No primeiro (atual) uma introdução ao problema e aos objetivos do trabalho são apresentados, sendo seguido pelo Capítulo 2 que contém a Fundamentação Teórica dos recursos utilizados para a realização dos experimentos. No Capítulo 3, os Trabalhos Relacionados são apresentados, e logo após, a Metodologia utilizada está presente no Capítulo 4, com os Resultados obtidos a partir dela e as análises apresentados no Capítulo 5 para dois cenários de análise, um considerando o desempenho geral do classificador e o outro o desempenho da classificação exclusiva do coronavírus. Finalizando assim com a Conclusão e Trabalhos Futuros no Capítulo 6.



## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo é destinado a explicar termos e temas importantes para que o trabalho seja compreendido como um todo. Desta forma, ele está organizado de maneira que cada seção aborda uma etapa do processo, contendo em cada uma dessas etapas tópicos específicos que precisam ser explicados de maneira separada. Assim, começando com a contribuição principal da pesquisa que é a aplicação de Métodos de Seleção de Atributos, cada um deles se encontra descrito na Seção 2.1. Uma vez que existem várias maneiras de realizar classificações, assim como vários tipos de classificadores, passa a ser importante entender como cada um funciona. Sendo assim as Seções 2.2 e 2.3 abordam respectivamente as Abordagens Classificações e os Classificadores utilizados. Por fim, os resultados dessas classificações precisam ser compreendidos e analisados, com isso, a Seção 2.4 foca em apresentar as Métricas utilizadas para analisar os experimentos.

### 2.1 Seleção de Atributos

Entre as formas de se produzir melhores resultados nas tarefas de classificação, o uso da seleção de atributos foi escolhido para lidar com o problema atual. Neste cenário, como dito por Chen et al. (2019), as tarefas da seleção de atributos se baseiam em omitir as características irrelevantes e redundantes e reter as características relevantes para melhorar o desempenho de um modelo de aprendizado. E, ao mesmo tempo, o tempo e a memória consumidos (custo computacional) para treinar um modelo de aprendizado são reduzidos. Desta forma, os objetivos da seleção de atributos incluem criar modelos mais simples e fáceis de entender, melhorar a performance da mineração de dados e gerar dados limpos e compreensíveis (LI et al., 2017).

Logo, contendo apenas as características mais relevantes para determinado cenário, temos menos atributos que prejudicam o resultado do classificador e com isso potencializam sua performance. Assim, entre as diferentes estratégias de seleção, é possível encontrá-las categorizadas como: métodos *filters*, *wrapper* e *embedded* (LI et al., 2017). Sendo contemplado nesta pesquisa apenas as duas primeiras, a abordagem filter se encontra presente pelo uso de três métodos descritos na Seção 2.1.1, enquanto a abordagem wrapper é representada nesta pesquisa pelo uso de um Algoritmo Genético presente na Seções 2.1.2.

#### 2.1.1 Métodos Filters

Sendo uma das formas mais rápidas e com menor custo computacional para se selecionar os atributos mais relevantes de um determinado cenário, os métodos filters

atuam como uma etapa de pré-processamento para ranquear os atributos de forma que os melhores ranqueados são selecionados e aplicados ao classificador (CHANDRASHEKAR; SAHIN, 2014). Desta forma, por serem independentes de um algoritmo de indução (classificador) (MOLINA; BELANCHE; NEBOT, 2002) e utilizarem, em sua maioria, cálculos matemáticos, testes estatísticos e análises de dependência de variáveis, são mais rápidos mas nem sempre proporcionam os melhores resultados. Pois como dito por Li et al. (2017), eles dependem apenas das características dos dados para avaliar a importância dos atributos, com isso devido à falta de um algoritmo de aprendizado específico orientando a fase de seleção de características, as características selecionadas podem não ser otimizadas para os algoritmos de aprendizado de destino.

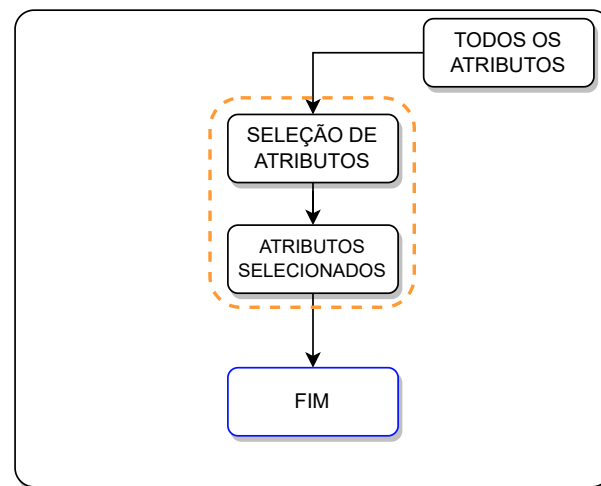


Figura 1 – Exemplo Seleção Filter

Apesar disso, nestes métodos, como dito por Chandrashekar e Sahin (2014), o principal critério para seleção (ordenação) dos atributos são as técnicas de ranqueamento, que são utilizadas devido a sua simplicidade e relatos de bons resultados em aplicações práticas. Assim, tendo sua etapa representada pelo pontilhado laranja na Figura 1, os métodos ANOVA e Mutual Information foram escolhidos para ranquear os atributos mais importantes em cada cenário por analisarem estatisticamente a relação entre cada atributo e classe. Desta forma, eles se encontram descritos na mesma ordem nas seções 2.1.1.1 e 2.1.1.2.

#### 2.1.1.1 Análise de Variância (ANOVA)

A Análise de Variância (ANOVA) (STHLE; WOLD, 1989), busca ao analisar as médias das variâncias entre os grupos ( $SSQ_b$ ) e dentro dos grupos ( $SSQ_w$ ), identificar eventuais diferenças significativas entre as médias de dois ou mais grupos (classes) (ALMUGREN; ALSHAMLAN, 2019). Sendo calculado pela Equação 2.1, é possível entender seu resultado como uma análise da dispersão e concentração dos dados tanto dentro como entre estes grupos.

Desta forma, caso a diferença entre o valor médio dos experimentos usando as respectivas classes for maior em comparação com as diferenças dentro dos experimentos usando a mesma classe, então provavelmente há uma diferença verdadeira entre os efeitos das classes no valor (STHLE; WOLD, 1989)<sup>1</sup>. Assim, em outras palavras, caso a dispersão dos dados (variância) dentro do mesmo grupo seja baixa enquanto entre outros grupos seja alta, este é um atributo relevante pois nos permite entender de que aqueles valores são comuns dentro da própria classe, mas não tão comum na outra, ou também que os dados (de cada classe) estão mais concentrados que dispersos e vice-versa.

$$F_{statistic} = \frac{SSQ_b}{SSQ_w} = \frac{\sum_{j=1}^p n_j (x_{.j} - x_{..})^2 / (p - 1)}{\sum_{j=1}^p \sum_{i=1}^{n_j} (x_{ij} - x_{.j})^2 / \sum_{j=1}^p (n_j - 1)} \quad (2.1)$$

Onde:

- $n_j$  = numero de amostras dentro do  $j$ -ésimo grupo
- $x_{.j}$  = os valores médios usando a (dentro da)  $j$ -ésima classe
- $x_{..}$  = valores totais médios (valor médio entre os valores médios das classes  $x_{.j}$ )
- $x_{ij}$  = o  $i$ -ésimo experimento usando a  $j$ -ésima classe
- $p$  = numero de grupos

### 2.1.1.2 Mutual Information (MI)

*Mutual Information (MI)* mede a quantidade de informação que uma variável aleatória contém sobre outra variável aleatória, sendo assim a redução na incerteza sobre uma variável aleatória devido ao conhecimento da outra (COVER, 1999). Calculado entre duas variáveis e pela Equação 2.2, ela também pode ser entendida pela quantidade de informação que ambas as variáveis compartilham (BENNASAR; HICKS; SETCHI, 2015).

Seu resultado (apenas) será zero, caso as duas variáveis aleatórias sejam estatisticamente independentes (BENNASAR; HICKS; SETCHI, 2015), ou seja, caso as informações (valores) de uma das variáveis não consigam de forma alguma descrever a outra variável, estando assim completamente descorrelacionadas. Caso contrário, um maior valor representa uma correlação, e conforme dito por Ross (2014), por ser um método poderoso para

<sup>1</sup> A tradução desta frase foi levemente adaptada, sendo apresentado no contexto original do texto “*catalysts*” como as classes e “*purity*” como os valores do exemplo utilizado pelo autor.

detectar relacionamentos entre conjuntos de dados, ele irá detectar qualquer tipo de relação entre estes conjuntos, seja envolvendo valores médios, variâncias ou *higher moments*.

$$MI = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (2.2)$$

Onde:

- $p(x, y)$  = probabilidade conjunta
- $p(x)p(y)$  = probabilidade marginal

Assim, para calcular a importância de cada atributo a partir da sua correlação com a classe, se faz necessário encontrar o valor de MI utilizando a equação 2.2. Desta forma, utilizando a Equação apresentada em Cover (1999), podemos chegar no valor desejado ao utilizar as probabilidades conjuntas  $p(x, y)$  e as probabilidades marginais  $p(x)p(y)$  entre os atributos e as classes. Sendo probabilidade conjunta, a probabilidade de duas coisas acontecerem ao mesmo tempo, ela pode ser calculada pela probabilidade de o valor do atributo e a classe desejada serem os mesmos. Enquanto a probabilidade marginal, é calculada utilizando apenas a probabilidade de um dos atributos (ou classe) receber aquele valor, ou seja, a probabilidade de apenas uma coisa acontecer no contexto desejado (atributo/classe). Desta forma, as somatórias são realizadas entre todas as possibilidades de combinações entre as duas variáveis (atributos / classes).



### 2.1.2 Métodos Wrappers

Permitindo atingir melhores resultados com os classificadores em um contexto de seleção de atributos, os métodos wrappers usam como critério a performance do próprio classificador para encontrar os subconjuntos que desempenham as melhores performances (CHANDRASHEKAR; SAHIN, 2014). Porém, por utilizar o algoritmo de aprendizagem como uma sub-rotina, apesar de obter estes melhores resultados, sua principal desvantagem é o custo computacional resultante da chamada deste algoritmo para avaliar cada um dos subconjunto considerados (MOLINA; BELANCHE; NEBOT, 2002).

Em outras palavras, por adicionar/remover os atributos aplicando a melhor escolha baseado no resultado do classificador para aquele momento, estes métodos possuem um maior custo computacional do que os métodos filters (TOO; MIRJALILI, 2021a). Apesar disso, ao permitir que a performance do classificador seja utilizada como a função objetivo para avaliar um subconjunto de variáveis (CHANDRASHEKAR; SAHIN, 2014), representado pelo pontilhado laranja na Figura 2, melhores desempenhos podem ser alcançados justamente pelo fato de os atributos escolhidos serem mais otimizados para aquele determinado contexto (classificação).

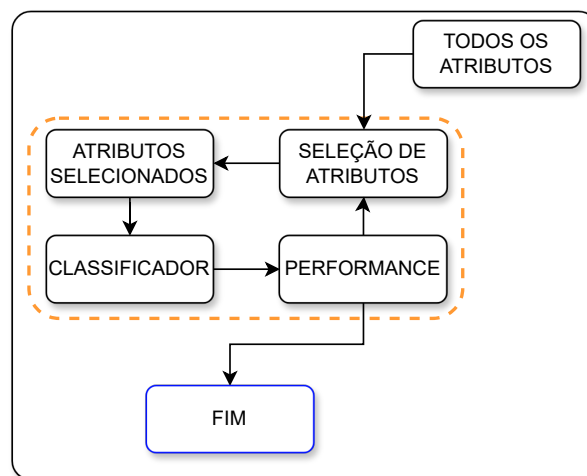


Figura 2 – Exemplo Seleção Wrapper

Entretanto, o custo computacional continua sendo um problema e, uma vez que avaliar  $2^N$  subconjuntos se torna um problema *NP-hard*, subconjuntos *sub-ótimos* podem ser encontrados aplicando algoritmos de busca que os encontram heurísticamente (CHANDRASHEKAR; SAHIN, 2014). Ou seja, apesar do custo, ainda é possível aplicar métodos wrappers de uma forma mais otimizada através de algoritmos heurísticos. Assim, entre as opções disponíveis o algoritmo genético se destaca por vários critérios e características específicas, que podem ser encontrados juntamente com a explicação de seu funcionamento para selecionar bons atributos na Seção 2.1.3.

### 2.1.3 Algoritmo Genético (AG)

Proposto como um método heurístico baseado na “sobrevivência do mais apto”, o algoritmo genético foi descoberto como uma ferramenta útil para problemas de busca e otimização (SIVANANDAM; DEEPA, 2008). Porém, como dito por Sivanandam e Deepa (2008), assim como a maioria dos métodos estocásticos, o AG não têm garantia de encontrar a solução global mais otimizada (global optimum solution) para um problema, ficando satisfeito ao encontrar soluções “aceitavelmente boas” para determinado problema. Em outras palavras, mesmo sendo um método wrapper e testar múltiplas combinações de atributos para encontrar a melhor solução, e fazer isso utilizando dos classificadores como forma de análise de desempenho. Este método não realiza operações para todas as combinações possíveis de atributos, e sim faz o uso de heurísticas para evoluir seu desempenho através de um processo inspirado na teoria de Charles Darwin da seleção natural, em que os mais aptos (subconjuntos com melhores performances) têm mais chances de sobreviver.

Assim, com uma estrutura de dados simples semelhante a um cromossomo, esses algoritmos conseguem codificar uma solução potencial para um problema específico (MATHEW, 2012), como pode ser visto na Figura 3. Nesta figura, é possível visualizar a representação de dois indivíduos (A e B) compostos por uma sequência de blocos que representam através das cores branco e preto a utilização ou não de um atributo. Com isso, através desta representação visual que também pode ser utilizado como 0 e 1, é possível afirmar que cada um contém a sua própria combinação genética (de atributos), que diz ao código quais deles estão sendo utilizados.




Figura 3 – Exemplo de dois indivíduos e seus cromossomos em um AG]

A partir deste conceito, os parâmetros e operadores do AG podem ser modificados, dentro da ideia geral de um algoritmo evolucionário, para se adequar aos dados ou à aplicação de forma a obter o melhor desempenho ou o melhor resultado de busca (CHANDRASHEKAR; SAHIN, 2014), fazendo isso de forma a realizar diferentes combinações genéticas de utilizações de seus atributos. Para isso, busca-se criar diferentes indivíduos com uma probabilidade de que se relacionem entre si a cada nova geração, buscando assim gerar novos indivíduos com diferentes combinações. Sendo feito de forma que, ao mesmo tempo, os melhores de cada geração sejam guardados (elitismo) na expectativa de que consigam ou influenciar positivamente as futuras combinações ou garantir que o melhor seja preservado caso os novos gerados tenham desempenhos inferiores para que então,

como dito por (XIA et al., 2018), o AG possa encontrar a solução da seleção de atributos mais otimizada ou sub-otimizada (*optimal/sub-optimal*).

Para que isso seja possível, a operação mais comum entre os algoritmos genéticos, é o cross-over, que pode ser visualizado na Figura 4. Neste processo, existem três etapas principais e, neste caso, cada uma delas contém dois indivíduos (A e B). Conforme explicado, cada indivíduo contém a sua estrutura de cromossomos em que a utilização ou não de um atributo é retratado pelas cores branco e preto. Iniciando pela primeira etapa (1), temos a seleção destes dois indivíduos feita em primeiro momento de forma aleatória. Em seguida (2) uma recombinação genética é realizada entre os indivíduos de forma a trocar parte de suas combinações, sendo no exemplo os últimos três cromossomos dos dois indivíduos. Por fim (3), duas novas sequências são geradas com essas trocas e novos indivíduos são criados (C e D) para compor a nova população.




Figura 4 – Exemplo de Cross-Over em um Algoritmo Genético

Em determinados artigos, o processo de torneio pode ser realizado para a seleção dos indivíduos na primeira etapa e conseqüentemente para gerar novas populações de tamanho  $X$ . Este processo se resume na realização de uma quantidade de torneios baseados no tamanho da população, em que cada torneio é responsável pela seleção aleatória de  $Y$  indivíduos da população (atual) para que estes, dentro dos selecionados, com base em seu fitness, os melhores possam ser enviados a etapa de cross-over e possam gerar novos indivíduos potencialmente melhores<sup>2</sup>.

Além deste processos, durante o cross-over também existe a chamada mutação, que é a chance (a probabilidade) de um cromossomo sofrer uma mutação. Ou seja, pode ser entendida como uma probabilidade de durante ou após o processo de cross-over, um

<sup>2</sup> Neste trabalho foram realizados  $X/2$  torneios, de forma que a cada torneio os dois melhores dos  $Y$  indivíduos selecionados naquele torneio, eram selecionados e enviados ao processo de cross-over, gerando assim dois novos indivíduos que eram passados à próxima geração.

atributo aleatório de qualquer indivíduo poder parar ou começar a ser utilizado, em outras palavras, existe a chance de um atributo que estava sendo utilizado parar de ser utilizado ou o contrário. Assim, com a nova população formada através de constantes processos de torneios e cross-overs, os novos indivíduos passam a ser avaliados pelo estimador (classificador) e o processo recomeça a partir desta nova população nesta nova geração.

Sendo este processo repetido várias vezes, até determinada quantidade de gerações ou valor de fitness alcançado, a ideia é que ao final do processo evolutivo os melhores resultados devem convergir até que se encontre um subconjunto de atributos (indivíduo) que obteve um desempenho mais alto de acordo com a função de fitness. Podendo não ser a melhor solução para aquele problema, mas sim a mais “aceitavelmente boa” ou sub-otimizada dado o menor custo computacional.

## 2.2 Abordagens de Classificação

Entre as abordagens existentes, para lidar com um problema naturalmente hierárquico, como o de classificação de patologias pulmonares, algumas formas de trabalhar com a hierarquia podem ser cogitadas. Desta forma, a Figura 5 apresenta as duas abordagens, uma plana e a outra hierárquica, as quais foram utilizadas para lidar com esta hierarquia de diferentes maneiras e se encontram descritas respectivamente nas Seções 2.2.1 e 2.2.2.

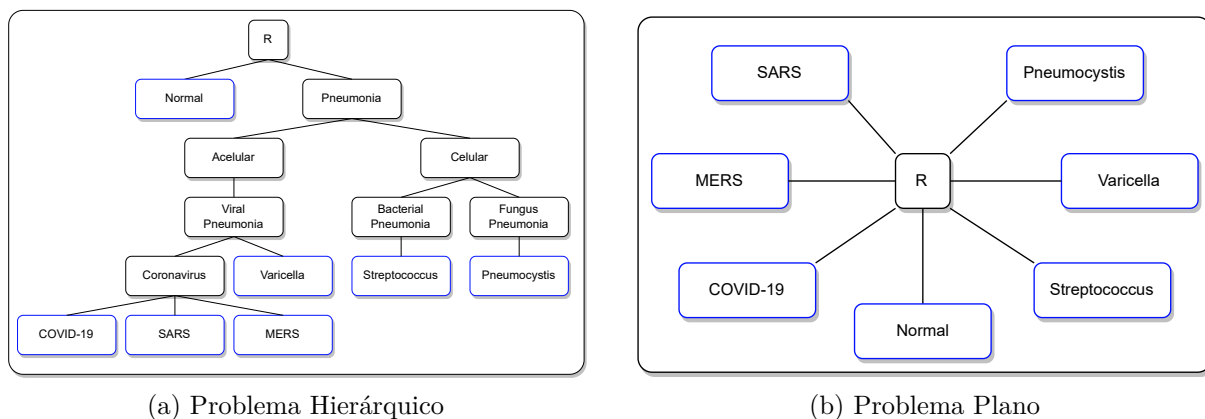


Figura 5 – Exemplo das abordagens de classificação.

### 2.2.1 Abordagem de Classificação Plana

Por abordagem de classificação plana, como dito por Silla e Freitas (2011), estamos nos referindo a problemas comuns de classificação binária ou multiclasse. Nestes problemas, enquanto nos de classificação binária existem apenas duas classes diferentes, nos problemas multiclasse existem múltiplas classes, mas com apenas uma saída por amostra (PEREIRA et al., 2020).

Deste modo, como dito por Silla e Freitas (2011), este processo consiste em ignorar completamente a hierarquia das classes (Apresentada na Figura 5b) e prever apenas as classes dos nós-folhas (Figura 5). Não havendo assim dependência ou correlação entre elas, cada classe passa a ser tratada como única sem que exista a possibilidade de mais de uma ser atrelada à resposta de uma instância, como apresentado na Figura 5b. A Figura 5b mostra um problema de classificação hierárquico que é transformado para um problema de classificação plana (Figura 5), o qual passa a apenas utilizar um único classificador sendo diretamente associado às classes finais de cada instância. Deste modo, pela Classificação Plana comumente abranger tanto classificações binárias quanto multiclasse, nesta pesquisa este termo e cenário de classificação (cenário plano) está diretamente ligado apenas a ambientes em que mais de duas classes podem existir.

### 2.2.2 Abordagem de Classificação Hierárquica

A Classificação Hierárquica consiste em um tipo de classificação em que a saída do processo de aprendizagem é definido sobre uma taxonomia de classe específica (PEREIRA et al., 2020). Em outras palavras, como visto na Figura 5a, podemos entender uma taxonomia como uma forma de agrupar classes que compartilham tipos de características em comum, ou seja, uma forma de representar associações de/entre classes em diferentes níveis de abstração (WU; ZHANG; HONAVAR, 2005).

Como dito por Silla e Freitas (2011), essa taxonomia é definida sobre um conjunto finito parcialmente ordenado  $(C, \prec)$ , onde  $C$  representa um conjunto finito que enumera todos os conceitos de classe no domínio da aplicação, e  $\prec$  a relação "é-um". Sendo ela assimétrica, antirreflexiva e transitiva para ser considerado um problema de classificação hierárquica, é necessário atender as seguintes propriedades:

- O único maior elemento "R" é a raiz da árvore.
- $\forall c_i, c_j \in C$ , se  $c_i \prec c_j$  então  $c_j \not\prec c_i$
- $\forall c_i \in C$ ,  $c_i \not\prec c_i$
- $\forall c_i, c_j, c_k \in C$ ,  $c_i \prec c_j$  e  $c_j \prec c_k$  por consequência  $c_i \prec c_k$

Desta forma, quando uma instância recebe o rótulo final de sua classificação (nó folha), ela é implicitamente/automaticamente rotulada com todos os ancestrais daquela classe (WU; ZHANG; HONAVAR, 2005), formando então sua taxonomia. E para que seja possível atingir este resultado, o processo de classificação hierárquico necessita passar por algumas definições.

Para isso Silla e Freitas (2011) criaram uma framework para ajudar a categorizar as peculiaridades de diferentes abordagens, tanto aos diferentes tipos de problemas de

classificação hierárquica, quanto como cada um lida com este processo em seu algoritmo. Assim, em relação ao problema de classificação, foi escolhido utilizar uma tupla tripla composta da seguinte forma  $\langle \Upsilon, \Psi, \Phi \rangle$ , onde:

- $\Upsilon$  especifica o tipo de grafo utilizado, entre  $\underline{T}$  (Tree) e  $\underline{D}$  (DAG - Direct Acyclic Graph).
- $\Psi$  indica se o rótulo de uma instancia vai ter apenas um ( $\underline{SPL}$  — Single Path of Labels) ou mais ( $\underline{MPL}$  — Multiple Paths of Labels) caminhos ligados a sua classificação final.
- $\Phi$  descreve a profundidade dos rótulos finais de cada instancia, sendo  $\underline{FD}$  (Full Depth labeling) utilizado caso todas as instancias sejam rotuladas até o nó folha e  $\underline{PD}$  (Partial Depth labeling) no caso de ao menos uma instancia não estar completamente rotulada, como em alguns casos em que a classe mais específica (nó folha) é desconhecida.

Ao chegar na forma em que o processo de classificação é programado (algoritmo), foi escolhido utilizar uma tupla com quatro elementos, sendo eles  $\langle \Delta, \Xi, \Omega, \Theta \rangle$ , onde:

- $\Delta$  indica se o algoritmo pode prever apenas um ( $\underline{SPP}$  - Single Path Prediction) ou mais ( $\underline{MPP}$  - Multiple Path Prediction) rótulos à uma instancia.
- $\Xi$  descreve a profundidade do algoritmo. Se  $\underline{MLNP}$  (Mandatory Leaf-Node Prediction) ele sempre irá rotular as instancias com as classes dos nós-folhas, enquanto  $\underline{NMLNP}$  (Non-Mandatory Leaf-Node Prediction) poderá rotular as instancias com as classes de qualquer nível da hierarquia.
- $\Omega$  especifica estrutura de taxonomia que o algoritmo suporta, sendo  $\underline{T}$  (Tree) ou  $\underline{D}$  (DAG).
- $\Theta$  é a forma como o algoritmo irá realizar os treinamentos e classificações. Estando entre as opções:  $\underline{LCPN}$  (Local Classifier per Parent Node);  $\underline{LCL}$  (Local Classifier per Level);  $\underline{LCN}$  (Local Classifier per Node) com suas variações; e  $\underline{GC}$  (Global Classifier).

Assim, a fim de melhor compreender como lidar com a hierarquia da Figura 5a dentro das abordagens  $\Theta$  citadas na tupla do algoritmo, elas se encontram descritas (na mesma ordem) nas subseções a-seguinte. Desta forma, ao utilizar exemplos adaptados de (SILLA; FREITAS, 2011) no lugar do problema das patologias, a ideia é reduzir a complexidade do modelo para melhor entendimento das abordagens.

### 2.2.2.1 Local Classifier per Parent Node

As abordagens locais tem como diferencial a utilização das informações da hierarquia, de forma local. Sendo no caso da abordagem LCPN (utilizada nesta pesquisa), "informação local" considerado como a informação que cada nó pai tem sobre seus filhos.

Assim, durante a fase de treinamento, essa é a abordagem em que para cada nó pai na hierarquia das classes, um classificador multi-classe é treinado para distinguir entre seus nós-filhos (SILLA; FREITAS, 2011), como é possível ver na Figura 6. Nela essa relação entre nó-pai e classificador multi-classe é ilustrada pelo pontilhado laranja, enquanto os nós-folhas (classe final a ser prevista) pela cor azul.

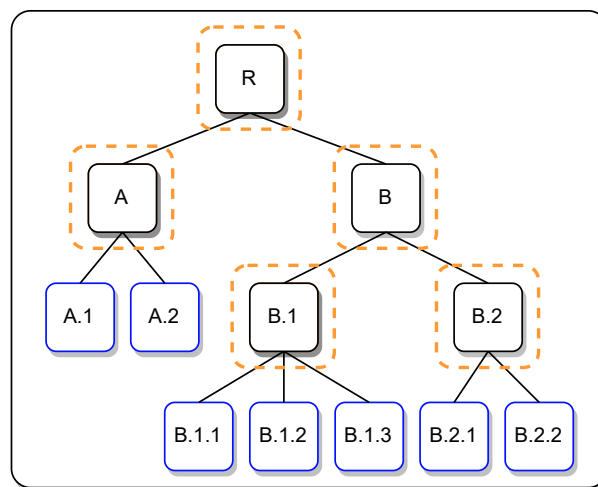


Figura 6 – Exemplo LCPN Adaptado de (SILLA; FREITAS, 2011) - Pontilhado representa os *classificadores*, enquanto os nós em preto os *nós-internos* e os azuis os *nós-folhas*.

Então, ao se treinar um classificador na Raiz (R), ele deverá considerar apenas as classes A e B, fazendo parte de cada uma delas todos seus filhos, sendo isso repetido para cada nó pai. Assim, ao chegar no nó B.2 ele apenas será treinado para distinguir entre B.2.1 e B.2.2.

Desta forma, ao se passar para uma etapa de classificação/previsão ela é realizada de forma a utilizar a abordagem *top-down* em que a nova instancia desconhecida começa na raiz, passa a ser classificada como A ou B, e segue descendo sendo classificada localmente até que se atinja um nó folha.

### 2.2.2.2 Local Classifier per Level

A Abordagem LCL, consiste em treinar um classificador multi-classe para cada nível da hierarquia de classes (SILLA; FREITAS, 2011). Desta forma seguindo o exemplo na Figura 7, por haver três níveis na hierarquia, três classificadores multi-classe passam a ser utilizados, sendo cada um deles treinados com as informações (locais) daquele nível e indicados pelo pontilhado laranja.

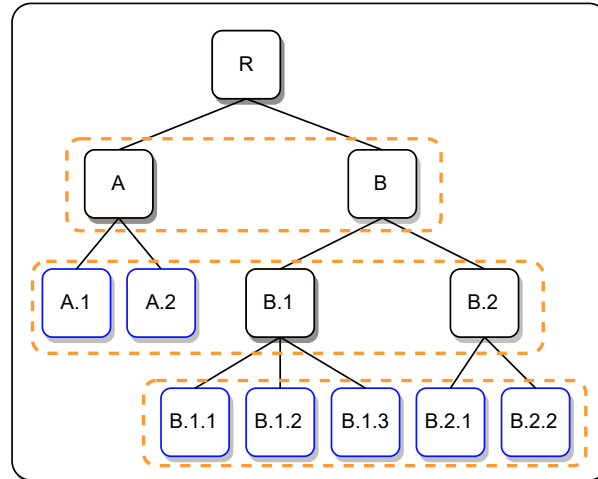


Figura 7 – Exemplo LCL Adaptado de (SILLA; FREITAS, 2011) - Pontilhado representa os *classificadores*, enquanto os nós em preto os *nós-internos* e os azuis os *nós-folhas*.

Então, ao entrar em uma etapa de classificação/previsão são obtidos resultados para os classificadores de todos os níveis, o que pode levar a inconsistências. Pois ao mesmo tempo em que o 1º classificador pode identificar a nova instância como sendo A, o 2º classificador pode identificá-la como sendo B.2. Desta forma, Silla e Freitas (2011) sugerem mais uma vez a utilização da abordagem *top-down*, considerando-a como uma forma de restrição de respostas aos classificadores apenas aos nós-filhos do nó anteriormente previsto. Assim, caso previsto como A no 1º classificador, o 2º ficaria restrito apenas às respostas A.1 e A.2.

### 2.2.2.3 Local Classifier per Node

A Abordagem LCN consiste em treinar um classificador binário para cada nó da hierarquia de classes, desconsiderando o nó raiz (SILLA; FREITAS, 2011). Representado mais uma vez pelo pontilhado laranja, a Figura 8 apresenta os 11 classificadores binários que seriam necessários para resolver o seguinte problema. Porém para que seja possível realizar o treinamento destes classificadores, algumas regras (*policies*) precisam ser consideradas para determinar o que pertence ou não à cada nó/classificador.

Estando entre as opções: *Exclusive*; *Less Exclusive*; *Less Inclusive*; *Inclusive*; *Siblings*; *Exclusive Siblings*. Cada uma destas regras irá determinar o que deverá ser considerado positivo ou negativo em cada um dos classificadores existentes, decidindo assim se irmão, filhos ou sobrinhos vão de alguma forma fazer parte de sua classificação. Assim, independente de como os exemplos positivos e negativos foram escolhidos, segundo Silla e Freitas (2011), durante uma etapa de classificação/previsão cada classificador binário irá retornar se uma determinada amostra de teste pertence ou não aquele classificador em específico.






Figura 8 – Exemplo LCN Adaptado de (SILLA; FREITAS, 2011) - Pontilhado representa os *classificadores*, enquanto os nós em preto os *nós-internos* e os azuis os *nós-folhas*.

Podendo então ser levado a inconsistências como em LCL, a possibilidade de um novo exemplo ser previsto como *positivo* para B.2.1 e *falso* para B.2 passa a existir. Assim, a forma de previsão *top-down*, mais uma vez aparece entre as alternativas para resolver estes problemas de forma que para cada nível da hierarquia, a decisão sobre qual classe é prevista no nível atual é baseada na classe prevista no nível anterior (pai) (SILLA; FREITAS, 2011).

#### 2.2.2.4 Global Classifier

Na abordagem GC apenas um modelo é construído a partir dos dados de treinamento, levando em consideração a hierarquia das classes como um todo durante o processo de classificação (PEREIRA et al., 2020). Ilustrado pelo pontilhado laranja na Figura 9, este modelo único parte do pressuposto de que aprender um único modelo global para todas as classes tem a vantagem de que seu tamanho total será consideravelmente menor em comparação com o tamanho total de todos os modelos aprendidos por qualquer uma das abordagens locais (SILLA; FREITAS, 2011).

Assim, para realizar uma nova classificação/previsão podem existir variações. Sendo utilizado por (PEREIRA et al., 2020) o Clus-HMC<sup>3</sup>, este modelo busca construir um conjunto de árvores de classificação para prever um conjunto de classes ao invés de apenas uma, transformando assim a saída de sua classificação em um vetor com componentes *booleanos* correspondentes as possíveis classes, além de levar em consideração o uso de uma métrica baseada em distância para calcular quão semelhantes ou diferentes os exemplos de treinamento são na árvore de classificação (SILLA; FREITAS, 2011).

<sup>3</sup> Clus-HMC Framework: <<https://dtai.cs.kuleuven.be/clus/>>

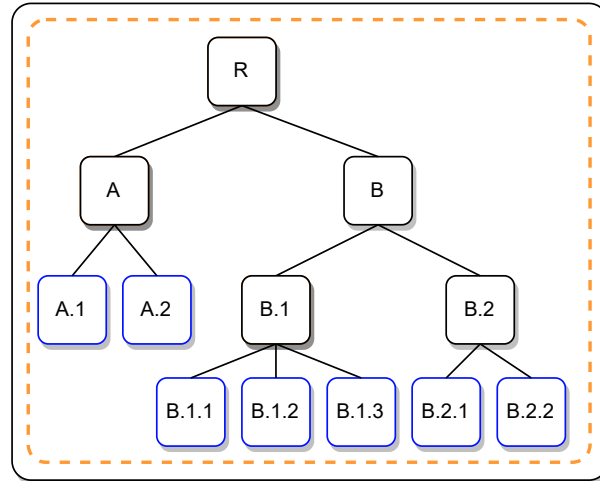


Figura 9 – Exemplo Global Adaptado de (SILLA; FREITAS, 2011)

## 2.3 Classificadores

Para realizar as classificações tanto no cenário plano quanto as presentes em cada nó-pai do cenário hierárquico, os classificadores Decision Tree (DT); k-Nearest Neighbors (KNN); Multilayer Perceptrons (MLP); Random Forest (RF); e Support Vector Machine (SVM) foram utilizados.

Eles foram selecionados por serem utilizados por Pereira et al. (2020) no artigo base para esta pesquisa, sendo aplicados de forma a replicar os parâmetros utilizados neste mesmo artigo para que fosse possível comparar o impacto da aplicação dos métodos de seleção de atributos em suas classificações. Assim, seguindo a ordem em que foram descritos, cada um deles contém uma breve explicação a seguir.

### 2.3.1 Decision Tree (DT)

*Decision Tree Classifier* (BREIMAN et al., 1984) é um classificador que dispõe de todos os atributos da base de treino para a criação de seu modelo que, durante esta etapa, busca entender a importância de cada um para que seja possível realizar divisões baseadas na capacidade de generalização dos atributos disponíveis (ALY, 2005). Ele classifica uma instancia descendo do nó raiz até atingir algum nó folha, que fornece a classificação final dessa instância, sendo que em cada nó desta árvore o teste de algum atributo desta instancia é efetuado, e cada ramificação descendente daquele nó corresponde a um dos valores possíveis para este atributo (MITCHELL, 1997).

Assim, como pode ser visto na Figura 10, podemos entender uma árvore de decisão como um fluxograma que ao testar/prever uma nova instancia, segue um caminho pré-definido com base na fase de treinamento.

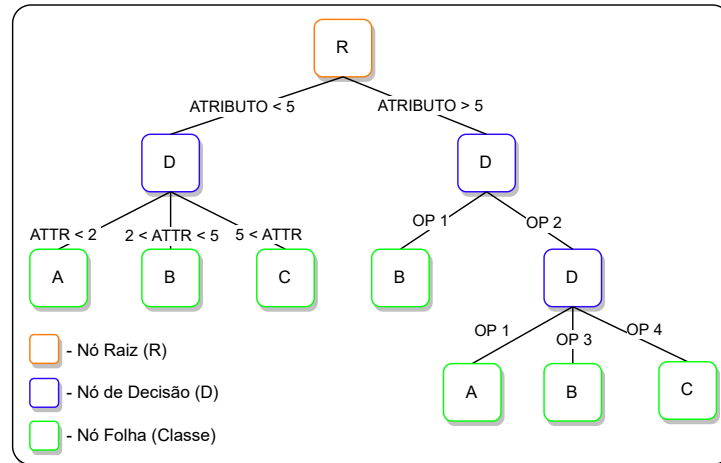


Figura 10 – Exemplo de DT

### 2.3.2 k-Nearest Neighbors (KNN)

Diferente de boa parte dos classificadores, o *k-Nearest Neighbors* não realiza a construção de um modelo para obtenção de resultados. O que acontece na verdade é que ele parte da suposição de que observações que estão próximas (em alguma métrica apropriada) terão a mesma classificação (COVER; HART, 1967). Assim, para classificar uma nova instância, ele mede a distância (usando alguma medida de distância, ex. euclidiana) deste exemplo com todos os outros exemplos de treinamento (ALY, 2005), podendo também sofrer variações como em *KDTree* (MOORE, 1991) e *BallTree* (OMOHUNDRO, 1989) que buscam formas alternativas de otimizar essas tentativas por "força bruta".

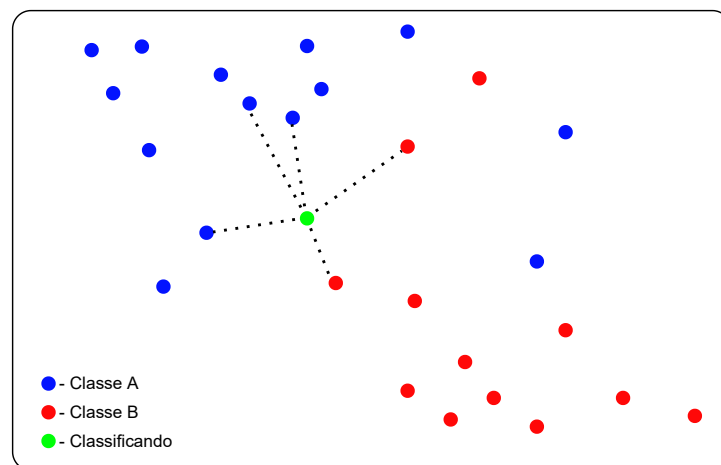



Figura 11 – Exemplo de KNN

Desta forma, como pode ser visto na Figura 11, a etapa de teste se resume a verificar quem são os  $k$  vizinhos mais próximos da instância desejada. Sendo estes "vizinhos" as instâncias da base de treino já rotuladas, ou um conjunto de validação que seria responsável por avaliar a qualidade da classificação avaliando diferentes números de vizinhos, o KNN assume que por essa instância desejada estar mais próxima a X, Y ou Z, ela também

pertence àquela classe, classificando-a com o rótulo mais frequentemente entre as  $k$  amostras mais próximas (DUDA; HART; STORK, 2012).

### 2.3.3 Multilayer Perceptron (MLP)

*Multilayer Perceptron* é um modelo de rede neural inspirado na estrutura e função do cérebro que aprende com os dados e se especializa no reconhecimento de padrões (SOUI et al., 2021). Ou como dito por Phil Kim (2017), uma rede neural é uma rede de nós que imitam os neurônios do cérebro, os quais calculam a soma ponderada dos sinais de entrada e produzem o resultado da função de ativação com essa soma. Porém, para compreendê-lo se faz necessário entender primeiro o que é um neurônio, pois (em tradução livre) MLP nada mais é do que "várias camadas de neurônios". Assim, como pode ser visto na 12a, um neurônio é composto por valores de entrada ( $x$ ), pesos ( $w$ ), um bias ( $b$ ) e uma função de ativação ( $\varphi$ ). Sendo então um modelo matemático, esta figura exemplifica a sua função de combinar matematicamente estes valores que, em uma rede neural, serão em seguida processados por uma função de ativação a qual determinará o comportamento do neurônio em específico (Phil Kim, 2017).



(a) Ex. Neurônio.

(b) Ex. Rede Neural (MLP).

Figura 12 – Exemplos adaptados de (Phil Kim, 2017)

Desta forma, seguindo a Figura 12b, é possível identificar o funcionamento de uma rede neural começando pela entrada (quadrados), passando pelos neurônios (círculos) nas camadas ocultas e finalizando com os presentes na camada de saída. Se movendo assim da esquerda para a direita (de trás para frente), as operações matemáticas acontecem em cada um deles, respeitando a ordem e ligação das camadas seguindo isso até que se chegue ao final e ao resultado previsto pelo modelo. Com o resultado obtido, durante o processo de treinamento, a comparação com o rótulo original/verdadeiro irá ocorrer. Caso a previsão esteja correta nada acontece, porém se a previsão não for correspondente ao rótulo original, será produzido um erro e este erro será propagado na direção inversa (de frente para trás) recebendo o nome de algoritmo backpropagation. Com isso, o algoritmo

backpropagation permite que os pesos (de cada neurônio) sejam ajustados para reduzir o erro, repetindo este processo até que o erro se torne zero (SOUI et al., 2021).

### 2.3.4 Random Forest (RF)

*Random Forest* é uma combinação de classificadores de árvores em que cada árvore depende dos valores de um vetor de amostragem aleatória independente que contém a mesma distribuição de todas as árvores da floresta (BREIMAN, 2001). Em outras palavras, este classificador contém várias árvores de decisões, as quais individualmente recebem diferentes subconjuntos de combinações aleatórias das características existentes, o que permite realizarem suas divisões apenas para aquele contexto recebido ao invés de considerar todas as divisões possíveis como em uma árvore de decisão normal, garantindo assim uma baixa correlação entre elas. Ao combinar os resultados das diferentes árvores, o processo recebe, e é conhecido pelo, o nome de *ensemble learning* e parte da ideia de que ao combinar vários modelos, os erros de um provavelmente serão compensados por outros, e como resultado, o desempenho geral de previsão do ensemble será melhor do que quando usado um único classificador (SAGI; ROKACH, 2018).

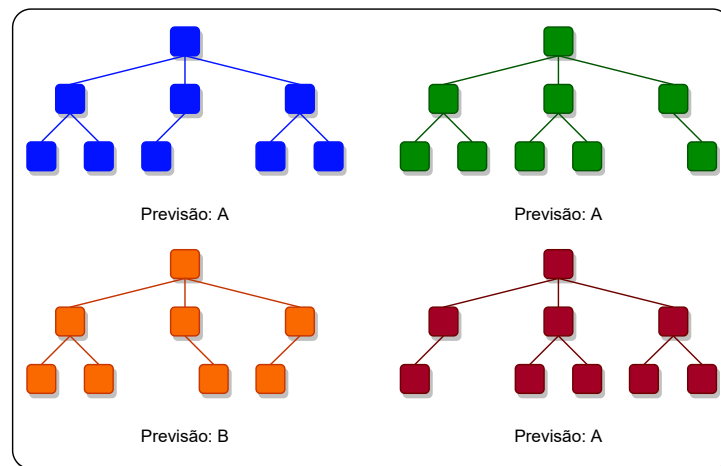


Figura 13 – Exemplo de RF

Desta forma, conforme dito em Sagi e Rokach (2018), ao usar um grande número de árvores de decisões independentes e não podadas, para que elas se mantenham precisas, certa aleatoriedade é adicionada aos classificadores usando dois processos de randomização. Sendo eles: em relação a uma amostragem das instâncias de treino a serem utilizadas na construção de cada árvore; e à disponibilidade dos atributos para que sejam realizadas as divisões em cada nó.

Assim, ao realizar as classificações depois que um grande número de árvores é gerado, eles votam na classe mais popular (BREIMAN, 2001). Pois, por uma instância ter sido testada em todos os modelos, e por eles terem sido criadas a partir de subconjuntos diferentes tanto de instâncias quanto de atributos, resultados diferentes podem ser obtidos.

### 2.3.5 Support Vector Machine (SVM)

Em *Support Vector Machine* os valores de entrada são mapeados não linearmente em um espaço de atributos de alta dimensão onde uma superfície de decisão linear é construída, que devido suas propriedades especiais de decisão garantem alta capacidade de generalização (CORTES; VAPNIK, 1995). Assim, como explicado por Duda, Hart e Stork (2012), o objetivo do treinamento de um SVM é encontrar o hiperplano de separação com a maior margem; esperando que quanto maior a margem, melhor a generalização do classificador.

Desta forma, como visto no exemplo da Figura 14 ao buscar separar duas classes com apenas uma reta, a margem desejada passa a ser a distância entre a reta central em **negrito** e as outras duas paralelas (nos dois lados) em que se encontram as primeiras instâncias mais próximas de cada classe.




Figura 14 – Exemplo de SVM adaptado de (DUDA; HART; STORK, 2012)

Por ser um classificador binário, para que seja possível utilizá-lo em um cenário multi-classe se faz necessário a utilização de uma abordagem que possibilite decompor o problema. Neste contexto uma abordagem comum é a One-Vs-Rest/OVR (também conhecida por One-Vs-All e Um-Contra-Todos), em que o problema é transformado em  $K$  classificações binárias a partir das  $K$  classes existentes, desta forma cada uma das classificações separa uma classe (positiva) das outras  $K - 1$  classes (negativas) (ALY, 2005). Sendo a classificação de uma nova instância feita por todos os modelos, ganha o modelo com maior probabilidade de pertencimento (positivo) de certa classe.

Em contrapartida, a abordagem One-Vs-One/OVO (também conhecida por All-Vs-All e Todos-Contra-Todos) busca comparar cada classe entre si em um classificador binário entre cada par de classe, sendo assim uma abordagem mais custosa. Então para testar um novo exemplo, uma votação é feita entre os classificadores, e a classe com maior quantidade de votos vence (é selecionada) (ALY, 2005).

## 2.4 Métricas e Análise

Para que seja possível entender o resultado de um classificador, é preciso analisar sua performance e real desempenho através de algumas métricas, estando entre as mais comuns o uso da acurácia. Porém, ao lidar com um cenário desbalanceado é necessário evitar seu uso, pois um classificador que é muito eficaz na previsão da classe majoritária, mas erra a boa parte das instâncias minoritárias, pode facilmente ter uma acurácia muito alta. (MARATEA; PETROSINO; MANZO, 2014).

Por essa razão *Macro-Average F1-Score* é utilizada no lugar da acurácia, porém para ser possível compreendê-la se faz necessário a explicação de outras métricas que a compõem. Com isso, as Subseções 2.4.1, 2.4.2, 2.4.3 e 2.4.4 contam respectivamente com a explicação das métricas *Precision*, *Recall*, *F1-Score* e enfim *Macro-Avg F1-Score*.

### 2.4.1 Precision

A métrica *Precision* (em português Precisão) calcula a porcentagem de acertos obtidos em uma classe em relação a quantidade de instâncias ditas pertencer a (previstas como) ela. Ou como dito por Vateekul, Kubat e Sarinnapakorn (2014): é a porcentagem de exemplos verdadeiramente positivos entre aqueles rotulados como tais pelo classificador. Sendo assim calculada pela Equação 2.3 com seus valores vindo da matriz de confusão, Verdadeiro Positivo (VP) e Falso Positivo (FP).

<b>A</b>	12	0	15	0
<b>B</b>	0	1	2	0
<b>C</b>	0	0	299	0
<b>D</b>	2	0	0	0
	<b>A</b>	<b>B</b>	<b>C</b>	<b>D</b>

Figura 15 – Calculando Precision

Para exemplificar, a Figura 15 nos apresenta uma matriz de confusão multi-classe. Indo de A até D, podemos calcular a precisão de uma classe utilizando a Equação 2.3 citada e atualizar seus valores como pode ser visto na Equação 2.4, ou então, de maneira visual dividir o valor na caixa verde (VP=12) pela soma dos valores na caixa laranja (VP=12 + FP=(0+0+2)). Obtendo assim o resultado aproximado de  $Pr \approx 0,86$  para a classe A.

$$Pr = \frac{VP}{VP + FP} \quad (2.3)$$

$$Pr = \frac{12}{12 + (0 + 0 + 2)} \approx 0,86 \quad (2.4)$$

### 2.4.2 Recall

A métrica *Recall* (em português Revocação) calcula a porcentagem de acertos obtidos em uma classe em relação a quantidade de instâncias que realmente pertenciam a ela. Ou como dito por Vateekul, Kubat e Sarinnapakorn (2014): é a porcentagem de exemplos positivos que foram reconhecidos ("*recalled*") como tais pelo classificador. Sendo assim calculada pela Equação 2.5 com seus valores vindo da matriz de confusão, Verdadeiro Positivo (VP) e Falso Negativo (FN).

A	12	0	15	0
B	0	1	2	0
C	0	0	299	0
D	2	0	0	0
	A	B	C	D

Figura 16 – Calculando Recall

A Figura 16 nos mostra o mesmo exemplo multi-classe de Precision, porém contornando os valores utilizados para o cálculo do Recall. Seguindo equação 2.5, ao atualizar os valores chegamos a Equação 2.6 que também pode ser calculada de maneira visual, dividindo o valor contornado em verde (VP=12) pela soma dos valores contornados em laranja (VP=12 + FN= (0+15+0)). Obtendo então o resultado aproximado de  $Re \approx 0,44$  para classe A.

$$Re = \frac{VP}{VP + FN} \quad (2.5)$$

$$Re = \frac{12}{12 + (0 + 15 + 0)} \approx 0,44 \quad (2.6)$$



### 2.4.3 F1-Score

A métrica *F1-Score* fornece uma maneira de combinar recall e precision para obter uma única medida que fica entre recall e precision (CHINCHOR, 1992), que pode ser entendida como uma média harmônica entre as duas.

$$F1 = \frac{(\beta^2 + 1, 0) * Pr * Re}{\beta^2 * Pr + Re} = \frac{2 * Pr * Re}{Pr + Re} \quad (2.7)$$

$$F1 = \frac{2 * 0,86 * 0,44}{0,86 + 0,44} = \frac{0,7568}{1,3} \approx 0,58 \quad (2.8)$$

Calculado pela Equação 2.7 sendo *Precision (Pr)* e *Recall (Re)*, uma vez que ambos tem a mesma importância,  $\beta$  passa a assumir valor 1,0 (CHINCHOR, 1992). Assim, seguindo o mesmo exemplo das métricas anteriores, o valor de F1 para a classe A pode ser calculado, sendo seu resultado  $F1 \approx 0,58$  obtido através da aplicação dos valores na equação 2.7 que resulta nos cálculos presentes na equação 2.8 com os respectivos valores e resultados.

### 2.4.4 Macro-Avg F1-Score

A métrica *Macro Average F1-Score* é uma forma de agrupar os resultados de todas as métricas, calculadas individualmente para cada classe, apresentadas anteriormente. Pois, para que seja possível obter uma análise dos experimentos como um todo, o uso de uma métrica que resuma/reúna os valores destas outras (calculadas por classe) em um único número se faz necessário.

Contendo uma versão conhecida por Micro-Avg, a diferença entre elas está na importância dada a cada classe em seu cálculo. Enquanto a versão micro dá um peso à cada classe relativo a sua frequência (quantidade de instâncias), a versão macro considera pesos iguais para todas elas (VATEEKUL; KUBAT; SARINNAPAKORN, 2014). Desta forma, ao lidar com um cenário desbalanceado todas as classes passam a ser igualmente importantes, tendo o mesmo peso na equação.

$$Mavg = \frac{\sum_{j=1}^l F1_{.j}}{l} \quad (2.9)$$

$$Mavg = \frac{(0,58 + 0,50 + 0,97 + 0,00)}{4} \approx 0,51 \quad (2.10)$$

Calculada pela Equação 2.9, o valor de Macro-Avg pode ser atingido pela somatória dos resultados de F1-Score de cada uma das classes ( $j$ ) divididos pela quantidade de classes existentes ( $l$ ). Desta forma, considerando o exemplo utilizado até o momento temos

os seguintes valores de F1-Score: Classe A(0,58); Classe B(0,50); Classe C(0,97); Classe D(0,00).

Assim, atualizando a Equação 2.9 com os valores atuais, a Equação 2.10 pode ser ilustrada e o resultado do exemplo obtido a partir de seu cálculo. Então, por utilizar métricas sensíveis à desbalanceamento, passamos a ter um resultado aproximado de 0,51 (macro-avg) no lugar de 0,94 (acurácia) ou 0,94 (micro-avg) para ser comparado entre diferentes experimentos, em que 1,00 é o melhor resultado.

## 3 TRABALHOS RELACIONADOS

Neste capítulo são apresentados trabalhos relacionados à tarefa de seleção de atributos ao lidar com classificação de covid-19. Sendo limitado à trabalhos que explicitamente utilizavam *seleção de atributos* e *covid* em seus títulos, para serem considerados relevantes, foi considerado como um pré-requisito de que em algum momento de seu texto (ex. relacionados) eles comentassem sobre outros trabalhos que usaram raios X, e com isso a seguinte string de busca foi utilizada: *intitle:"feature selection"AND intitle:"covid"AND x-ray*. Desta forma, com a última atualização de busca sendo feita ao final de julho de 2022, 29 pesquisas foram obtidas e destas apenas 25 foram selecionadas.

Assim, o presente capítulo conta com duas contribuições principais a partir destas buscas, sendo elas: a sumarização das bases de dados utilizadas nestas pesquisas contando com tamanho, quantidade de classes e distribuição das amostras quando disponível; e a sumarização das pesquisas em si, as quais buscaram aplicar a seleção de atributos para a detecção de covid-19 contando assim com a fácil comparação entre os métodos utilizados entre elas, melhores resultados obtidos e categorização entre métodos e metodologias utilizadas. Com isso, essas contribuições se encontram respectivamente nas Seções 3.1 e 3.2.

### 3.1 Bases de Dados

Buscando agrupar as bases de dados, a Tabela 1 apresenta a sumarização de todas as bases utilizadas nos trabalhos relacionados presentes na próxima seção. Nesta tabela é possível visualizar em cinco colunas as informações sobre estas bases, sendo elas: a categorização delas pelo tipo de dado presente; seu nome e referência original quando disponível; a contagem total de imagens/amostras e seu detalhamento entre as classes disponíveis; e um identificador único para futura comparação e detalhamento dos artigos que as utilizaram (apresentados na Seção 3.2).

Com a atualização desta tabela de jun/2021 para jul/2022 é possível ver um aumento de 12 bases sendo utilizadas nos novos artigos publicados neste período, equilibrando assim a quantidade de bases utilizadas para aplicação de seleção de atributos. Resultando em 6 bases de *raios X*, 5 bases de *CT* e 8 bases contendo amostras de *Dados dos Pacientes e/ou Demográficos*, uma novidade foi o uso de amostras de *Sangue* para o mesmo fim, contendo no caso apenas 2 bases.

Deste modo, outra possível análise a partir desta tabela é a quantidade de classes existentes em cada uma delas, sendo mais comum o uso apenas de duas classes que se faz

presente em 12 bases, ou seja, em mais da metade delas. Essa quantidade é seguida pelo uso de três classes em 5 bases e duas bases contendo 5 e 7 classes, havendo também duas bases com essas informações indisponíveis. No caso das bases com maiores quantidades de classes, a B10 que contém cinco classes possui seu foco em diferentes estágios das anormalidades do tecido pulmonar, enquanto a B21 que contém sete classes busca fazer a previsão entre essas doenças sem que necessariamente sejam relacionadas à pneumonia/covid-19 ou mesmo entre elas. Com isso, é possível afirmar de que o presente trabalho é o único, até onde sabemos, que até o momento utiliza uma base de dados contendo amostras de 7 classes sendo uma normal e seis tipos de patologias pulmonares que podem ser organizadas hierarquicamente por serem subtipos de pneumonia (6 das 7 classes), ao utilizar seleção de atributos na tarefa de detecção de covid-19.

Tabela 1 – Bases de Dados Utilizadas nos Trabalhos Relacionados

TIPO DE DADO	BASE DE DADOS E REFERENCIA	CONTAGEM DE	AMOSTRAS / CLASSES	BASE ID
<b>Raios X</b>	Do trabalho de (NARIN, 2021)	2.905 imagens	219 COVID-19 1.341 Normal 1.345 Pneumonia	B 01
	Do trabalho de (REDDY; NASIRI; ALAVI, 2022)	1.125 imagens	125 COVID-19 500 No-findings 500 Pneumonia	B 02
	Do trabalho de (MOHAMMED et al., 2021)	110 imagens	55 COVID-19 55 Normal	B 03
	Do trabalho de (ASLAN et al., 2022)	15.153 imagens	10.192 Normal 1.345 Viral Pneumonia 3.616 COVID-19	B 04
	MH-COVIDNet (CANAYAZ, 2021)	1.092 imagens	364 Covid 364 Pneumonia 364 Normal	B 05
	Novel COVID-19 Chestxray Repository (BHOWAL; SEN; SARKAR, 2021)	3.975 imagens	752 COVID-19 1.639 Normal 1.584 Pneumonia	B 06
<b>CT</b>	COVID-CT-Dataset (YANG et al., 2020)	746 imagens	349 COVID-19 463 healthy	B 07
	Do trabalho de (SUN et al., 2020)	2.522 imagens	1.495 COVID-19 1.027 CAP	B 08
	Do trabalho de (EL-KENAWY et al., 2020)	1.128 imagens	334 COVID-19 794 non-COVID-19	B 09
	MOSMED dataset (MOROZOV et al., 2020)	1.110 persons	254 CT0 (Zero) 684 CT1 (Mild) 125 CT2 (Moderate) 45 CT3 (Severe) 2 CT4 (Critical)	B 10
	SARS-CoV-2 CT-scan (SOARES et al., 2020)	2.482 imagens	1.252 COVID-19 infected 1.230 non-infected	B 11
<b>Sangue</b>	Pre_Surv_COVID_19 (YAN et al., 2020)	375 amostras	174 individuals died 201 individuals survived	B 12
	COVID-19 and Clinical Spectrum (Hospital Israelita Albert Einstein, 2020)	5.644 amostras	5.086 SARS-Cov-2 negative 558 SARS-Cov-2 positive	B 13
<b>Dados do Paciente e/ou Demograficos</b>	A COVID-19 Prediction Model Using Symptoms (ZOABI; DERI-ROZOV; SHOMRON, 2021)	99.232 amostras	8.393 COVID-19 90.839 not COVID-19	B 14
	Covid-19-Patient-Health-Analytics (IWENDI et al., 2020)	1085 amostras	Death Recovered	B 15
	Clinical Data Repository Carbon Health e Braid Health (2020)	630 amostras	315 positive 315 negative	B 16
	Do trabalho de (ALI; ABDUSALAM, 2021)	8.571 amostras	-	B 17
	Do Trabalho de (MUSTAFA et al., 2021)	99.778 amostras	Death Recovered	B 18
	predCOVID-19 (SCHWAB et al., 2020)	5.644 amostras	-	B 19
	Patient Medical Data for Novel Coronavirus COVID-19 (Wolfram Research, 2020)	1.495 amostras	757 COVID-19 738 not COVID-19	B 20
	Do Trabalho de (DUTTA et al., 2021)	1.588 amostras	182 Jaundice 203 Malaria 352 Covid 19	B 21
			179 Common fever 224 Typhoid 197 Dengue 251 Pneumonia	

## 3.2 Artigos Relacionados

Buscando entender o que já foi feito no cenário acadêmico em relação a aplicação de métodos de seleção de atributos para potencializar a classificação de covid-19, a Tabela 2 contém a sumarização de 25 pesquisas e possibilita a comparação direta entre elas em relação a:

- O tipo de dado e base de dados utilizado através do identificador apresentado na Tabela 1;
- Sua proposta ao utilizar métodos existentes ou o desenvolvimento de métodos ou metodologias novas;
- A disponibilidade do código através de um link ou pseudocódigo no artigo;
- A técnica de extração, seleção e classificação;
- A utilização de *HoldOut* ou *CrossValidation*;
- O resultado alcançado em relação à Acurácia e F1-Score quando disponível.

Assim, ao analisar a tabela é possível ver que com os novos artigos publicados a quantidade de tipo de dado utilizado, para a aplicação de seleção de atributos, também se estabilizou resultando em 7 artigos utilizando *raios X*, 7 artigos utilizando *CT*, 9 artigos utilizando *Dados dos Pacientes e/ou Demográficos (P&D)*, além dos 2 artigos que passaram a utilizar amostras de *Sangue*. Em relação às bases de dados mais utilizadas temos a B07, B11 e B15 que estiveram presentes em 3 pesquisas da tabela, sendo seguidos apenas pela B05 que foi utilizada em 2 artigos e todas as outras que foram utilizadas apenas uma vez. Por fim, devido a constantes atualizações das bases e diferentes etapas de pré-processamento, a quantidade de imagens/amostras utilizadas nos artigos podem ser diferentes dos disponibilizados pelas bases presentes na Tabela 1 e lincadas diretamente pela referência original. Seguindo essa lógica, de forma a melhor apresentar a tabela principal e, ao mesmo tempo, agrupar os métodos utilizados, a Tabela 3 contém as siglas e nomes completos de todos os métodos citados na Tabela 2.

Uma vez que buscamos agrupar trabalhos que aplicaram a seleção de atributos para resolver/otimizar o problema de classificação independente do tipo de dado, existe uma divisão natural entre as pesquisas que necessitaram, ou não, realizar uma etapa de extração de características. Deste modo, os artigos que utilizaram de imagens de raios X e CT (que representam 14 dos 25) precisaram convertê-las e as técnicas utilizadas para isso encontram-se detalhadas na Tabela 2, enquanto nos trabalhos que utilizaram P&D e Sangue (que representam os outros 11) isso não se fez necessário e se encontram indicados

pelas iniciais DB<sup>1</sup> na mesma tabela, se fazendo mais comum entre estes artigos o uso de CNN para a realização deste processo. Com isso, é importante ressaltar de que uma vez que o foco desta análise está voltado ao processo de seleção e classificação, contando com uma pequena verificação dos processos de extração, técnicas adjacentes (como *enhancement*, *sampling*, *pré-treinamento de cnn*, ...) que podem ter sido realizadas por algumas pesquisas em etapas de pré-processamento, ou outras, foram deixadas de lado e não se encontram na tabela.

Apesar de algumas técnicas de extração já conterem uma forma de filtrar características/atributos, todos os artigos realizaram uma forma de seleção posterior, sendo assim interessante categorizá-los pela sua proposta em si, podendo ser: (X) apenas utilizar métodos existentes, (Y) o desenvolvimento de um novo método ou (Z) o desenvolvimento de uma metodologia e/ou categorização como framework ao utilizar (X) ou (Y). Formando assim os seguintes grupos:

- (X) o grupo dos que apenas utilizaram métodos existentes (NARIN, 2021; MOHAMMED et al., 2021; KHAN et al., 2021; CHAUHAN; MODI; SHRIVASTAVA, 2022; DENIZ et al., 2022; ALI; ABDULSALAM, 2021)
- (Y) o grupo dos que apenas desenvolveram ou otimizaram métodos (TOO; MIRJALILI, 2021b);
- (Z, X) o grupo dos que desenvolverem metodologias utilizando métodos existentes (SEN et al., 2021; SYED; KHAN; ALROMEMA, 2022; SEN et al., 2021; SYED; KHAN; ALROMEMA, 2022; REDDY; NASIRI; ALAVI, 2022; BHOWAL; SEN; SARKAR, 2021; AHMED et al., 2022; DUTTA et al., 2021; BANDYOPADHYAY et al., 2021; CANAYAZ, 2021; DEY et al., 2021; ASLAN et al., 2022; SOUI et al., 2021; DENIZ et al., 2022; MUSTAFA et al., 2021);
- (Z, Y) o grupo dos que desenvolverem metodologias e métodos (ALSAEEDI; KURNAZ, 2022);
- (Z, X, Y) o grupo dos que desenvolverem metodologias e utilizaram tanto métodos existentes quanto novos (SHABAN et al., 2020, 2020; ROSTAMI; OUSSALAH, 2022; SUN et al., 2020; OZYURT; TUNCER; SUBASI, 2021; EL-KENAWY et al., 2020);

Com isso, os trabalhos que se encontram brevemente descritos abaixo levam em consideração o escopo da pesquisa ao filtrar apenas os mais relacionados, ou seja, que empregam seleção de atributos em imagens de raios X, sendo eles os trabalhos de (REDDY; NASIRI; ALAVI, 2022; BHOWAL; SEN; SARKAR, 2021; NARIN, 2021; MOHAMMED et al., 2021; KHAN et al., 2021; CANAYAZ, 2021; ASLAN et al., 2022).

<sup>1</sup> Uma abreviação equivalente a Dado Bruto.

Em Reddy, Nasiri e Alavi (2022), sua ideia é criar uma nova framework utilizando os métodos já existentes para que possa ajudar radiologistas a diagnosticar covid-19 através de imagens de raios X ao utilizar *DenseNet169* para extrair características das imagens, *Análise de Variância (ANOVA)* para reduzir custo computacional, e *eXtreme Gradient Boosting (XGBoost)* para realizar a etapa de classificação. Sendo realizados testes em dois cenários, o primeiro buscou analisar a proposta utilizando apenas duas classes (*covid-19, no-findings*) atingindo uma acurácia de 98.72%, enquanto o segundo buscou fazer os mesmos testes utilizando três classes (*covid-19, no-findings e pneumonia*) atingindo uma acurácia de 92%.

Assim, seguindo a linha dos trabalhos que desenvolveram uma metodologia, Canayaz (2021) faz isso ao propor sua abordagem baseada em *deep learning* quando antes de realizar o processo de extração, com *AlexNet, VGG19, GoogleNet e ResNet*, busca melhorar o contraste das imagens para então após a extração aplicar os métodos meta-heurísticos *Binary Particle Swarm Optimization (BPSO)* e *Binary Gray Wolf Optimization (BGWO)* para selecionar os melhores atributos para a classificação. Deste modo, a acurácia de 99,38% foi alcançada ao combiná-los com uma classificação utilizando um SVM na tarefa de previsão de 3 classes (*covid-19, pneumonia e normal*) na base de dados montada por ele, base a qual foi posteriormente utilizada por Khan et al. (2021) que em seu trabalho conseguiu, com a mesma base e classificador, atingir um resultado superior. Neste trabalho, Khan et al. (2021) atinge uma acurácia de 99,43% ao classificar as mesmas 3 classes e utilizar *Binary Differential Evolution (BDE)* para a seleção dos atributos mais relevantes extraídos por uma *Deep Convolutional Neural Network*.

De mesmo modo, em relação às pesquisas que apenas aplicaram métodos já existentes, em (NARIN, 2021) após realizar a extração dos atributos das imagens de raios X com *ResNet50, ResNet101 e InceptionResNetV2*, os métodos meta-heurísticos *Particle Swarm Optimization (PSO)* e *Ant Colony Algorithm (ACO)* foram aplicados para selecionar os mais relevantes. E havendo testes com os classificadores SVM e KNN, e diferentes combinações de métodos, o melhor resultado de 99.86% foi obtido ao combinar SVM com PSO e os atributos selecionados de todos os extratores. Enquanto isso, em (MOHAMMED et al., 2021), apesar de utilizar os mesmos classificadores (SVM, KNN), após aplicar técnicas de melhoramento de imagem, as características foram extraídas utilizando *Local Binary Pattern (LBP)* e as mais relevantes foram selecionadas com BPSO, obtendo assim uma acurácia de 94,6% com o classificador SVM.

Assim, em Aslan et al. (2022), após realizar testes em 13 diferentes CNNs para extração e classificação, os métodos *Iterative Neighborhood Component Analysis (INCA)* e *Iterative ReliefF (IRF)* foram utilizados para selecionar os atributos mais importantes de cada um dos extratores e posteriormente enviá-los para seus respectivos CNNs para realização das classificações, resultando assim em uma acurácia de 99,14% ao combinar



INCA com *VGG16*. Por fim, em (BHOWAL; SEN; SARKAR, 2021), apesar de abordarem em seu artigo a proposta como "*um novo método de seleção de atributos de duas camadas*", por estarem criando uma nova forma de seleção combinando métodos já existentes, neste artigo, ele foi categorizado como (Z, X) ao invés de (Y). Logo, após a extração feita com *VGG16*, *Xception* e *InceptionV3* e a seleção com o método apresentado que utiliza *Coalition Game Theory (Approximated Shapley Values)* e *CUR decomposition com Nystrom Sampling*, a classificação foi realizada com um MLP alcançando assim 94,17% de acurácia.

Com isso, é possível visualizar que o foco das pesquisas, até o momento, se deu no cenário de classificação plano com maior uso de apenas 2 classes, sendo também mais comum o uso do HoldOut para realização dos experimentos devido ao alto custo computacional. Desta forma, com todas as pesquisas buscando alternativas aos testes RT-PCR para a triagem de pacientes infectados, é possível visualizar e entender a eficácia da aplicação de seleção de atributos neste meio. Sendo possível afirmar de que o presente trabalho é o único, até onde sabemos, que até o momento realiza a seleção de atributos em nos cenários de classificação tanto plano quanto hierárquico na tarefa de detecção de covid-19, contando também com a utilização de uma base com amostras de tipos de patologias pulmonares, que podem ser organizadas hierarquicamente por serem subtipos de pneumonia, em ambos os cenários de classificação.

Tabela 2 – Trabalhos Relacionados - (\*) Indica método ou metodologia proposto no mesmo artigo

ARTIGO	TIPO DE DADO	PROPOSTA	BASE ID	CODIGO DISPONIVEL	TÉCNICA UTILIZADA	NOME METODOLOGIA	MÉTODOS UTILIZADOS	TIPO	CLASSIFICADOR	CROSS/Hold	PRINCIPAL RESULTADO
(SEN et al., 2021)	CT	Z, X	[B 11] [B 07]	SIM	CNN	A bi-stage feature selection approach *	1° MI & ReliefF; 2° DA.	F, M	SVM	Holdout	Acurácia a. 98,39% b. 90,00% F1 Score a. [B 11] b. 0,8855
(SYED, KHAN, ALROMEMA, 2022)	Sangue	Z, X	[B 12]	Pseudo <sup>2</sup>	DB	Proposed Hybrid Feature Selection Approach *	1° mRMR; 2° Threshold supervised t-test; 3° SCX; AG; GWO; WOA;	F, M	SVM; DT; LR; KNN; RF Gaussian-NB e XGBoost	HoldOut	96% RF + WOA
(TOO; MIRJALILI, 2021b)	P & D	Y	[B 15]	SIM	DB	-	HLBDA *	W	HLBDA *	HoldOut	92,21%
Shaban2020a	CT	Z, X, Y	[B 07]	Pseudo	GLCM	COVID-19 Patients Detection Strategy (CPDS) *	HFSM *	F, W	EKNN *	HoldOut	96%
(ROSTAMI; OUSSALAH, 2022)	Sangue	Z, X, Y	[B 13]	SIM <sup>3</sup>	DB	Feature Selection with Explainable Random Forest (FSXRF) *	1° Pearson Similarity Criteria, SoftMax Normalization; 2° Fisher Score (FS), Node Centrality (NC);	F	XRF	CV (x10)	89,98% 78,12%
(REDDY; NASIRI; ALAVI, 2022)	Ratio X	Z, X	[B 02]	SIM	CNN (DenseNet101)	-	ANOVA	F	XGBoost	a CV (x5) b HoldOut	a 98,72% b 92% a 97,87% b 92,42% a. 2 classes b. 3 classes
(BHOWAL; SEN; SARKAR, 2021)	Ratio X	Z, X	[B 06]	SIM	CNN (VGG16, Xception, InceptionV3)	Two-tier feature selection method *	1° Condition Game theory (Approximated Shapley Values); 2° CUR decomposition e Nyström Sampling;	F	MLP	HoldOut	94,17%
(NARIN, 2021)	Ratio X	X	[B 01]	NAO	CNN (ResNet50, ResNet101, InceptionResNetV2)	-	PSO, ACO	M	SVM, KNN	CV (x10)	99,80% 99,08%
(SUN et al., 2020)	CT	Z, X, Y	[B 08]	NAO	handcrafted features + radiomics	Adaptive Feature Selection Guided Deep Forest (AFS-DF) *	AFS-DF *	W	AFS-DF *	CV (x5)	91,79% 93,07%
(OZTURK; FUNGER; SUBASI, 2021)	CT	Z, X, Y	[B 07]	Pseudo	FDEPPFN *	RFNCA *	1° ReliefF; 2° NCA;	F	a ANN b DNN	CV (x10)	a 94,10% b 95,84% a 94,08% b 95,83% a-ANN b-DNN
(MOHAMMED et al., 2021)	Ratio X	X	[B 03]	NAO	LBP	BPSO	1° GNDQ; 2° SA;	M	SVM, KNN	CV (x10)	94,69%
(AHMED et al., 2022)	P & D	Z, X	[B 15]	SIM	DB	Binary Simulated Normal Distribution Optimizer (BSNDO) *	-	M	KNN, RF, NB	HoldOut	98,61%
(KHAN et al., 2021)	Ratio X	X	[B 05]	NAO	Deep Convolutional Neural Network	BDE	-	M	SVM	HoldOut	99,43%
(CHAUHAN; MODI; SHRIVASTAVA, 2022)	P & D	X	[B 16]	Pseudo	DB	Chi2, MI ANOVA F-score	-	F	ANN-based	HoldOut	93%
(DUFFIA et al., 2021)	P & D	Z, X	[B 21]	NAO	DB	RF-based	-	En	RF, DT, SVM, XGBoost	HoldOut	96,60%
(ALSHEDEI; KURNAZ, 2022)	P & D	Z, Y	[B 19]	NAO	DB	Binary Version of NCCLA *	-	M	ANN	HoldOut	94,31%
(BANDYOPADHYAY et al., 2021)	CT	Z, X	[B 11]	Pseudo	CNN (DenseNet)	HBO, SA, CI	-	M	-	HoldOut	98,85%
(CANAYAZ, 2021)	Ratio X	Z, X	[B 05]	SIM	CNN (AlexNet, ResNet)	BPSO, BGWO	-	M	SVM	CV (x5)	99,38% a. 99,15% b. 99,42% c. 95,57%
(DEY et al., 2021)	CT	Z, X	[B 11] [B 10]	NAO	CNN (GoogLeNet, ResNet18, ResNet152, VGG19, VGG16)	Monta Rec, Foraging based Golden Ratio Optimizer (MRFCRO) *	MRFO, GRO	M	SVM; ELM; MLP	-	a. [B 07] b. [B 11] c. [B 10]
(ASLAN et al., 2022)	Ratio X	Z, X	[B 04]	NAO	CNN (VGG16, VGG19, SqueezeNet, ShuffleNet, Resnet101, Resnet50, Resnet18, GoogLeNet, DarkNet53, DarkNet19, AlexNet, DenseNet201, InceptionResnet-V2)	INCA, IRF	-	F	CNN (VGG16, VGG19, SqueezeNet, ShuffleNet, Resnet101, Resnet50, Resnet18, GoogLeNet, DarkNet53, DarkNet19, AlexNet, DenseNet201, InceptionResnet-V2)	HoldOut	99,14% 99,58% INCA + VGG16
(EL-KENAWY et al., 2020)	CT	Z, X, Y	[B 09]	Pseudo	CNN (AlexNet, VGG16Net, VGG19Net, ResNet50)	SFS-Guided WOA *	SFS, Guided WOA	M	PSO-GuidedWOA *	HoldOut	* 0,995 AUC area under the curve (auc)
(SOUI et al., 2021)	P & D	Z, X	[B 20] [B 14]	Pseudo	DB	-	NSGA-II	M	AdaBoost	HoldOut	a. 86,01% b. 95,56% b. [B 14]
(DENIZ et al., 2022)	P & D	Z, X	[B 15]	Pseudo	DB	MG-ELM *	AG, ELM	M	MG-ELM *	CV (x5)	96,22%
(ALI; ABDULSALAM, 2021)	P & D	X	[B 17]	NAO	DB	RF, ETC	-	W, E	a. Naive Bayesian b. RDM	HoldOut	a. 60,320% b. 39,924%
(MUSTAFA et al., 2021)	P & D	Z, X	[B 18]	NAO	DB	Two-step Feature SelectionInfoGain Algorithm Genetic	1° IG 2° AG	F, M	fitness (DT)	CV (x10)	95,017%

Tabela 3 – Siglas e Nome dos Métodos Utilizados nos Trabalhos Relacionados

SIGLAS	MÉTODOS DE SELEÇÃO	SIGLAS	EXTRATORES
-	Two-tailed unpaired t-test analysis ate 5% significance level	FDEPFGN	Fused Dynamic sized Exemplars based Pyramid Feature Generation Network
ACO	Ant Colony Algorithm	GLCM	Gray Level Co-occurrence Matrix
AG	Algoritmo Genético	LBP	Local Binary Pattern
ANOVA	Analysis Of Variance	-	-
BDE	Binary Differential Evolution	<b>SIGLAS</b>	<b>MÉTODOLOGIAS / SELEÇÃO</b>
BGWO	Binary Gray Wolf Optimization	-	A bi-stage feature selection approach
BPSO	Binary Particle Swarm Optimization	-	Proposed Hybrid Feature Selection Approach
BSNDO	Binary Simulated Normal Distribution Optimizer	CPDS	COVID-19 Patients Detection Strategy
CHHO	Chaotic Harris Hawks optimisation Algorithm	FSXRF	Feature Selection with Explainable Random Forest
CI	Chaotic Initialisation (CI)	-	Two-tier feature selection method
DA	Dragonfly Algorithm (DA)	AFS-DF	Adaptive Feature Selection Guided Deep Forest
ELM	Extreme Learning Machines	RFINCA	Relieff + NCA
ETC	Extra Tree Classifier	BSNDO	Binary Simulated Normal Distribution Optimizer
GND0	Generalized Normal Distribution Optimizer	MRFGRO	Manta Ray Foraging based Golden Ratio Optimizer
GRO	Golden Ratio Optimizer	SFS-Guided WOA	Stochastic Fractal Search + Guided Whale Optimization Algorithm
Guided WOA	Guided Whale Optimization Algorithm	MG-ELM	Multi-threaded Genetic feature selection algorithm combined with Extreme Learning Machines
GWO	Grey Wolf Optimizer	-	Two-step Feature SelectionInfoGain Algoritmo Genetico
HFSM	Hybrid Feature Selection Methodology	-	-
HHO	Harris Hawks optimisation (HHO)	<b>SIGLAS</b>	<b>CLASSIFICADORES</b>
HLBDA	Hyper Learning Binary Dragonfly Algorithm	ANN	Artificial Neural Network
IG	Information Gain	DNN	Deep Neural Network
INCA	Iterative Neighborhood Component Analysis	DT	Decision Trees
IRF	Iterative ReliefF	EKNN	Enhanced K-Nearest Neighbor
MI	Mutual Information	ELM	Extreme Learning Machine
MRFO	Manta Ray Foraging Optimizer	KNN	K-Nearest Neighbor
mRMR	Minimum Redundancy Maximum Relevance	LR	Logistic Regression
NCA	-	Gaussian-NB	Gaussian Naïve Bayes
NCCLA	New Caledonian Crow Learning Algorithm	NB	Naïve Bayesian
NSGA-II	Non-dominated Sorting Genetic Algorithm	PSO-GuidedWOA*	Guided WOA based on Particle Swarm Optimization
PSO	Particle Swarm Optimization	RBM	Restricted Boltzmann Machine
RFE	Recursive Feature Elimination	RF	Random Forest
SA	Simulated Annealing	SVM	Support Vector Machine
SCA	Sine Cosine Algorithm	XGBoost	eXtreme Gradient Boosting
SFS	Stochastic Fractal Search (SFS)	XRF	Explainable Random Forest
WOA	Whale Optimization Algorithm	-	-



## 4 METODOLOGIA

Este Capítulo apresenta o processo e as etapas utilizadas para realização deste trabalho, bem como o detalhamento das configurações de métodos utilizados e previamente apresentados na Fundamentação Teórica (Capítulo 2).

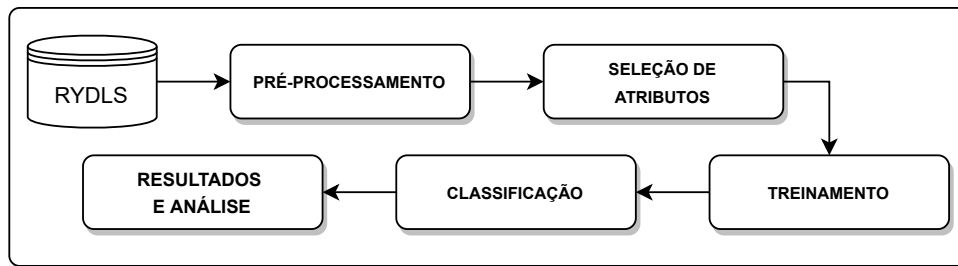


Figura 17 – Fluxograma da metodologia utilizada

Assim, conforme o fluxograma apresentado na Figura 17, as próximas seções seguirão a mesma ordem. Na Seção 4.1 a base de dados RYDLS-20 é apresentada juntamente com sua composição de arquivos que foram tratados na etapa de Pré-Processamento descrita na Seção 4.2. Seguido pela etapa de Seleção de Atributos, seus métodos e procedimentos são explicados na Seção 4.3. Desta forma, as etapas de Treinamento e Classificação se encontram descritos na Seção 4.4, finalizando então com a geração dos resultados na Seção 4.5 e as ferramentas, configurações e versões utilizadas na Seção 4.6 contendo as configurações e parâmetros dos métodos, classificadores e versões de bibliotecas.

### 4.1 Base de dados RYDLS-20

RYDLS-20 ou RYDLS (PEREIRA et al., 2020) é uma base de dados composta por 1.144 amostras de *imagens de raios X de pulmões*, com elas estando divididas em 7 categorias (classes) diferentes. Essas imagens são frutos da combinação de outras bases, adquiridas de três diferentes locais e repositórios, gerando assim a seguinte composição de classes: *COVID-19*, *SARS*, *Pneumocystis*, *Streptococcus*, *Varicella*, *MERS* e *Normal*. Com isso, existem dois aspectos interessantes que entram em destaque para a escolha desta base, sendo o primeiro o seu alto nível de desbalanceamento entre as patologias (doenças pulmonares), ou em outras palavras, o fato de algumas classes conterem muito mais imagens do que outras. E segundo, pelo fato de todas as classes e amostras já estarem rotuladas hierarquicamente do nó raiz até o nó folha, seguindo a hierarquia natural dessas patologias conforme disponível na Figura 18 juntamente com a contagem de amostras por classe.

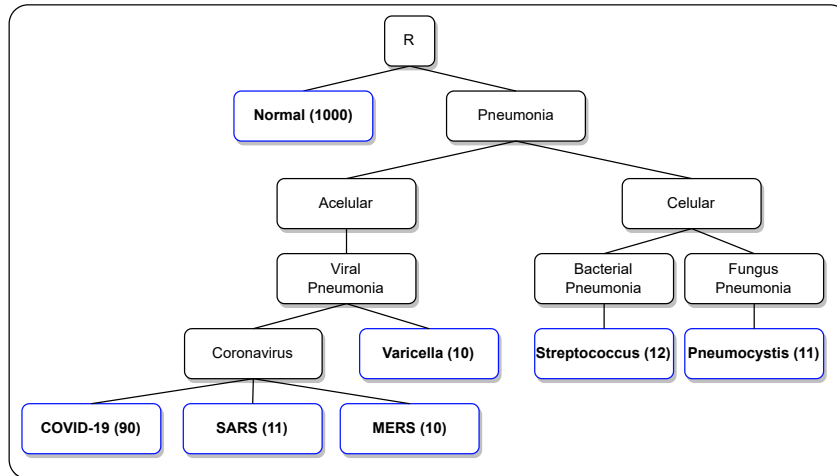


Figura 18 – Hierarquia presente na base RYDLS com contagem de amostras.

Desta forma, além das imagens originais disponíveis, outro aspecto que motivou a escolha desta base foi que os autores já realizaram a extração dos dados destas imagens e providenciaram diferentes conjuntos de dados criados a partir das características delas. Permitindo assim, uma comparação direta através dos resultados obtidos por eles e futuros experimentos utilizando outras técnicas. Com isso, os conjuntos disponibilizados, e utilizados neste trabalho, são provenientes dos seguintes métodos de extração:

- BSIF - Binarized statistical image features (KANNALA; RAHTU, 2012); Inspirado por outros descritores que produzem códigos binários, como LBP e LPQ, ao invés de construções de código heurístico, este método é baseado em *estatísticas de imagens naturais* o que melhora sua capacidade de modelagem (KANNALA; RAHTU, 2012).
- EQP - Elongated quinary patterns (NANNI; LUMINI; BRAHNAM, 2010); É basicamente uma variação dos descritores LBP e LTP, em que a maior diferença para estes descritores é o uso de um padrão quinário em EQP, ao invés de uma codificação binária ou ternária como em LBP e LTP respectivamente (PEREIRA et al., 2020).
- INCEPTION - Learned features with inception-V3 (SZEGEDY et al., 2016); Usada no cenário *non-handcrafted* por se mostrar mais robusta que outras arquiteturas profundas, apresentando baixas taxas de erro no desafio ILSVRC-2012 (PEREIRA et al., 2020).
- LBP - Local binary pattern (OJALA; PIETIKÄINEN; HARWOOD, 1996); É um *invariante em escala de cinza* e pode ser facilmente combinado com uma simples medida de contraste ao calcular para cada vizinhança a diferença do nível médio de cinza daqueles *pixels* que têm o valor 1 e daqueles que têm o valor 0, respectivamente (OJALA; PIETIKÄINEN; HARWOOD, 1996).

- LDN - Local directional number (RIVERA; CASTILLO; CHAE, 2013); Ele codifica a informação direcional das texturas da face (ou seja, a estrutura da textura) de uma forma compacta, produzindo um código mais discriminativo do que os métodos atuais (RIVERA; CASTILLO; CHAE, 2013).
- LETRIST - Locally encoded transform feature histogram (SONG et al., 2018); É uma representação de histograma que codifica explicitamente a *informação conjunta* dentro de uma imagem, através de espaços de atributos e escalas, sendo livre de treinamento e de baixa dimensão, porém discriminativa e robusta para descrição de texturas. (SONG et al., 2018).
- LPQ - Local phase quantization (OJANSIVU; HEIKKILÄ, 2008); Proposto originalmente com o objetivo de fornecer uma boa descrição de textura para imagens com ruído afetadas por desfoque, o LPQ surpreendentemente também se mostrou bastante eficaz para descrever o conteúdo textural, mesmo para imagens não afetadas pelo desfoque (PEREIRA et al., 2020).
- oBIFs/OBIF - Oriented basic image features (NEWELL; GRIFFIN, 2014); Sua principal ideia é categorizar cada local da imagem em uma das sete classes possíveis de *simetria local* (entre: *plana*, *inclinada*, *rotacional escura*, *rotacional clara*, *linha escura sobre luz*, *linha clara sobre escura* ou *em forma de sela*), sendo usado para categorizar cada uma das partes da imagem seis filtros *derivados do gaussiano* (PEREIRA et al., 2020).

Dado o número de experimentos realizados em (PEREIRA et al., 2020), os autores decidiram por utilizar a abordagem hold-out em que 70%(802) e 30%(342) das amostras foram separadas respectivamente para as etapas de treino e teste. Para isso, pelos autores estarem investigando o uso de diferentes abordagens de reamostragem de dados, tanto em cenários planos quanto hierárquicos, um cuidado especial foi tomado para garantir que as mesmas amostras (imagens) estivessem igualmente separadas nas divisões treino/teste de cada extrator (como pode ser visto na Figura 19). Permitindo assim que o conjunto de teste, e conseqüentemente suas amostras, só aparecesse na fase final do processo.

Assim, uma vez que todos os experimentos apresentados por Pereira et al. (2020) foram realizados nestas condições e, todas as divisões e conjuntos de dados usados pelos autores estão disponíveis gratuitamente para outros pesquisadores utilizarem, esta base foi escolhida por possibilitar a comparação direta entre seus resultados com testes futuros sob outras abordagens. E uma vez que o presente trabalho busca aplicar seleção de atributos nos cenários de classificação plano e hierárquico, podemos considerar seu uso como uma vantagem, pois até onde sabemos esta é a única base, que contém amostras de sete classes sendo uma normal e seis subtipos de pneumonia que podem ser organizadas hierarquicamente contendo todas as amostras rotuladas desde o nó raiz até o nó folha.




Figura 19 – Detalhamento da organização da RYDLS

Além disso, por haver a possibilidade de realizar classificações de sete classes nos dois cenários de classificação (plano e hierárquico) e, por haver a possibilidade de se obter resultados diretamente comparáveis com os apresentados em (PEREIRA et al., 2020), o uso de outras bases foi descartado. E por mais que até fosse interessante a possibilidade de se fazer uma fusão ou qualquer tipo de combinação entre outras bases, como as apresentadas nos trabalhos relacionados, isso não é possível uma vez tanto parte delas quanto a RYDLS já são combinações de terceiras e inconsistências poderiam aparecer.



## 4.2 Pré-processamento

Com a divisão dos conjuntos de treino e teste feitas previamente pelos criadores da base de dados RYDLS, poucas alterações foram necessárias para realizar os experimentos desta pesquisa. Sendo primeiro uma pequena atualização na taxonomia das classes, foi adicionado o elemento maior “R” (raiz) para se seguir as orientações de Silla e Freitas (2011) durante os experimentos no Cenário Hierárquico, passando então de "*Pneumonia/Acellular/Viral/Varicella*" para "*R/Pneumonia/Acellular/Viral/Varicella*" por exemplo. E apesar disso, nos experimentos do Cenário Plano apenas o nome da patologia (nó-folha) foi utilizado.

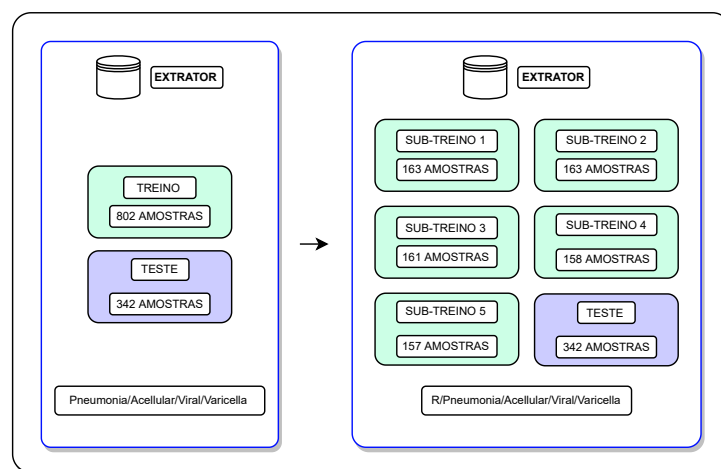


Figura 20 – Demonstração da Base RYDLS após Pré-Processamento

Além disso, para realização de testes primários e da seleção no algoritmo genético foram realizadas subdivisões (estratificadas) das bases de treino de cada extrator. Assim, se permitiu a realização de um processo de hold-out estratificado com  $k=5$ , de forma que a base de teste original permanecesse intocada até a classificação final, ao gerar bases de sub-treinos e sub-validações como pode ser visto na Figura 20, com um maior detalhamento apresentado na Tabela 4. Por fim, a última alteração foi a conversão dos arquivos ".arff" originais para ".csv" em cada um dos novos arquivos gerados.

Tabela 4 – Contagem de amostras das subdivisões após o pré-processamento

CLASSES	SUB-TREINO 1	SUB-TREINO 2	SUB-TREINO 3	SUB-TREINO 4	SUB-TREINO 5	TESTE	TOTAL
Normal	140	140	140	140	140	300	1000
COVID-19	13	13	13	12	12	27	90
MERS	2	2	1	1	1	3	10
SARS	2	2	2	1	1	3	11
Varicella	2	2	1	1	1	3	10
Streptococcus	2	2	2	2	1	3	12
Pneumocystis	2	2	2	1	1	3	11
TOTAL	163	163	161	158	157	342	1144

### 4.3 Seleção de Atributos

Durante a etapa de seleção de atributos, duas abordagens foram empregadas e com elas dois processos levemente diferentes executados. Apesar de suas diferenças em ambos se seguiu o mesmo protocolo, em que apenas os conjuntos de dados destinados ao treinamento foram utilizados para a seleção dos atributos a partir das características previamente extraídas e disponibilizadas pela RYDLS.

Para a seleção dos melhores atributos dos ranqueadores filters, por eles calcularem a importância dos atributos sem a utilização de um classificador, foi utilizada a base de treino completa (sem usar nenhum dado da base de teste). Agora, no caso do algoritmo genético, após testes aplicando a seleção usando cross-validation e por conseguinte as cinco subdivisões, foi identificado um alto custo computacional e com isso a falta de equipamento para tal tarefa. Assim, em sua aplicação final da seleção, foi escolhido utilizar as divisões já existentes para realizar um hold-out, em que as quatro primeiras subdivisões foram destinadas ao treinamento do algoritmo e a última para testar sua eficácia durante todas as iterações como pode ser visto na Figura 21.

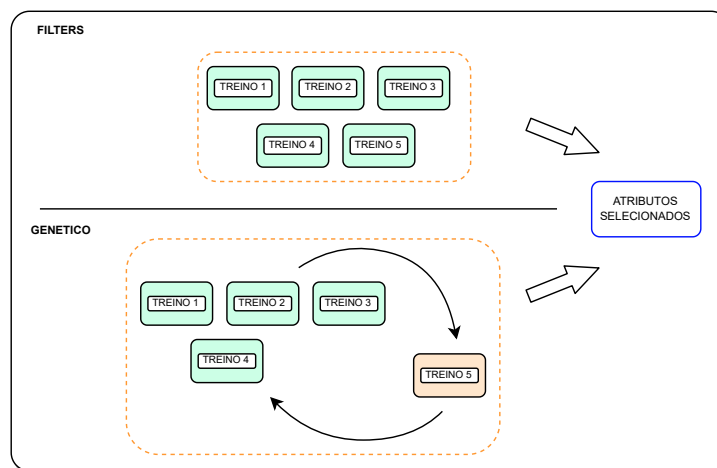


Figura 21 – Metodologia Utilizada nas Abordagens de Seleção

Quando pensado na seleção final de cada método, para os filters, por terem a habilidade de retornarem (independente da maneira calculada) os scores de importância de cada atributo, pode ser gerado um ranking completo ordenado pela relevância de cada um. Assim, sendo possível quebrá-los em diferentes porcentagens para analisar o desempenho das classificações (independente do classificador) com 100%, 90%, 80%... até 10% dos atributos, com seus valores arredondados em caso de valor fracionado como: 10% de 85 atributos =  $8,5 = 8$ . Já no caso do algoritmo genético isso não foi possível, pois ele se utiliza de heurísticas para chegar a um resultado otimizado específico ao classificador utilizado como estimador. E assim, apenas a melhor combinação de atributos foi retornada ao atingir o máximo de gerações, desta forma apenas obtivemos a combinação de atributos mais otimizada para cada combinação de classificador com extrator, que foi utilizado

durante as próximas etapas.

Assim, seguindo a lógica explicada, a seleção de atributos foi realizada tanto no cenário de classificação Plano quanto Hierárquico, em que a única diferença neste processo para o cenário Hierárquico, foi a realização de cinco seleções por experimento sendo elas realizadas em cada nó pai (LCPN). Desta forma, para realizar cada uma das seleções também foi feita a filtragem das amostras em cada uma delas para se selecionar apenas entre os filhos de cada nó, e assim selecionar os melhores atributos para descrevê-los.

Desta forma, por haver diferentes processos de seleção sendo feitos em diferentes nós em uma mesma hierarquia, diferentes combinações e quantidades de atributos selecionados entre cada nó-pai poderiam aparecer em um mesmo experimento. Neste caso, para os métodos filters, essa variação se deu apenas em relação às combinações de atributos utilizados, uma vez que eles retornam um ranking completo de importância. Assim, a quantidade selecionada para eles, pode ser delimitada posteriormente no processo de classificação pelas percentagens desejadas (100%, 90%, ..., 10%) na hierarquia como um todo. Porém, no caso do algoritmo genético, por retornar apenas a seleção mais otimizada para cada nó, a variação se deu tanto na combinação de atributos escolhidos quanto em sua quantidade, não sendo possível escolher uma porcentagem para a hierarquia como um todo.

## 4.4 Treinamento e Classificação

Por estarmos lidando com um problema hierárquico, para se realizar as classificações primeiro é necessário especificar o tipo de problema apresentado. Desta forma, seguindo a framework de Silla e Freitas (2011) e a tupla escolhida para categorizá-los (explicada no Capítulo 2), o problema atual pode ser descrito como:  $\langle T, SPL, FD \rangle$ . Enquanto ao que se diz respeito ao código desenvolvido para solucionar/lidar com ele no cenário hierárquico, a tupla  $\langle SPP, MLNP, T, LCPN \rangle$  é formada.

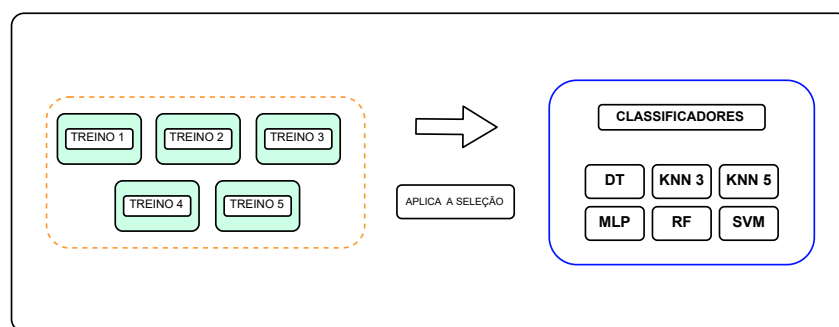


Figura 22 – Metodologia Utilizada na Etapa de Treinamento

Nestas etapas os classificadores DT, MLP, RF, SVM e KNN (com 3 e 5 vizinhos) foram utilizados, sendo escolhidos de forma a permitir que todos os resultados gerados

fossem diretamente comparáveis com os da pesquisa de Pereira et al. (2020) em que a base RYDLS foi proposta. Desta forma, além dos classificadores, os mesmos parâmetros utilizados em cada um deles no trabalho original também foram implementados e se encontram detalhados na Seção 4.6. Permitindo assim, que fosse possível ter um norte de quais seriam os resultados mínimos esperados e quais metas poderiam ser superadas.

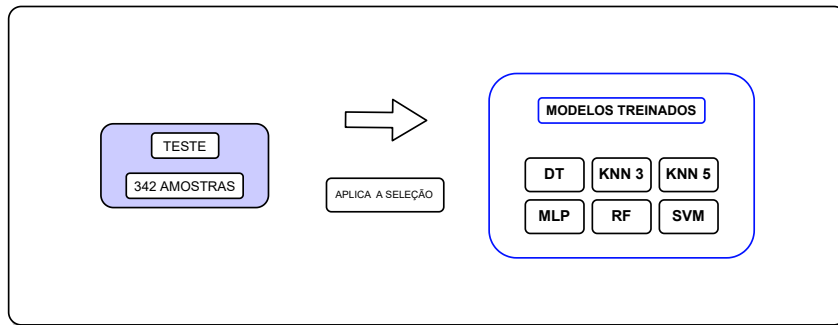


Figura 23 – Metodologia Utilizada na Etapa de Teste

Assim, sendo "*experimento*" utilizado para descrever a combinação de um extrator, com um método de seleção e uma das porcentagens selecionadas, foram realizados 4.176 deles. Para isso, o seguinte protocolo foi utilizado independente da abordagem de classificação: Apenas as bases destinadas ao treinamento (cinco subdivisões) foram utilizadas para treinar cada um dos classificadores, enquanto as bases de teste só foram utilizadas durante a etapa da classificação/previsão/teste como pode ser visto nas Figuras 22 e 23 respectivamente. Reforçando assim que os experimentos foram executados utilizando a abordagem holdout, o que também se mostrou mais comum entre os Trabalhos Relacionados apresentado na Seção 3.2.

Então, com protocolo definido, os experimentos foram realizados seguindo o que foi apresentado na Fundamentação Teórica (Capítulo 2) sobre a *Abordagem de Classificação Plana e Hierárquica LCPN*.

## 4.5 Geração dos Resultados

Com os resultados sendo gerados a partir da comparação entre os rótulos originais e previstos para as amostras da base de teste, as métricas apresentadas na Seção 2.4 foram escolhidas para que fosse possível analisar a eficácia entre cada um dos experimentos. Considerando o cenário desbalanceado, usar a acurácia não seria muito útil pois ao classificar corretamente apenas a classe majoritária, essa métrica poderia continuar gerando resultados altos.

Com isso, para análise individual das classes, a métrica *F1-Score* foi escolhida, porém para analisar o experimento como um todo, se fez necessário o uso de uma métrica que agregasse seus resultados (de *F1-Score*) de forma coerente ao cenário desbalanceado.

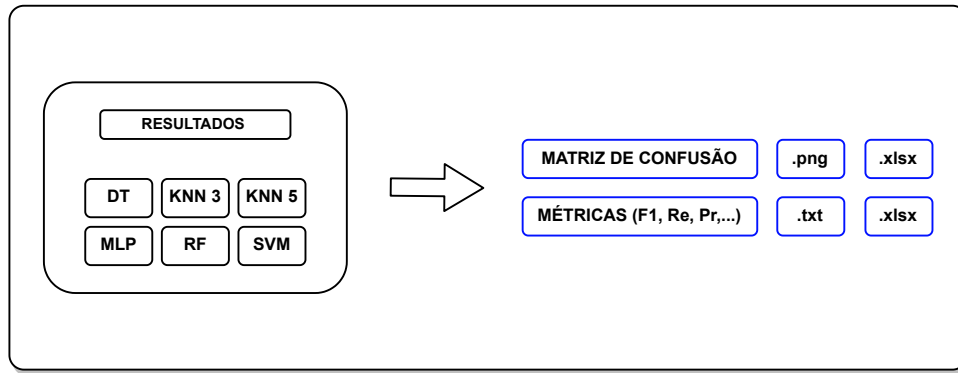


Figura 24 – Metodologia Visual dos Resultados Salvos

Assim, por não considerar as diferenças quantitativas das classes, *Macro-Average F1-Score* foi escolhida. Desta forma, como pode ser visto na Figura 24, os resultados de cada um dos experimentos foram salvos em formatos diferentes, tanto para as Matrizes de Confusão quanto para as Métricas.

## 4.6 Ferramentas, Configurações e Versões

De forma a permitir reprodutibilidade dos experimentos, esta seção contém o detalhamento das ferramentas, configurações e versões utilizadas. Com os códigos desenvolvidos em python (3.8), a biblioteca de machine learning escolhida foi o scikit-learn<sup>1</sup>, desta forma tanto ela quanto outras bibliotecas instaladas (coluna “instalados”), além dos pacotes padrões e/ou instalados junto com outros (coluna “outros”), se encontram detalhados na Tabela 5 juntamente com suas versões, sendo seguido pelas seções 4.6.1, 4.6.2 e 4.6.3 que abordam os Métodos Filters, o Algoritmo Genético e os Classificadores respectivamente.

Tabela 5 – Versões dos Pacotes/Bibliotecas

INSTALADOS		OUTROS			
PACOTE	VERSÃO	PACOTE	VERSÃO	PACOTE	VERSÃO
matplotlib	3.5.1	Pillow	9.0.1	pyparsing	3.0.7
numpy	1.22.3	cycler	0.11.0	python-dateutil	2.8.2
openpyxl	3.0.9	et-xmlfile	1.1.0	pytz	2022.1
pandas	1.4.1	fonttools	4.31.2	scipy	1.8.0
scikit-learn	1.0.2	joblib	1.1.0	setuptools	57.0.0
seaborn	0.11.2	kiwisolver	1.4.0	six	1.16.0
		packaging	21.3	threadpoolctl	3.1.0
		pip	21.1.2	wheel	0.36.2

<sup>1</sup> <https://scikit-learn.org/stable/>

### 4.6.1 Métodos Filters e seus Parâmetros

Por possibilitarem a geração de rankings de importância dos atributos sem a utilização de um classificador, os métodos ANOVA<sup>2</sup> e Mutual Information<sup>3</sup>, descritos na Fundamentação Teórica, foram utilizados. Tendo cada um sua própria maneira de calcular a importância dos atributos, eles foram escolhidos por serem mais comuns e por já estarem implementados na biblioteca utilizada e permitir assim o desenvolvimento da pesquisa no tempo determinado. Além disso, o uso de métodos filters nos possibilitam ter um balizamento dos resultados alcançados pelo Algoritmo Genético entre resultados minimamente esperados.

Sendo utilizados como função de score (ranqueadores) em combinação com o método *SelectKBest*<sup>4</sup> do scikit-learn para que independente da maneira calculada sempre se retornasse os scores de importância de cada atributo de forma que quanto maior o valor, maior a relevância. Podendo desta forma gerar um ranking ordenado de forma decrescente conforme a importância de cada um e filtrá-los nas porcentagens desejadas. Assim, todos os parâmetros (inclusive os padrões) podem ser encontrados na Tabela 6.

Tabela 6 – Parâmetros dos Filters - (\*) indica valores padrão

FUNÇÃO / MÉTODO	PARÂMETROS	VALORES
SelectKBest	score_func k *	Chi2, FClassif, MI 'all'
Mutual Information (mutual_info_classif)	X Y discrete_features * n_neighbors * copy * random_state *	dados da base de treino rótulos da base de treino 'auto' 3 True None
ANOVA (f_classif)	X Y	dados da base de treino rótulos da base de treino

### 4.6.2 Algoritmo Genético e seus Parâmetros

O Algoritmo Genético utilizado foi programado do zero e utiliza como seus estimadores os mesmos classificadores da etapa de classificação (parâmetros na seção 4.6.3). Com a população inicial criada aleatoriamente (por cromossomo), neste código o processo de *Torneio* foi implementado de forma que 5 indivíduos eram selecionados aleatoriamente entre

<sup>2</sup> ANV: <[https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_selection.f\\_classif.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.f_classif.html)>

<sup>3</sup> MI: <[https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_selection.mutual\\_info\\_classif.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.mutual_info_classif.html)>

<sup>4</sup> SelectKBest: <[https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_selection.SelectKBest.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.SelectKBest.html)>

a população e entre estes, os 2 melhores selecionados para aplicar "*One-Point Cross-Over*" e então gerar novos indivíduos.

Tabela 7 – Parâmetros do Algoritmo Genético

PARÂMETROS	DESCRIÇÃO / VALOR
Base Treino	valores e rótulos das folds de treino 1 a 4
Base Teste	valores e rótulos da fold de treino 5
Tamanho da População	(58) - inicial e das gerações seguintes
Máximo de Gerações	(200) - critério de parada
Estimadores / Classificadores	(DT, KNN 3/5, MLP, RF, SVM)
Protocolo	(Torneio: sorteia 5 e seleciona os 2 melhores) maneira de selecionar indivíduos ao cross-over
Tipo de Cross-Over	(One-Point Cross-Over) - Acontece Sempre
Probabilidade de Mutação	(1/ n° atributos) - probabilidade por cromossomo
Elitismo	(2 indivíduos)
Valor de Desempenho	Macro-Avg F1-Score

Uma vez criados os novos indivíduos, uma probabilidade de mutação (por cromossomo) era aplicada, acrescentando assim certa variabilidade nas novas gerações. Esta nova população gerada por meio do cross-over continha 2 indivíduos a menos, pois foi escolhido trabalhar com *elitismo*. Assim, para completar a nova população, os dois melhores indivíduos da população atual eram escolhidos sem sofrer alterações. Para isso e todas as outras análises de desempenho, a métrica utilizada para analisar os indivíduos foi novamente *Macro-Avg F1-Score*, vinda diretamente dos resultados das classificações realizadas nos estimadores citados. E uma vez gerada uma nova população, todo o processo é repetido até que uma quantidade de gerações seja atingida. Assim, todos os parâmetros e configurações citadas se encontram resumidos na Tabela 7.

### 4.6.3 Classificadores e seus Parâmetros

Como dito anteriormente, os classificadores Decision Tree (DT), K-Nearest Neighbors (KNN), Multi-Layer Perceptron (MLP), Random Forest (RF) e Support Vector Machines (SVM) foram utilizados durante toda esta pesquisa. Assim, com o foco em comparar posteriormente os resultados obtidos com os apresentados por Pereira et al. (2020) todos os parâmetros utilizados em seu artigo foram replicados e encontram-se detalhados na Tabela 8. Desta forma, a parametrização apresentada foi aplicada em todas as utilizações dos classificadores, tanto nas utilizações para classificações planas quanto em cada uma das classificações hierárquicas locais.

Tabela 8 – Parâmetros dos Classificadores (PEREIRA et al., 2020)

<b>Algorithm</b>	<b>Parameters</b>	
KNN	Number of Neighbors	3 e 5
	Distance	Euclidean
SVM	Kernel	RBF
	Penalty Parameter (C)	1
	Degree	3
	Gamma	Scale
	Cache size	200
	Decision Function Shape	Ovr
	Tolerance	0,001
MLP	Solver	LBFGS
	Alpha	1e-5
	Shuffle	TRUE
	Max Iterations	500
	Learning Rate Init	0.3
	Momentum	0.2
	Hidden Layer Sizes	13
DT	Criterion	Gini
	Splitter	Best
	Min Samples Leaf	10
	Min Samples Split	20
	Max Leaf Nodes	None
	Max Depth	10
RF	Number of Trees	10
	Class Weight	Balance
	Type of Trees	Same of DT



## 5 RESULTADOS

Neste capítulo os melhores resultados obtidos durante os experimentos de aplicação dos métodos de seleção de atribuídos para detecção de patologias pulmonares em imagens de raios-X são apresentados. Estes experimentos foram feitos de forma a tentar melhorar o desempenho de cinco classificadores utilizados previamente por Pereira et al. (2020).

Desta forma, utilizando a metodologia explicada no Capítulo 4, foram realizados experimentos em dois diferentes cenários de classificação, sendo eles a *Abordagem de Classificação Plana* e a *Abordagens de Classificação Hierárquica* presentes nas Seções 5.2 e 5.3 respectivamente. Em cada uma destas seções os resultados são mostrados considerando dois cenários de análise, sendo eles o *cenário covid* e o *cenário macro*. Enquanto o primeiro foca em apresentar os melhores resultados de f1-score obtidos especificamente para a classificação da classe covid-19, o segundo foca na triagem e detecção de todas as classes, analisando os melhores resultados a partir de macro-avg f1-score. Contando assim, com a realização de  $4.128^1$  experimentos computacionais e o alto número de resultados, apenas os 5 melhores de cada cenário (de classificação e análise) são apresentados. E para facilitar o entendimento de todas as análises e comparações, a Seção 5.1 conta com uma explicação em detalhes das tabelas utilizadas nestas comparações. Além disso, caso desejado, os demais resultados podem ser encontrados tanto nos Apêndices, quanto nos Anexos, estando organizados da seguinte forma: O Apêndice (B) apresenta os baselines de todos os experimentos, ou seja, eles sem a utilização de seleção de atributos; O Apêndice (C e D) apresentam os demais resultados de todos os experimentos aplicando as seleções; No Anexo (A) se encontra os melhores resultados apresentados em (PEREIRA et al., 2020), uma vez que eles representam resultados de baseline para comparar a performance dos métodos de seleção de características utilizados neste trabalho.

---

<sup>1</sup> O calculo do número total de experimentos realizado encontra-se no Apêndice (A)

## 5.1 Explicando as Tabelas de Resultado

Usando como exemplo uma tabela de resultados real e presente nas próximas seções, esta seção busca detalhar como ela foi pensada e organizada a fim de permitir e facilitar o entendimento de como as análises foram feitas.

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	ANV	154 / 256	60%	0,4471	0,5851
2	LPQ	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
3	LPQ	KNN 3	ANV	205 / 256	80%	0,4859	0,5362
4	LPQ	KNN 3	ANV	179 / 256	70%	0,4859	0,5199
5	LPQ	KNN 3	MI	154 / 256	60%	0,4859	0,5021

Figura 25 – Colunas que compõem um experimento

Todas as tabelas de resultado irão apresentar resultados provenientes de diferentes experimentos, os quais (como pode ser visto na Figura 25) são compostos de um resultado (*Macro Avg* ou *Covid F1-Score*) gerado a partir de uma previsão ao utilizar um *classificador* (*CLF*) feita a partir da aplicação de um *método de seleção* (*MS*) às características de um *extrator* (*EXT*). Este experimento, conta também com a porcentagem (*% Atributos*) e a quantidade (*N° Atributos*) de atributos que foram utilizados, a partir dos disponíveis para aquele extrator (*usados / total*), para se alcançar o devido resultado.

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	ANV	154 / 256	60%	0,4471	0,5851
2	LPQ	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
3	LPQ	KNN 3	ANV	205 / 256	80%	0,4859	0,5362
4	LPQ	KNN 3	ANV	179 / 256	70%	0,4859	0,5199
5	LPQ	KNN 3	MI	154 / 256	60%	0,4859	0,5021

Figura 26 – Como encontrar um experimento na tabela

Cada experimento, pode ser identificado como uma linha nesta tabela como mostra a Figura 26. Porém, como pode ser visto, essa linha contém duas colunas a mais do que de fato compõem o resultado de um experimento, sendo elas a *Baseline* e a "#".

A coluna *Baseline*, como demonstrado na Figura 27, contém os resultados provenientes dos experimentos utilizando o mesmo extrator e classificador da linha em que está inserida, porém sem a utilização de qualquer tipo de seleção de atributos, ou seja, utilizando todos os atributos. Desta forma, permitindo a comparação direta entre o resultado de um experimento e seu baseline (a versão usando todas as características)

Com isso, cada um dos resultados atingidos está organizado de forma decrescente, do melhor ao pior desempenho a partir da métrica (*Macro Avg* ou *Covid F1-Score*)

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	ANV	154 / 256	60%	0,4471	0,5851
2	LPQ	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
3	LPQ	KNN 3	ANV	205 / 256	80%	0,4859	0,5362
4	LPQ	KNN 3	ANV	179 / 256	70%	0,4859	0,5199
5	LPQ	KNN 3	MI	154 / 256	60%	0,4859	0,5021

Figura 27 – Composição do Baseline

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	ANV	154 / 256	60%	0,4471	0,5851
2	LPQ	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
3	LPQ	KNN 3	ANV	205 / 256	80%	0,4859	0,5362
4	LPQ	KNN 3	ANV	179 / 256	70%	0,4859	0,5199
5	LPQ	KNN 3	MI	154 / 256	60%	0,4859	0,5021

Figura 28 – Indicador de ordenação dos resultados do maior para o menor

apresentada. Essa organização, está indicada pelo símbolo "↓" ao lado da coluna a qual está ordenando o ranking, como mostra a Figura 28. Assim, a coluna "#", quando disponível, contém apenas a posição no ranking que o resultado daquele experimento (linha) atingiu com base na métrica que está ordenando a tabela (Figura 29). Além disso, uma vez que o foco da pesquisa é a seleção de atributos e por consequência a aplicação destes métodos, todas as vezes em que um baseline (experimento utilizando todos os atributos do extrator) conseguiu atingir resultados próximos ou superiores aos resultados aplicando seleção, eles foram adicionados as tabelas de resultados, porém sem receber um ranking específico para seu desempenho.

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	ANV	154 / 256	60%	0,4471	0,5851
2	LPQ	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
3	LPQ	KNN 3	ANV	205 / 256	80%	0,4859	0,5362
4	LPQ	KNN 3	ANV	179 / 256	70%	0,4859	0,5199
5	LPQ	KNN 3	MI	154 / 256	60%	0,4859	0,5021

Figura 29 – Como os resultados estão organizados/ranqueados

Por fim, devido a alta quantidade de classificadores, extratores, métodos de seleção e por consequente siglas, a Tabela 9 contém o resumo de como todas elas foram apresentadas e abreviadas nos resultados. Assim, uma vez que o foco da pesquisa é a seleção de atributos, é importante lembrar a quantidade de características (atributos) que cada extrator gerou

em seu conjunto de dados da base RYDLS, sendo encontrados ao final da mesma linha de seu respectivo extrator.

Tabela 9 – Descrição das siglas utilizadas nas tabelas de resultados.

Extratores		
BSIF	Binarized statistical image features	256 atributos
EQP	Elongated quinary patterns	256 atributos
INCEPTION	Learned features with inception-V3	2048 atributos
LBP	Local binary pattern	59 atributos
LDN	Local directional number	56 atributos
LETRIST	Locally encoded transform feature histogram	413 atributos
LPQ	Local phase quantization	256 atributos
OBIF	Oriented basic image features	484 atributos
Classificadores		
DT	Decision Tree	
KNN 3	K-Nearest Neighbors com k=3	
KNN 5	K-Nearest Neighbors com k=5	
MLP	Multi-Layer Perceptron	
RF	Random Forest	
SVM	Support Vector Machines	
Métodos de Seleção		
AG	Algoritmo Genético	
ANV	ANOVA - Análise de Variância	
MI	Mutual Information	

## 5.2 Classificação Plana

Os resultados preliminares desta seção foram apresentados na 21st IEEE Int. Conf. on Bioinformatics and Biomedicine (IEEE BIBE), porém em função de inúmeras modificações no código para realização de experimentos nos diferentes cenários descritos nesta dissertação, optamos por realizar os experimentos novamente com os códigos atualizados para garantir a comparação justa entre as diferentes abordagens avaliadas neste documento. Por esse motivo podem existir divergências entre os resultados apresentados neste documento e no trabalho com resultados preliminares publicados em (SELLETI; SILLA, 2021). Desta forma, por cenário plano queremos especificar os experimentos utilizando a *Abordagem de Classificação Plana* que visa resolver um problema hierárquico ignorando a hierarquia das classes e prever apenas as classes dos nós-folhas (SILLA; FREITAS, 2011). Assim, as Seções 5.2.1 e 5.2.2 contam respectivamente com os melhores resultados dos cenários de análise *covid* e *macro* atingidos a partir das classificações feitas com a base de teste no cenário plano.

### 5.2.1 Melhores Resultados - Cenário Covid

Os melhores cinco resultados na tarefa de detecção de covid-19 ao utilizar a abordagem de Classificação Plana são apresentados na Tabela 10. A análise dessa tabela segue a explicação feita na Seção 5.1 que contém um detalhamento de como ela foi idealizada. Assim, seguindo a ideia de que cada linha é um experimento, ao analisar a diferença entre os resultados atingidos ao usar seleção de atributos e seus respectivos baselines (experimento sem aplicar seleção), obtemos desempenhos com variações de  $-0,0278$  e  $+0,1113$  em relação a eles.

Estes resultados, de f1-score para classe covid-19, se encontram entre os valores  $0,8197$  e  $0,8475$ , e contam com a diminuição de até 80% da quantidade de atributos utilizados. Como primeiro item da tabela, ou seja, o experimento com melhor desempenho na tarefa de detecção de covid-19, temos o classificador MLP combinado com os atributos do extrator LPQ. Neste experimento foi atingido o resultado de  $0,8475$  utilizando todos os atributos disponíveis, e por consequente sem o uso de qualquer seleção. Desta forma, por não ter sido realizada qualquer seleção neste experimento, e pelo foco da pesquisa ser justamente isso, como dito anteriormente, foi optado por não adicionar uma posição para ele no ranking mas ainda sim apresentá-lo na tabela. Assim, apesar de ser caso único nesta pesquisa, este fato nos leva a lembrança de que a aplicação de métodos de seleção de atributos nem sempre busca atingir os melhores resultados, e sim em muitos casos, algo próximo com um menor custo computacional, atingido-o de forma mais simples e/ou menos complexa. O que nos leva a um dos experimentos com o segundo melhor desempenho, que obtiveram um resultado apenas  $0,0054$  menor em relação ao primeiro (*seu próprio baseline*).

Tabela 10 – Resultados - Cenário Covid - Classificação Plana - Seleção Plana

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
-	LPQ	MLP	-	256	100%	-	0,8475
1	LPQ	MLP	ANV	51 / 256	20%	0,8475	0,8421
	LETRIST	DT	MI	154 / 413	60%	0,7308	0,8421
2	LPQ	MLP	ANV	154 / 256	60%	0,8475	0,8302
3	LPQ	MLP	MI	102 / 256	40%	0,8475	0,8276
4	LETRIST	DT	MI	205 / 413	80%	0,7308	0,8214
5	LPQ	MLP	ANV	128 / 256	50%	0,8475	0,8197

Com um resultado de  $0,8421$ , a primeira colocação foi atingida por dois experimentos diferentes, sendo utilizados os classificadores DT e MLP. Neles as características obtidas pelos extratores LPQ e LETRIST foram combinadas com os métodos de seleção MI e ANV, o que permitiu reduzir de 40% a 80% dos atributos disponíveis (de cada extrator) para atingir o mesmo desempenho. Ao serem comparados apenas em relação a perda ou ganho de performance entre eles e seus respectivos baselines, é possível visualizar que a combinação de LPQ com MLP foi o único experimento dos dois que obteve um desempenho inferior ao seu baseline. Porém apesar de o outro experimento (usando LETRIST com DT) ter alcançado a mesma colocação contando com esta performance positiva, isso foi feito utilizando mais de 200 atributos, enquanto este obteve a mesma performance utilizando apenas 51 dos 256 atributos disponíveis pelo extrator LPQ.

Em ambos os casos, ao pensar no uso desta abordagem em um cenário real de triagem de pacientes isso realmente chama a atenção, pois uma vez que os extratores LPQ e LETRIST geram apenas 256 e 413 atributos respectivamente, isso possibilita um resultado mais rápido tanto na extração, quanto na seleção e classificação a partir das imagens de raios-X ao reduzir seu custo computacional. Apesar disso, ao olhar um pouco mais para estes resultados, é possível perceber que o experimento que utiliza as características do LPQ, contém mais um ponto interessante. Sendo o fato de que seu baseline é o experimento que obteve o melhor resultado neste cenário de classificação, estando registrado na primeira linha da tabela. Desta forma, é possível dar destaque a este experimento, pois alcançou uma performance apenas  $0,0054$  ( $0,65\%$ ) menor que seu baseline e o melhor resultado do cenário de análise, e ao mesmo tempo, realizou isso utilizando apenas 20% de seus atributos.

Por fim, os demais resultados apresentados, apesar de não destacados no texto, também são interessantes e podem ser analisados da mesma forma que foi feito até aqui. Por curiosidade, além de estarem organizados de forma decrescente pelo resultado atingido, por haver empates, dentro de cada posição em que isso ocorreu, eles estão ordenados pela quantidade de atributos utilizados (da menor para a maior). Não havendo, neste cenário de análise, nenhum experimento que permitisse o algoritmo genético estar entre os cinco melhores resultados. E por se utilizar as mesmas divisões originais da base de dados RYDLS, é possível compará-los diretamente aos resultados apresentados por Pereira et al.

(2020). Assim, por também apresentar os melhores resultados de f1-score para a classe covid-19 ao utilizar diferentes abordagens, para o cenário plano seus resultados variaram de  $0,8000$  a  $0,8333$ . Desta forma, é possível afirmar que, com o uso de métodos de seleção de atributos foi possível obter resultados superiores ao estado da arte utilizando a mesma base de dados, com exatamente a mesma divisão entre treino e teste para a tarefa de classificação plana.

### 5.2.2 Melhores Resultados - Cenário Macro

Ao lidar com a detecção de todas as classes utilizando a abordagem de Classificação Plana, os cinco melhores resultados são apresentados na Tabela 11. Estes resultados, conforme explicado e detalhado na Seção 5.1, se encontram de forma que cada linha é composta por informações de um experimento, estando entre elas, no caso da análise macro, a métrica *Macro Average F1-Score*. Quando analisado a diferença de performance entre cada um deles e seus respectivos baselines, é possível perceber que todos atingiram desempenhos superiores a eles, contendo variações de  $+0,1072$  a  $+0,1782$ . Assim, estes cinco melhores resultados de macro average se encontram entre os valores de  $0,4567$  a  $0,4772$  e contam com uma diminuição de 20% até 90% dos atributos disponíveis para uso entre cada extrator.

Contando com um resultado de  $0,4772$  no experimento que atingiu o melhor desempenho, o classificador MLP com as características do LBP foram utilizados. Apesar de reduzir apenas em 10% a quantidade de atributos utilizados, é possível visualizar que o desempenho do classificador pode ser melhorado em  $+0,1333$  em relação ao seu baseline (experimento sem seleção), sendo esta o segundo melhor ganho de desempenho entre o resultado e o baseline presente na tabela. Assim, como o resultado atingido em si não é o único ponto de interesse, e sim todos os dados apresentados como a quantidade de atributos, é possível visualizar que este experimento conseguiu atingir a melhor performance deste cenário utilizando apenas 47 atributos, sendo numericamente 79, 107 e 283 menos atributos que as três posições subsequentes. Porém percentualmente, em relação à quantidade de atributos disponíveis para serem selecionados, este primeiro experimento utilizou 80% dos atributos, enquanto os outros utilizaram desta quantidade para menos. Uma ênfase na quantidade numérica e percentual foi adicionada, devido principalmente a diferença nas características utilizadas, pois o extrator LBP (usado no experimento #1) gera 59 atributos enquanto o EQP (usado no experimento #2) e LPQ (usado no experimento #3) geram ambos 256 atributos.

Apesar dessas comparações, ao pensar em um cenário real de triagem de pacientes, o uso de apenas 47 atributos em relação a 256 passa a ser muito mais vantajoso computacionalmente. Porém, como dito anteriormente, todos os dados apresentados são importantes e quando olhado que à quantidade de atributos utilizados pelo experimento

Tabela 11 – Resultados - Cenário Macro - Classificação Plana - Seleção Plana

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	LBP	MLP	MI	47 / 59	80%	0,3439	0,4772
2	EQP	RF	GA	126 / 256	49,2%	0,3524	0,4726
3	LPQ	RF	MI	154 / 256	60%	0,2969	0,4751
4	LETRIST	RF	ANV	330 / 413	80%	0,3650	0,4722
5	OBIF	KNN 3	ANV	48 / 484	10%	0,3420	0,4567

com o quinto melhor desempenho, é possível perceber que foi adicionado numericamente apenas um atributo a mais em relação ao primeiro experimento. O que nos leva a afirmação de que o importante não é apenas a quantidade selecionada e sim os atributos que foram selecionados para tentar melhor descrever cada imagem, sendo possível fazer essa análise pelo desempenho  $0,0205$  menor entre eles ao utilizar apenas 10% dos atributos disponíveis do extrator OBIF, enquanto o outro precisou utilizar 80% dos atributos de LBP.

Desta forma, havendo uma maior variedade nos classificadores utilizados por todos os experimentos, os demais resultados apesar de não comentados no texto, também são interessantes e podem ser analisados, não havendo nenhum experimento que permitisse o algoritmo genético estar entre eles. Em relação aos melhores resultados atingidos por Pereira et al. (2020) ao analisar o desempenho de macro average f1-score na aplicação de diferentes abordagens de sampling no cenário plano, eles variam de  $0,4500$  a  $0,6491$ . Não sendo possível neste caso ultrapassar o estado da arte, mas ao menos a faixa de resultados foi mantida ao atingir bons resultados utilizando menos atributos na triagem de sete classes de imagens de raios-X de tórax.

### 5.3 Classificação Hierárquica

Esta seção apresenta a aplicação de métodos de seleção de atributos em um cenário de classificação hierárquico para a triagem e detecção de covid-19 e outras patologias pulmonares. Desta forma, por cenário hierárquico queremos especificar os experimentos utilizando a *Abordagem de Classificação Hierárquica LCPN (Local Classifier per Parent Node)* em que, conforme explicado na Seção 2.2.2.1, para resolver um problema naturalmente hierárquico um classificador multiclasse é treinado em cada nó pai da hierarquia.

Assim, para que fosse possível realizar estes experimentos, duas formas de seleção de atributos no cenário hierárquico foram investigadas, sendo esta seção subdividida entre estas abordagens. Na Seção 5.3.1 o desempenho da classificação hierárquica ao utilizar as seleções de atributos feita previamente de forma plana com as classificações sendo realizadas de forma local é investigada, enquanto na Seção 5.3.2 as seleções de atributos foram realizadas respeitando a abordagem LCPN, em que cada nó pai obteve uma seleção e classificação específica para aquele nó.



### 5.3.1 Desempenho com Seleção Plana

Nos experimentos apresentados nesta seção buscou-se investigar se a aplicação dos atributos selecionados em um cenário plano, poderiam melhorar o desempenho de uma classificação hierárquica. Sendo feito de forma a respeitar o uso do mesmo extrator, e no caso do algoritmo genético, a sua combinação com o mesmo classificador. Assim, todos os rankings e atributos selecionados na Seção 5.2 foram replicados sem haver nenhuma outra alteração para estes experimentos além da troca do cenário de classificação. Desta forma, as Seções 5.3.1.1 e 5.3.1.2 apresentam respectivamente os melhores resultados para os cenários de análise *covid* e *macro*, e com isso o possível efeito deste diferencial na etapa de classificação.

#### 5.3.1.1 Melhores Resultados - Cenário Covid

A Tabela 12 apresenta os cinco melhores resultados na tarefa de detecção da classe covid-19 ao utilizar a abordagem de classificação hierárquica com os atributos sendo selecionados de forma plana. Nela, uma vez que cada linha representa um experimento, conforme explicado na Seção 5.1, os resultados obtidos para métrica f1-sobre da classe covid-19 variam de  $0,7869$  a  $0,8438$ . Ao comparar cada um destes resultados usando seleção de atributos aos seus respectivos baselines sem aplicar seleção, é possível visualizar uma diferença de  $+0,0202$  a  $+0,0727$  de desempenho em relação a eles. Com isso, podemos afirmar que ao simplesmente manter as seleções e trocar a abordagem de classificação, todos os classificadores puderam obter melhores performances ao aplicar algum tipo de seleção e com isso atingiram resultados mais altos.

Tabela 12 – Resultados - Cenário Covid - Classificação Hierárquica - Seleção Plana

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
1	LPQ	MLP	ANV	102 / 256	40%	0,7931	0,8438
2	LPQ	MLP	ANV	77 / 256	30%	0,7931	0,8302
3	LPQ	SVM	ANV	51 / 256	20%	0,7667	0,8214
	LPQ	SVM	ANV	128 / 256	50%	0,7667	0,8000
4	LPQ	SVM	ANV	154 / 256	60%	0,7667	0,8000
	LETRIST	DT	ANV	230 / 256	90%	0,7273	0,8000
-	LPQ	MLP	-	256	100%	-	0,7931
5	LPQ	SVM	ANV	77 / 256	30%	0,7667	0,7869

Nos resultados presentes na Tabela 12, pode-se visualizar que apesar de estarem limitados aos cinco melhores, um total de oito experimentos são apresentados uma vez que houveram três empates obtendo o mesmo desempenho na terceira colocação, sendo seguido por um resultado de baseline o qual não recebeu uma posição no ranking para permitir o foco na seleção de atributos. De todos estes experimentos, cinco conseguiram atingir seus resultados utilizando percentualmente menos de 50% dos atributos disponíveis para cada um, enquanto numericamente quase todos (6 dos 8) conseguiram essas performances usando menos de 155 atributos.

Atingindo um resultado de  $0,8438$ , o experimento na primeira colocação conseguiu melhorar em  $+0,0507$  o desempenho do classificador MLP ao utilizar apenas 40% dos atributos do extrator LPQ. Assim, por realizar as seleções com método ANV, ao utilizar apenas 102 atributos dos disponíveis pelo extrator, foi possível obter resultados superiores aos apresentados na Seção 5.2.1, dos que realizam seleção de atributos, com o mesmo extrator e classificador em que uma seleção e classificação plana foram realizadas e resultado (máximo)  $0,8421$  foi atingido. Porém, fazendo um contraponto em relação a quantidade de atributos utilizados, ao diminuir a quantidade de 40% para 20% dos atributos do LPQ, o cenário de seleção e classificação plano continuam com um maior desempenho ( $0,8421$  - #1 - Tabela 10) comparado com cenário atual ( $0,8214$  - #3 - Tabela 12). Desta forma, o experimento na terceira posição (#3) é o único, no cenário de classificação hierárquico com as seleções feitas de forma plana, mais próximo do primeiro resultado contendo um menor uso de atributos.

Em relação aos extratores, é possível visualizar que neste cenário quase todos os melhores experimentos atingiram seus resultados utilizando o LPQ, porém no caso dos classificadores, o SVM apareceu no ranking sendo utilizado quatro vezes ao contrário dos experimentos da Seção 5.2.1, em que apenas DT e MLP se fizeram presentes. Não havendo, nenhum experimento que permitisse o algoritmo genético estar entre os cinco melhores resultados neste cenário de análise. Ao comparar os resultados obtidos neste cenário com os apresentados em (PEREIRA et al., 2020) para Covid F1-Score no cenário hierárquico não é possível dizer que o estado da arte foi batido, uma vez que ao utilizar abordagens de sampling os resultados de  $0,8276$  a  $0,8889$  foram obtidos, enquanto os presentes nesta seção estiveram entre  $0,7869$  a  $0,8438$ , não atingindo resultados superiores, porém se mantendo dentro da mesma faixa de resultados, gerando assim resultados satisfatórios, com um menor custo e complexidade.

### 5.3.1.2 Melhores Resultados - Cenário Macro

Ao aplicar atributos selecionados de forma plana em um cenário de classificação hierárquico, os cinco melhores resultados para o cenário de análise macro, ou seja, para a detecção de todas as classes são apresentados na Tabela 13. Nesta tabela, é possível visualizar os experimentos que obtiveram os melhores resultados para métrica *Macro Average F1-Score*, que seguindo explicação presente na Seção 5.1 cada um deles é representado por uma linha. Assim, ao comparar cada um destes resultados obtidos a partir dos experimentos utilizando seleção de atributos com seus respectivos baselines sem nenhuma seleção, é possível visualizar de que quase todos atingiram desempenhos superiores a eles, variando de  $+0,0000$  a  $+0,1877$ , e alcançando desta forma resultados entre  $0,4859$  e  $0,5284$ . Com isso, os melhores experimentos deste cenário de análise mostram que é possível melhorar o desempenho de classificadores ao utilizar algum tipo de seleção de atributos, reduzindo sua quantidade e por conseguinte o custo computacional.

Tabela 13 – Resultados - Cenário Macro - Classificação Hierárquica - Seleção Plana

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	LBP	MLP	MI	53 / 59	90%	0,3498	0,5284
2	LPQ	KNN 3	MI	128 / 256	50%	0,4859	0,5063
3	LPQ	KNN 4	MI	102 / 256	40%	0,4859	0,4999
4	LETRIST	DT	ANV	372 / 413	90%	0,3018	0,4895
5	LPQ	KNN 3	MI	230 / 256	90%	0,4859	0,4859
-	LPQ	KNN 3	-	256	100%	-	0,4859

Ao analisar a Tabela 13 é possível visualizar que o experimento com melhor desempenho conseguiu melhorar em  $+0,1786$  a performance, em relação ao seu respectivo baseline, do classificador MLP ao utilizar 90% dos atributos do extrator LBP. Assim, por utilizar os atributos selecionados de forma plana pelo método MI e aplicá-los ao mesmo classificador em um cenário hierárquico, com classificações sendo realizadas em cada ó pai, foi possível obter melhores resultados do que os apresentados na Seção 5.2.2 (seleção e classificação plana), e com isso atingir um desempenho  $0,0512$  maior ao sair de  $0,4772$  (#1 - Tabela 11) para  $0,5284$  (#1 - Tabela 13). Porém, ao trabalhar com seleção também é interessante olhar para a quantidade de atributos utilizada para se atingir tal resultado, o que neste cenário se mostrou um pouco menos vantajoso computacionalmente, uma vez que, o experimento no cenário de classificação plana com seleção plana (Seção 5.2.2) obteve seu melhor resultado ao utilizar 80% (47 de 59) atributos do extrator LBP, enquanto no cenário atual aplicando as mesmas seleção feitas de forma plana em um cenário de classificação hierárquico, o melhor resultado foi obtido ao utilizar 90% (53 de 59) atributos do mesmo extrator.

Nos experimentos apresentados nesta seção, diferentes combinações entre extratores e classificadores estavam presentes, estando entre elas o próprio MLP combinado com os atributos do LBP em um experimento, o KNN com 3 vizinhos em outros quatro experimentos combinados com o extrator LPQ, e uma vez o DT combinado com o LETRIST. Não havendo neste cenário de análise nenhum experimento que permitisse o algoritmo genético estar entre os melhores resultados. Assim, com o resultados de  $0,4615$  a  $0,5669$  apresentados por Pereira et al. (2020) sendo os melhores macro averages alcançados, ao se utilizar abordagens de sampling em um cenário de classificação hierárquica, podemos afirmar que não foi possível ultrapassar o estado da arte neste cenário de análise, sendo possível apenas mantê-los na mesma faixas de resultados ao utilizar menos atributos na triagem das sete classes pulmonares.

### 5.3.2 Desempenho com Seleção LCPN

Os experimentos apresentados nesta seção buscam investigar os efeitos da aplicação de métodos de seleção de atributos de forma a seguir a *Abordagem de Classificação Hierárquica LCPN* em que cada nó pai contém um classificador próprio. Assim, ao buscar um melhor desempenho do que nos cenários anteriores, todas as seleções e classificações foram realizadas de maneira individual para cada um nó-pai presente na hierarquia. Com isso, os melhores resultados para os cenários de análise *covid* e *macro* são apresentados nas Seções 5.3.2.1 e 5.3.2.2 respectivamente.

#### 5.3.2.1 Melhores Resultados - Cenário Covid

Os melhores cinco resultados na tarefa de detecção de covid-19 ao utilizar a Abordagem de Classificação Hierárquica LCPN, com as seleções e classificações sendo feitas de forma individual para cada nó pai, são apresentados na Tabela 14. Nesta tabela, conforme explicado e detalhado na Seção 5.1, cada linha contém as informações de um experimento e ao comparar cada um destes resultados (obtidos ao aplicar métodos de seleção) com seus respectivos baselines (sem aplicar seleção), é possível visualizar que eles obtiveram resultados superiores, com suas performances variando de  $+0,0006$  a  $+0,0398$ . Desta forma, ao analisar o desempenho exclusivamente para a classe covid-19, seus valores para a métrica f1-score se encontram entre  $0,7937$  a  $0,8197$  e contam, em sua maioria, com a diminuição de até metade dos atributos disponíveis por cada extrator.

Tabela 14 – Resultados - Cenário Covid - Classificação Hierárquica - Seleção Local

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
1	LPQ	MLP	MI	128 / 256	50%	0,7931	0,8197
2	LPQ	MLP	GA	-	45,7%	0,7931	0,8136
3	LPQ	SVM	ANV	179 / 256	70%	0,7667	0,8065
4	LPQ	SVM	ANV	51 / 256	20%	0,7667	0,8000
	LPQ	SVM	ANV	77 / 256	30%	0,7667	0,8000
5	LPQ	MLP	ANV	26 / 256	10%	0,7931	0,7937

Nestes experimentos, o melhor resultado foi atingido ao utilizar 50% dos atributos gerados pelo extrator LPQ e classificados pelo MLP. Assim, por se utilizar do método Mutual Information ao selecionar 128 dos 256 atributos disponíveis foi possível atingir um resultado de 0,8197, o que infelizmente foi um resultado inferior a todos obtidos com seleção e classificação feitas de forma plana, e apresentados anteriormente na Tabela 10, sendo apenas compatível com o último resultado lá apresentado. E quando brevemente comparado aos resultados apresentados na Tabela 12, obtidos com uma classificação hierárquica e atributos selecionados de forma plana, o melhor resultado desta seção (#1 - Tabela 14) se encontra entre o terceiro e quarto experimento com melhor desempenho da Tabela 12.

Sendo o único cenário de análise covid desta pesquisa a apresentar entre os cinco melhores, o resultado obtido por um classificador após a seleção ser efetuada por um algoritmo genético, o segundo melhor desempenho da Tabela 14 conta com uma performance  $0,0205$  maior que seu baseline. Seguindo a explicação feita na Seção 5.1, em que cada linha apresenta um experimento, este resultado em destaque não conta com valores nas colunas de quantidade e porcentagem de atributos utilizados, porque não existe um valor único para esta seleção em toda a hierarquia, e sim uma quantidade diferente (otimizada) entre cada classificação e por conseguinte cada nó pai.

Assim, ao olhar para os extratores mais utilizados, é interessante reparar que no caso deste cenário de classificação apenas o extrator LPQ se fez presente, porém apresentando variações entre os classificadores SVM e MLP. Por fim, e apesar de resultados menores, é interessante ressaltar que houve um experimento que utilizou apenas 10% dos atributos extraídos pelo LPQ, o que resulta na utilização de apenas 26 atributos de 256, ou seja, a menor quantidade utilizada até o momento entre os melhores experimentos no cenário de análise covid.

Desta forma, ao comparar diretamente com os resultados apresentados em (PEREIRA et al., 2020) no cenário de classificação hierárquica ao analisar o desempenho do classificador para classe covid-19, os melhores valores de f1-score ao utilizar diferentes abordagens variaram de  $0,8276$  a  $0,8889$ . Com isso, os resultados apresentados nesta seção apesar de próximos não superam o estado da arte, contendo variações de desempenhos de  $-0,0079$  a  $-0,0339$  em relação ao menor valor atingido e apresentado, entre os melhores, por Pereira et al. (2020), ao utilizar diferentes abordagens de sampling. Apesar disso, estes resultados não necessariamente devem ser vistos como algo completamente ruim devido a considerável redução no uso de atributos e custo computacional para atingi-los.

### 5.3.2.2 Melhores Resultados - Cenário Macro

Visando analisar o desempenho das classificações na detecção de todas as classes, a Tabela 15 apresenta os cinco melhores resultados, para macro average, obtidos ao utilizar a *Abordagem de Classificação Hierárquica LCPN*, ou seja, com seleções e classificações sendo realizadas para cada nó pai da hierarquia. Para isso, conforme detalhado na Seção 5.1, estes resultados são organizados de forma que cada linha representa um experimento, e no cenário de análise macro apresenta o valor de *Macro Average F1-Score* obtido. Ao comparar cada um destes resultados (aplicando seleção de atributos) com seus respectivos baselines (sem aplicar seleção), é possível visualizar que todos obtiveram desempenhos superiores e contam com variações de  $+0,0162$  a  $+0,1380$  em relação a eles. Assim, estes cinco melhores resultados de macro average se encontram entre os valores de  $0,5021$  a  $0,5851$  e contam em sua maioria com o uso de mais que 50% dos atributos disponíveis para uso entre cada extrator, algo compreensível devido a necessidade de se distinguir e

interpretar diversas classes, porém ainda necessitando de no mínimo 128 atributos neste cenário.

Ao analisar a Tabela 15, seguindo a explicação de que cada experimento é representado por uma linha, é possível visualizar que o experimento com melhor performance obteve um resultado de  $0,5851$  ao melhorar em  $+0,1380$  o desempenho do classificador MLP usando 60% dos atributos do extrator BSIF. Assim, por utilizar o método de seleção ANOVA para selecionar 154 dos 256 disponíveis, este experimento conseguiu atingir o melhor resultado desta pesquisa para o cenário de análise macro, uma vez que os melhores resultados atingidos pelos cenários apresentados nas Seções 5.2.2 (classificação e seleção plana) e 5.3.1.2 (classificação hierárquica com seleção plana) foram de  $0,4772$  e  $0,5284$  respectivamente.

Tabela 15 – Resultados - Cenário Macro - Classificação Hierárquica - Seleção Local

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	ANV	154 / 256	60%	0,4471	0,5851
2	LPQ	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
3	LPQ	KNN 3	ANV	205 / 256	80%	0,4859	0,5362
4	LPQ	KNN 3	ANV	179 / 256	70%	0,4859	0,5199
5	LPQ	KNN 3	MI	154 / 256	60%	0,4859	0,5021

Em relação aos outros experimentos presentes na tabela, é possível visualizar novas combinações de classificadores com extratores utilizados entre os melhores resultados. Essa variação se deu em relação ao uso do extrator BSIF combinado com o classificador MLP, e ao classificador KNN com 3 vizinhos utilizando os atributos do extrator LPQ, não havendo nenhum experimento que permitisse o algoritmo genético estar entre eles. Com isso, ao compará-los com os melhores resultados de macro average para o cenário de classificação hierárquico apresentado por Pereira et al. (2020), que variam entre  $0,4615$  a  $0,5669$  ao utilizar abordagens de samping, é possível ver um aumento de  $0,0182$  em relação ao resultado mais alto apresentado. Desta forma, pode-se dizer que o uso de seleção de atributos em um cenário de classificação (e seleção) hierárquica permitiu ultrapassar o estado da arte e obter resultados superiores utilizando uma menor quantidade de atributos.

## 5.4 Classificação Plana VS Hierárquica

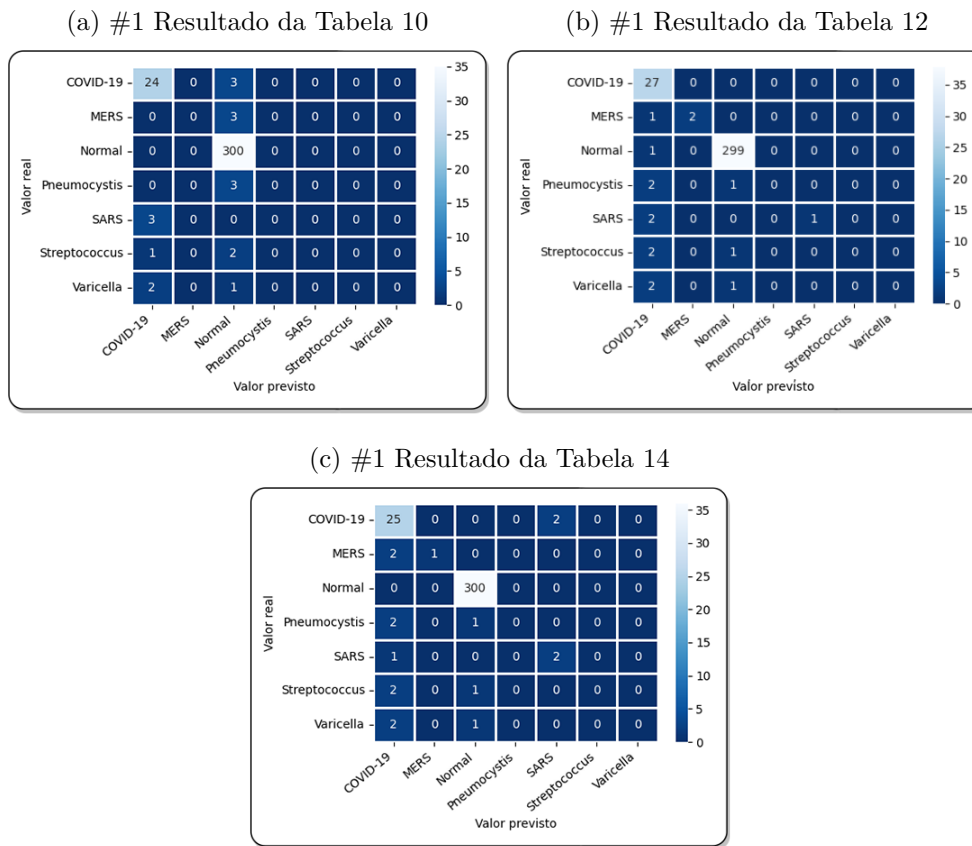
Com os melhores resultados apresentados de forma a analisar tanto o desempenho geral do classificador como da classe covid-19 em diferentes cenários de classificação, uma análise em relação ao desempenho entre eles passa a ser interessante. Essa análise só é possível ser realizada uma vez que estamos lidamos com um problema MLNP (*Mandatory Leaf-Node Prediction*) e a base de dados atual contém todas as suas instâncias rotuladas até o nó-folha FD (*Full Depth labeling*). Desta forma, as Seções 5.4.1 e 5.4.2 apresentam as matrizes de confusão do melhor resultado de cada um dos cenários apresentados anteriormente, sendo seguidos por uma breve análise em relação à melhor abordagem de classificação por extrator presente na Seção 5.4.3.

### 5.4.1 Performance no Cenário Covid

A fim de comparar os melhores resultados apresentados nos cenários de análise covid, a Figura 30 foi criada de forma a mostrar lado a lado as matrizes de confusão para cada uma das abordagens de classificação utilizadas, sendo elas: (a) classificação plana com seleção plana; (b) classificação hierárquica com seleção plana; (c) e classificação hierárquica com seleção LCPN. Assim, por estarmos analisando o desempenho ao utilizar métodos de seleção, e pelos rankings nas tabelas não incluírem os baselines, apenas os melhores experimentos obtidos ao aplicar seleção de atributos estão presentes.

Das matrizes apresentadas, os respectivos resultados de Covid-19 F1-Score para as imagens (a), (b) e (c) são  $0,8421$ ,  $0,8438$  e  $0,8197$ , o que representa uma evolução na distinção da classe covid-19 conforme o aumento de complexidade do cenário de classificação. Além disso, também é possível visualizar uma grande diminuição na confusão de todas as classes com a classe normal ao trocar a abordagem de classificação plana para a hierárquica (a  $\rightarrow$  b, c). Desta forma, considerando o cenário atual de testes com 352 amostras sendo apenas 52 subtipos de pneumonia, ao analisar a evolução da troca de seleção feita de forma plana para a feita de forma local no cenário de classificação hierárquico (b  $\rightarrow$  c), houve uma pequena diminuição na confusão de outras classes com covid (10 para 9 falsos positivos para covid) porém um aumento na confusão de covid com sars (0 para 2 verdadeiros negativos para covid). Assim, é possível afirmar que os erros foram transferidos para locais mais profundos da hierarquia, uma vez que ocorreram menos confusões das patologias com a classe normal.

Figura 30 – Matrizes de confusão - Cenário de Análise Covid



### 5.4.2 Performance no Cenário Macro

Para que fosse possível comparar os melhores resultados apresentados nos cenários de análise macro, a Figura 31 foi criada de forma a mostrar lado a lado as matrizes de confusão para cada uma das abordagens de classificação utilizadas, sendo elas: (a) classificação plana com seleção plana; (b) classificação hierárquica com seleção plana; (c) e classificação hierárquica com seleção LCPN. Assim, como neste cenário de análise todos os melhores resultados foram atingidos utilizando algum tipo de seleção, nesta análise foram selecionados todos os primeiros resultados de cada uma das abordagens.

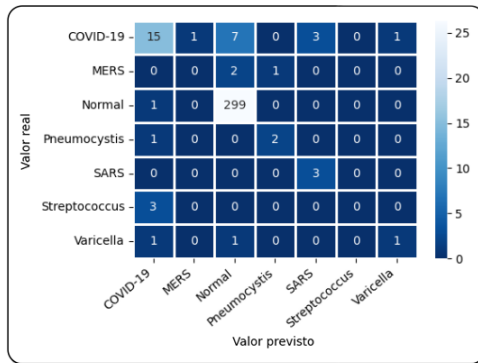
Dadas as matrizes (a), (b) e (c) presentes na imagem, seus respectivos resultados de Macro-Avg F1-Score são  $0,4772$ ,  $0,5284$  e  $0,5851$ . Desta forma, como neste cenário o foco é o desempenho geral do classificador, ou seja, todas as classes, é interessante visualizar a diferença nos acertos das diagonais principais de cada um dos experimentos. Assim, ao somar todos os acertos presentes em cada uma delas, temos a evolução de 320 para 321 e depois 325 conforme a alteração do cenário de seleção e classificação. Junto com isso, é possível visualizar a diminuição dos erros de várias classes com covid e dele com Varicella, seguido por um aumento dos acertos das classes covid e normal.

Considerando o cenário atual de testes com 352 amostras sendo apenas 52 subtipos de pneumonia, ao olhar para a mudança na forma de seleção no cenário de classificação

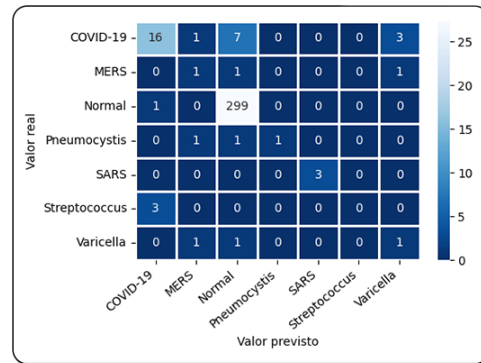


Figura 31 – Matrizes de confusão - Cenário de Análise Macro


(a) #1 Resultado da Tabela 11



(b) #1 Resultado da Tabela 13



(c) #1 Resultado da Tabela 15



hierárquico, saindo de plana para a local (b  $\rightarrow$  c), é possível notar que houve uma diminuição no erro de covid com normal e varicella, havendo assim uma distribuição deles para outras classes e alguns novos acertos. Em relação às outras classes, é possível visualizar que os erros se mantiveram em níveis mais profundos da hierarquia, sendo a classe Streptococcus a única que não obteve ao menos um acerto em nenhum dos três experimentos.

### 5.4.3 Performance por Extrator

Considerando o número de possibilidades de combinações entre extratores, métodos de seleção e classificadores, pelos resultados apresentados conterem apenas os cinco melhores para cada abordagem de classificação, muitas vezes houveram extratores que se destacaram e ocuparam várias dessas posições. Assim, a fim de entender/visualizar qual cenário de classificação se mostrou eficiente e se destacou mais vezes com diferentes extratores, esta seção apresenta nas Tabelas 16 e 17 o melhor resultado atingido para cada um dos extratores (disponíveis na RYDLS) nos cenários de análise covid e macro respectivamente. Considerando o explicado na Seção 5.1 em que cada linha dos resultados apresentados representa um experimento. Esta seção apresenta uma nova coluna chamada “cenário” dedicada ao *cenário de classificação* ao qual aquele resultado pertence, sendo preenchida

de forma a abreviar: (*Plano*) classificação plana com seleção plana; (*H-Plano*) classificação hierárquica com seleção plana; e (*H-Local*) classificação hierárquica com seleção LCPN. Além disso, como o foco da pesquisa é a seleção de atributos, alguns poucos resultados foram filtrados no caso de o melhor desempenho para determinado extrator ser o próprio baseline sem a realização de uma seleção. Desta forma ao contrário das seções anteriores, estes resultados que utilizam todos os atributos não aparecem na tabela para permitir a visualização de apenas um experimento por extrator. Também, em caso de algum empate em performance e resultado, o experimento com o menor uso de atributos foi selecionado e apresentado na tabela.

Começando pelo cenário de análise covid, todos os melhores resultados obtidos para cada um dos extratores se encontram na Tabela 16 e obtiveram desempenhos superiores aos seus baselines, variando de  $+0,0132$  até  $+0,2267$  em relação a eles. Sendo o experimento com melhor performance apresentado na Seção 5.3.1.1, o resultado de 0,8438 foi atingido ao utilizar ANV para selecionar (de forma plana) 77 dos 256 atributos do extrator LPQ e classificá-los com o MLP no cenário hierárquico. Em relação ao experimento que obteve maior acréscimo de desempenho ao aplicar seleção de atributos, o extrator EQP por utilizar apenas 77 de seus 256 atributos em uma classificação plana com seleção plana, permitiu um aumento de  $42,508\%$  na performance do classificador por utilizar  $70\%$  menos de atributos.

Tabela 16 – Resultados por Extrator - Cenário Covid

EXT	CENÁRIO	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
LPQ	H-Plano	MLP	ANV	102 / 256	40%	0,7931	0,8438
LETRIST	Plano	DT	MI	248 / 413	60%	0,7308	0,8421
BSIF	H-Plano	MLP	ANV	230 / 256	90%	0,5909	0,7692
EQP	Plano	KNN 3	MI	77 / 256	30%	0,5333	0,7600
OBIF	Plano	SVM	ANV	48 / 484	10%	0,7037	0,7547
LDN	H-Plano	SVM	ANV	6 / 56	10%	0,7368	0,7500
LBP	H-Local	MLP	MI	12 / 59	20%	0,6792	0,7170
INCEPTION	Plano	MLP	ANV	205 / 2048	10%	0,5000	0,6182

Assim, ao comparar os classificadores mais utilizados nos diferentes extratores para atingir seus melhores desempenhos, é possível visualizar que o MLP esteve presente em quatro experimentos, seguido por SVM em dois experimentos e por fim DT e KNN 3 em apenas um experimento. E em relação aos métodos de seleção mais utilizados, ANOVA esteve em cinco experimentos, enquanto Mutual Information apenas em dois, e o genético em nenhum.

Por fim, ao analisar os cenários de classificação que mais permitiram os extratores atingirem sua maior performance, podemos dizer que houve um que se destacou no caso da classificação específica da classe covid-19. Estando presente em quatro experimentos, o cenário de seleção e classificação Plano recebe este destaque, sendo seguido pelo cenário H-Plano, com seleção plana e classificação hierárquica presente em três experimentos e

finalizando com o cenário H-Local, com seleção e classificação feitas de forma hierárquica LCPN, presente em apenas um experimento

Agora olhando para o cenário de análise macro, todos os melhores resultados obtidos para cada um dos extratores se encontram na Tabela 17 e obtiveram desempenhos superiores aos seus baselines contando com uma variação de  $+0,0528$  a  $+0,1877$  em relação a eles. Com o maior resultado de 0,5851 alcançado ao utilizar ANOVA para selecionar de forma local (H-Local) os melhores atributos do extrator BSIF, conforme apresentado na Seção 5.3.2.2, 154 dos 256 atributos foram utilizados permitindo uma performance  $+0,1350$  maior em relação ao seu baseline. Assim, considerando o experimento que obteve maior acréscimo de desempenho ao aplicar seleção de atributos o extrator LETRIST, conseguiu obter um aumento de  $38,345\%$  no resultado de seu baseline ao utilizar 10% menos atributos, pelo simples fato de utilizar ANOVA para selecionar 372 dos 413 atributos disponíveis.

Tabela 17 – Resultados por Extrator - Cenário Macro

EXT	CENÁRIO	CLF	MS	Nº Atributos	% Atributos	Baseline	Macro Avg ↓
BSIF	H-Local	MLP	ANV	154 / 256	60%	0,4471	0,5851
LPQ	H-Local	KNN 3	ANV	128 / 256	50%	0,4859	0,5387
LBP	H-Plano	MLP	MI	47 / 59	80%	0,3498	0,5284
LETRIST	H-Plano	DT	ANV	372 / 413	90%	0,3018	0,4895
EQP	Plano	RF	GA	126 / 256	49,2%	0,3524	0,4726
OBIF	Plano	KNN 3	ANV	48 / 484	10%	0,3420	0,4567
INCEPTION	Plano	MLP	ANV	410 / 2048	20%	0,2887	0,4224
LDN	H-Local	KNN 3	ANV	6 / 56	10%	0,3248	0,4153

Desta forma, ao prestar atenção e comparar os classificadores mais utilizados em conjunto com os extratores para atingir seus melhores desempenhos, é possível visualizar que o MLP e o KNN 3 estiveram presentes na maior parte dos experimentos, em três deles cada. Sendo seguido pelo DT e RF presentes cada um em apenas um. Em relação aos métodos de seleção mais utilizados no cenário macro, o ANV se fez presente em seis experimentos, enquanto Mutual Information e o Algoritmo Genético estiveram apenas em um experimento cada.

Assim, ao analisar os cenários de classificação que mais permitiram os extratores atingirem sua maior performance, potencializando os resultados de macro-avg e por consequência ao acerto de mais classes, pode-se dizer que o uso da abordagem hierárquica possibilitou um maior desempenho. somando o cenário *H-Plano* quanto o *H-Local* obtemos o dobro da quantidade de vezes em que o cenário *Plano* esteve presente nestes experimentos. Podendo ser levado em consideração também a presença deles nas quatro primeiras posições, mostrando seu melhor desempenho ao prever classes diferentes.



## 6 CONCLUSÃO

A pandemia da COVID-19 afetou a maneira que vivemos por quase três anos, e diante dessa situação muitos pesquisadores foram em busca de soluções para ajudar neste cenário. Sendo a triagem de pacientes afetados pelo vírus a forma inicial de combate, a rápida identificação e isolamento dos infectados passou a ser o foco de muitas destas pesquisas. Dentro da triagem de pacientes, pelo coronavírus afetar principalmente o pulmão, a aplicação de aprendizado da máquina para a classificação de imagens de raios X de tórax se tornou uma possibilidade de contribuição do mundo da tecnologia ajudar na área da saúde.

Neste contexto, o presente trabalho foi desenvolvido pelo incentivo do governo por meio da CAPES e inspiração direta no trabalho de Pereira et al. (2020), tanto pela criação da base de dados RYDLS quanto pelo uso da classificação hierárquica para resolver o atual problema. Uma vez que imagens de raios X necessitam de equipamentos mais baratos e são mais acessíveis que CT Scan, foi escolhido trabalhar com essas imagens. Desta forma, esta pesquisa investigou se o uso de diferentes métodos de seleção de atributos poderia melhorar o desempenho de diferentes algoritmos de aprendizagem de máquina na tarefa de previsão de diferentes patologias pulmonares a partir de imagens de raios X.

Para isso, diferentes abordagens de seleções e classificações foram utilizadas e desta forma diferentes combinações foram testadas. Havendo disponíveis na RYDLS oito tipos de características vindas de diferentes abordagens de extração, as melhores foram selecionadas utilizando três métodos filters e um algoritmo genético. Assim, com as características/atributos selecionados, as previsões foram feitas utilizando cinco diferentes classificadores, combinados com diferentes quantidades e/ou porcentagens de atributos selecionados (no caso dos filters). Com isso, sendo tudo aplicado tanto ao cenário de classificação Plano quanto Hierárquico LCPN (x2), um total de 2.832 experimentos foram realizados.

Então, conforme os resultados apresentados no Capítulo 5, concluímos que é possível melhorar a detecção de covid-19 juntamente com outros cinco tipos de patologias pulmonares a partir da seleção de atributos. Não podendo deixar de fora o caso dos melhores resultados do cenário de análise covid com classificação plana, o qual foi o único momento da pesquisa em que não houve melhora do experimento utilizando seleção em relação ao seu baseline (sem seleção), porém resultados próximos foram alcançados o que dependendo do caso também é relevante por se fazer a troca de X performance por Y tempo de classificação.

Assim, ao olhar para o cenário de análise covid, em que apenas a performance da

classe covid-19 e por consequência seu f1-score é levado em consideração, com as diversas combinações e experimentos realizados foi possível atingir respectivamente os resultados de  $0,8421$ ,  $0,8438$  e  $0,8197$  para os cenários de classificação *Plano*, *H-Plano* e *H-Local*. Sendo ( $0,8438$ ) o melhor resultado alcançado ao utilizar o classificador MLP de forma Hierárquica LCPN, em que sua seleção de atributos foi realizada de forma plana, isso foi possível ao aplicar o método ANOVA para selecionar 102 dos 256 (40%) atributos de LPQ. Desta forma, ao olhar cenário de análise macro, em que todas as classes são levadas em consideração e o macro-avg f1-score do experimento é analisado, os melhores resultados alcançados foram respectivamente  $0,4772$ ,  $0,5284$  e  $0,5851$  para os cenários de classificação *Plano*, *H-Plano* e *H-Local*. Uma vez que o melhor resultado ( $0,5851$ ) foi alcançado ao utilizar o classificador MLP de forma Hierárquica LCPN, sua seleção também foi realizada de forma local ao aplicar ANOVA aos atributos de BSIF e obter essa performance por utilizar 154 dos 256 (60%) seus atributos.

Com isso, uma vez que o uso de seleção de atributos permitiu ultrapassar o estado da arte ao obter resultados superiores utilizando uma menor quantidade de atributos em alguns cenários de análise, os cenários covid (plano) e macro (hierárquico) ganham este destaque. Ao utilizar a mesma base de dados e divisões treino/teste de cada extrator os seguintes resultados foram atingidos por Pereira et al. (2020): para o f1-score da classe covid-19 seus resultados ficaram entre  $0,8000$  a  $0,8889$ , sendo  $0,8333$  o melhor resultado do cenário plano e  $0,8889$  o melhor do hierárquico; para macro-avg f1-score seus resultados ficaram entre  $0,4500$  a  $0,6491$ , sendo  $0,6491$  o melhor resultado do cenário plano e  $0,5669$  o melhor do hierárquico.

Desta forma, contendo resultados compatíveis com o estado da arte, uma análise detalhada sobre eles pode ser encontrada no Capítulo 3 em que também é possível visualizar a evolução dos melhores resultados conforme a mudança de cenário e seleção. E uma vez que o uso de métodos de seleção de atributos melhorou o desempenho da identificação do coronavírus independente do tipo de dado extraído, este é o primeiro trabalho (até onde sabemos) a explorar o uso de seleção de atributos em uma base de dados de covid-19 altamente desbalanceada contendo amostras de mais de três classes nos cenários de classificação plano e hierárquico.

Em relação às limitações da pesquisa, apesar de relevante e inovador trabalhar com uma base tão desbalanceada no atual contexto, pode-se afirmar que isso possivelmente foi um empecilho. Pois, ao não realizar nenhum tipo de balanceamento como na pesquisa base, os seletores tiveram dificuldades em identificar os atributos mais relevantes (das classes mais importantes) em cada cenário devido a pouca quantidade de amostras, algo que pode ser visto analisando a diferença de performance ao trocar as seleções planas para as locais (hierárquicas).

Por fim, considerando que este trabalho buscava em primeiro lugar analisar o

desempenho da seleção de atributos para resolver o problema escolhido e assim averiguar sua eficácia e viabilidade, uma vez se comprovando viável, as próximas etapas podem seguir algumas vertentes, estando entre elas: testar outras bases de dados; utilizar dos outros datasets disponíveis na RYDLS em que técnicas de sampling foram aplicadas e analisar a diferença de desempenho ao se ter mais amostras; buscar novas imagens, realizar técnicas de augmentation ou buscar outras formas de aumentar as bases e equalizar a quantidade de amostras nas classes; combinar atributos de diferentes extratores para realizar as seleções; otimizar e calibrar o algoritmo genético com mais tempo buscando um melhor desempenho; testar diferentes métodos filters uma vez que se mostraram promissores e tem baixo custo computacional; realizar testes de cross-validation e/ou estatísticos para comprovar o real desempenho de tudo o que foi feito.





## Referências

- AHMED, Shameem; SHEIKH, Khalid Hassan; MIRJALILI, Seyedali; SARKAR, Ram. Binary simulated normal distribution optimizer for feature selection: Theory and application in covid-19 datasets. *Expert Systems with Applications*, v. 200, p. 116834, 2022. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417422002871>>. Citado 2 vezes nas páginas 53 e 56.
- ALI, Rasha H.; ABDULSALAM, Wisal Hashim. The prediction of COVID 19 disease using feature selection techniques. *Journal of Physics: Conference Series*, IOP Publishing, v. 1879, n. 2, p. 022083, may 2021. Disponível em: <<https://doi.org/10.1088/1742-6596/1879/2/022083>>. Citado 3 vezes nas páginas 51, 53 e 56.
- ALMUGREN, Nada; ALSHAMLAN, Hala. A survey on hybrid feature selection methods in microarray gene expression data for cancer classification. *IEEE Access*, v. 7, p. 78533–78548, 2019. Citado na página 28.
- ALSAEEDI, Mokhalad abdulameer kadhim; KURNAZ, Sefer. Feature selection for diagnose coronavirus (covid-19) disease by neural network and caledonian crow learning algorithm. *Applied Nanoscience*, 2022. ISSN 2190-5517. Disponível em: <<https://doi.org/10.1007/s13204-021-02159-x>>. Citado 2 vezes nas páginas 53 e 56.
- ALY, Mohamed. Survey on multiclass classification methods. *Neural Netw*, Citeseer, v. 19, n. 1-9, p. 2, 2005. Citado 3 vezes nas páginas 40, 41 e 44.
- ASLAN, Narin; Ozmen Koca, Gonca; KOBAT, Mehmet Ali; DOGAN, Sengul. Multi-classification deep cnn model for diagnosing covid-19 using iterative neighborhood component analysis and iterative relieff feature selection techniques with x-ray images. *Chemometrics and Intelligent Laboratory Systems*, v. 224, p. 104539, 2022. ISSN 0169-7439. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169743922000508>>. Citado 4 vezes nas páginas 51, 53, 54 e 56.
- BANDYOPADHYAY, Rajarshi; BASU, Arpan; CUEVAS, Erik; SARKAR, Ram. Harris hawks optimisation with simulated annealing as a deep feature selection method for screening of covid-19 ct-scans. *Applied Soft Computing*, v. 111, p. 107698, 2021. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494621006190>>. Citado 2 vezes nas páginas 53 e 56.
- BENNASAR, Mohamed; HICKS, Yulia; SETCHI, Rossitza. Feature selection using joint mutual information maximisation. *Expert Systems with Applications*, v. 42, n. 22, p. 8520–8532, 2015. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417415004674>>. Citado na página 29.
- BHOWAL, Pratik; SEN, Subhankar; SARKAR, Ram. A two-tier feature selection method using coalition game and nystrom sampling for screening covid-19 from chest x-ray images. *Journal of Ambient Intelligence and Humanized Computing*, 2021. ISSN 1868-5145. Disponível em: <<https://doi.org/10.1007/s12652-021-03491-4>>. Citado 4 vezes nas páginas 51, 53, 55 e 56.

- BREIMAN, Leo. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1023/A:1010933404324>>. Citado na página 43.
- BREIMAN, L.; FRIEDMAN, J.; STONE, C.J.; OLSHEN, R.A. *Classification and Regression Trees*. Taylor & Francis, 1984. ISBN 9780412048418. Disponível em: <<https://books.google.com.br/books?id=JwQx-WOmSyQC>>. Citado na página 40.
- CANAYAZ, Murat. Mh-covidnet: Diagnosis of covid-19 using deep neural networks and meta-heuristic-based feature selection on x-ray images. *Biomedical Signal Processing and Control*, v. 64, p. 102257, 2021. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809420303840>>. Citado 5 vezes nas páginas 23, 51, 53, 54 e 56.
- Carbon Health; Braid Health. *Coronavirus Disease 2019 (COVID-19) Clinical Data Repository*. 2020. Accessed from <<https://covidclinicaldata.org/>>. Citado na página 51.
- CHANDRASHEKAR, Girish; SAHIN, Ferat. A survey on feature selection methods. *Computers & Electrical Engineering*, v. 40, n. 1, p. 16–28, 2014. ISSN 0045-7906. 40th-year commemorative issue. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045790613003066>>. Citado 3 vezes nas páginas 28, 31 e 32.
- CHAUHAN, Hetal; MODI, Kirit; SHRIVASTAVA, Saurabh. Development of a classifier with analysis of feature selection methods for covid-19 diagnosis. *World Journal of Engineering*, Emerald Publishing Limited, v. 19, n. 1, p. 49–57, jan. 2022. ISSN 1708-5284. Disponível em: <<https://doi.org/10.1108/WJE-10-2020-0537>>. Citado 2 vezes nas páginas 53 e 56.
- CHEN, Hongmei; LI, Tianrui; FAN, Xin; LUO, Chuan. Feature selection for imbalanced data based on neighborhood rough sets. *Information Sciences*, v. 483, p. 1–20, 2019. ISSN 0020-0255. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025519300507>>. Citado na página 27.
- CHINCHOR, Nancy. Muc-4 evaluation metrics. In: *Proceedings of the 4th Conference on Message Understanding*. USA: Association for Computational Linguistics, 1992. (MUC4 '92), p. 22–29. ISBN 1558602739. Disponível em: <<https://doi.org/10.3115/1072064.1072067>>. Citado na página 47.
- CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. *Machine Learning*, v. 20, n. 3, p. 273–297, 1995. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1007/BF00994018>>. Citado na página 44.
- COVER, T.; HART, P. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, v. 13, n. 1, p. 21–27, 1967. Citado na página 41.
- COVER, Thomas M. *Elements of information theory*. [S.l.]: John Wiley & Sons, 1999. Citado 2 vezes nas páginas 29 e 30.
- DENIZ, Ayça; KIZILOZ, Hakan Ezgi; SEVINC, Ender; DOKEROGLU, Tansel. Predicting the severity of covid-19 patients using a multi-threaded evolutionary feature selection algorithm. *Expert Systems*, v. 39, n. 5, p. e12949, 2022. Disponível em:

<<https://onlinelibrary.wiley.com/doi/abs/10.1111/exsy.12949>>. Citado 2 vezes nas páginas 53 e 56.

DEY, Arijit; CHATTOPADHYAY, Soham; SINGH, Pawan Kumar; AHMADIAN, Ali; FERRARA, Massimiliano; SENU, Norazak; SARKAR, Ram. Mrfgro: a hybrid meta-heuristic feature selection method for screening covid-19 using deep features. *Scientific Reports*, v. 11, n. 1, p. 24065, 2021. ISSN 2045-2322. Disponível em: <<https://doi.org/10.1038/s41598-021-02731-z>>. Citado 2 vezes nas páginas 53 e 56.

DUDA, Richard O.; HART, Peter E.; STORK, David G. *Pattern Classification*. John Wiley & Sons, 2012. ISBN 9781118586006. Disponível em: <[https://www.ebook.de/de/product/21168060/richard\\_o\\_duda\\_peter\\_e\\_hart\\_david\\_g\\_stork\\_pattern\\_classification.html](https://www.ebook.de/de/product/21168060/richard_o_duda_peter_e_hart_david_g_stork_pattern_classification.html)>. Citado 3 vezes nas páginas 7, 42 e 44.

DUTTA, Pijush; PAUL, Shobhandeb; OBAID, Ahmed J.; PAL, Souvik; MUKHOPADHYAY, Koushik. Feature selection based artificial intelligence techniques for the prediction of COVID like diseases. *Journal of Physics: Conference Series*, IOP Publishing, v. 1963, n. 1, p. 012167, jul 2021. Disponível em: <<https://doi.org/10.1088/1742-6596/1963/1/012167>>. Citado 3 vezes nas páginas 51, 53 e 56.

EL-KENAWY, El-Sayed M.; IBRAHIM, Abdelhameed; MIRJALILI, Seyedali; EID, Marwa Metwally; HUSSEIN, Sherif E. Novel feature selection and voting classifier algorithms for covid-19 classification in ct images. *IEEE Access*, v. 8, p. 179317–179335, 2020. Citado 3 vezes nas páginas 51, 53 e 56.

EL-RASHIDY, Nora; ABDELRAZIK, Samir; ABUHMED, Tamer; AMER, Eslam; ALI, Farman; HU, Jong-Wan; EL-SAPPAGH, Shaker. Comprehensive survey of using machine learning in the covid-19 pandemic. *Diagnostics*, v. 11, n. 7, 2021. ISSN 2075-4418. Disponível em: <<https://www.mdpi.com/2075-4418/11/7/1155>>. Citado na página 24.

Hospital Israelita Albert Einstein. Diagnosis of covid-19 and its clinical spectrum - ai and data science supporting clinical decisions (from 28th mar to 3st apr). 2020. Disponível em: <<https://www.kaggle.com/datasets/einsteindata4u/covid19>>. Citado na página 51.

IWENDI, Celestine; BASHIR, Ali Kashif; PESHKAR, Atharva; SUJATHA, R.; CHATTERJEE, Jyotir Moy; PASUPULETI, Swetha; MISHRA, Rishita; PILLAI, Sofia; JO, Ohyun. Covid-19 patient health prediction using boosted random forest algorithm. *Frontiers in Public Health*, v. 8, 2020. ISSN 2296-2565. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpubh.2020.00357>>. Citado na página 51.

KANNALA, Juho; RAHTU, Esa. Bsf: Binarized statistical image features. In: *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*. [S.l.: s.n.], 2012. p. 1363–1366. Citado na página 60.

KHAN, Adil Mehmood; IRAJI, Mohammad Saber; FEIZI-DERAKHSHI, Mohammad-Reza; TANHA, Jafar. Covid-19 detection using deep convolutional neural networks and binary differential algorithm-based feature selection from x-ray images. *Complexity*, Hindawi, v. 2021, p. 9973277, 2021. ISSN 1076-2787. Disponível em: <<https://doi.org/10.1155/2021/9973277>>. Citado 3 vezes nas páginas 53, 54 e 56.

LI, Jundong; CHENG, Kewei; WANG, Suhang; MORSTATTER, Fred; TREVINO, Robert P.; TANG, Jiliang; LIU, Huan. Feature selection: A data perspective. *ACM Comput. Surv.*, Association for Computing Machinery, New York, NY, USA, v. 50, n. 6, dec 2017. ISSN 0360-0300. Disponível em: <<https://doi.org/10.1145/3136625>>. Citado 2 vezes nas páginas 27 e 28.

MARATEA, Antonio; PETROSINO, Alfredo; MANZO, Mario. Adjusted f-measure and kernel scaling for imbalanced data learning. *Information Sciences*, v. 257, p. 331–341, 2014. ISSN 0020-0255. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025513003137>>. Citado na página 45.

MATHEW, Tom V. Genetic algorithm. *Report submitted at IIT Bombay*, 2012. Citado na página 32.

MITCHELL, T.M. *Machine Learning*. McGraw-Hill, 1997. (McGraw-Hill International Editions). ISBN 9780071154673. Disponível em: <<https://books.google.com.br/books?id=EoYBngEACAAJ>>. Citado na página 40.

MOHAMMED, Bazhdar; AL-MUKHTAR, Firas; YOUSIF, Raghad; ALMASHHADANI, Yazen. Automatic classification of covid-19 chest x-ray images using local binary pattern and binary particle swarm optimization for feature selection. *Cihan University-Erbil Scientific Journal*, v. 5, n. 2, p. 46–51, Nov. 2021. Disponível em: <<https://journals.cihanuniversity.edu.iq/index.php/cuesj/article/view/388>>. Citado 4 vezes nas páginas 51, 53, 54 e 56.

MOLINA, L.C.; BELANCHE, L.; NEBOT, A. Feature selection algorithms: a survey and experimental evaluation. In: *2002 IEEE International Conference on Data Mining, 2002. Proceedings*. [S.l.: s.n.], 2002. p. 306–313. Citado 2 vezes nas páginas 28 e 31.

MOORE, Andrew. *An introductory tutorial on kd-trees, Technical Report No. 209, Computer Laboratory, University of Cambridge*. Pittsburgh, PA, 1991. Citado na página 41.

MOROZOV, S. P.; ANDREYCHENKO, A. E.; PAVLOV, N. A.; VLADZYMYRSKIYY, A. V.; LEDIKHOVA, N. V.; GOMBOLEVSKIY, V. A.; BLOKHIN, I. A.; GELEZHE, P. B.; GONCHAR, A. V.; CHERNINA, V. Yu. *MosMedData: Chest CT Scans With COVID-19 Related Findings Dataset*. arXiv, 2020. Disponível em: <<https://arxiv.org/abs/2005.06465>>. Citado na página 51.

MUSTAFA, Saira; ALI, Aatka; SALAHUDDIN, Humayun; CHAUDHRY, Muhammad Umar. Two-step feature selection for predicting mortality risk in covid-19 patients. In: *2021 International Conference on Computing, Electronic and Electrical Engineering (ICE Cube)*. [S.l.: s.n.], 2021. p. 1–5. Citado 3 vezes nas páginas 51, 53 e 56.

NANNI, Loris; LUMINI, Alessandra; BRAHNAM, Sheryl. Local binary patterns variants as texture descriptors for medical image analysis. *Artificial Intelligence in Medicine*, v. 49, n. 2, p. 117–125, 2010. ISSN 0933-3657. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0933365710000278>>. Citado na página 60.

NARIN, Ali. Accurate detection of covid-19 using deep features based on x-ray images and feature selection methods. *Computers in Biology and Medicine*, v. 137, p. 104771, 2021. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482521005655>>. Citado 4 vezes nas páginas 51, 53, 54 e 56.

NEWELL, Andrew J.; GRIFFIN, Lewis D. Writer identification using oriented basic image features and the delta encoding. *Pattern Recognition*, v. 47, n. 6, p. 2255–2265, 2014. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0031320313005153>>. Citado na página 61.

OJALA, Timo; PIETIKÄINEN, Matti; HARWOOD, David. A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, v. 29, n. 1, p. 51–59, 1996. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0031320395000674>>. Citado na página 60.

OJANSIVU, Ville; HEIKKILÄ, Janne. Blur insensitive texture classification using local phase quantization. In: ELMOATAZ, Abderrahim; LEZORAY, Olivier; NOUBOUD, Fathallah; MAMMASS, Driss (Ed.). *Image and Signal Processing*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 236–243. ISBN 978-3-540-69905-7. Citado na página 61.

OMOHUNDRO, Stephen M. *Five balltree construction algorithms, ICSI Technical Report TR-89-063*. [S.l.]: International Computer Science Institute Berkeley, 1989. Citado na página 41.

OZYURT, Fatih; TUNCER, Turker; SUBASI, Abdulhamit. An automated covid-19 detection based on fused dynamic exemplar pyramid feature extraction and hybrid feature selection using deep learning. *Computers in Biology and Medicine*, v. 132, p. 104356, 2021. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482521001505>>. Citado 2 vezes nas páginas 53 e 56.

PEREIRA, Rodolfo M.; BERTOLINI, Diego; TEIXEIRA, Lucas O.; SILLA, Carlos N.; COSTA, Yandre M.G. Covid-19 identification in chest x-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*, v. 194, p. 105532, 2020. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260720309664>>. Citado 27 vezes nas páginas 3, 5, 9, 11, 23, 24, 34, 35, 39, 40, 59, 60, 61, 62, 66, 69, 70, 71, 77, 78, 80, 81, 83, 84, 91, 92 e 143.

Phil Kim. *MATLAB Deep Learning*. Apress, 2017. ISBN 1484228448. Disponível em: <<https://link.springer.com/book/10.1007/978-1-4842-2845-6>>. Citado 2 vezes nas páginas 7 e 42.

REDDY, G. Thippa; NASIRI, Hamid; ALAVI, Seyed Ali. A novel framework based on deep learning and anova feature selection method for diagnosis of covid-19 cases from chest x-ray images. *Computational Intelligence and Neuroscience*, Hindawi, v. 2022, p. 4694567, 2022. ISSN 1687-5265. Disponível em: <<https://doi.org/10.1155/2022/4694567>>. Citado 4 vezes nas páginas 51, 53, 54 e 56.

RIVERA, Adin Ramirez; CASTILLO, Jorge Rojas; CHAE, Oksam Oksam. Local directional number pattern for face analysis: Face and expression recognition. *IEEE Transactions on Image Processing*, v. 22, n. 5, p. 1740–1752, 2013. Citado na página 61.

ROSS, Brian C. Mutual information between discrete and continuous data sets. *PLOS ONE*, Public Library of Science, v. 9, n. 2, p. 1–5, 02 2014. Disponível em: <<https://doi.org/10.1371/journal.pone.0087357>>. Citado na página 29.

ROSTAMI, Mehrdad; OUSSALAH, Mourad. A novel explainable covid-19 diagnosis method by integration of feature selection with random forest. *Informatics in Medicine Unlocked*, v. 30, p. 100941, 2022. ISSN 2352-9148. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352914822000892>>. Citado 2 vezes nas páginas 53 e 56.

SAGI, Omer; ROKACH, Lior. Ensemble learning: A survey. *WIREs Data Mining and Knowledge Discovery*, Wiley, v. 8, n. 4, feb 2018. Citado na página 43.

SCHWAB, Patrick; SCHÜTTE, August DuMont; DIETZ, Benedikt; BAUER, Stefan. *predCOVID-19: A Systematic Study of Clinical Predictive Models for Coronavirus Disease 2019*. arXiv, 2020. Disponível em: <<https://arxiv.org/abs/2005.08302v1>>. Citado na página 51.

SELLETI, André L. Jeller; SILLA, Carlos N. An analysis of feature selection techniques for covid-19 detection on chest x-ray data. In: *2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE)*. [S.l.: s.n.], 2021. p. 1–6. Citado na página 75.

SEN, Shibaprasad; SAHA, Soumyajit; CHATTERJEE, Somnath; MIRJALILI, Seyedali; SARKAR, Ram. A bi-stage feature selection approach for covid-19 prediction using chest ct images. *Applied Intelligence*, v. 51, n. 12, p. 8985–9000, 2021. ISSN 1573-7497. Disponível em: <<https://doi.org/10.1007/s10489-021-02292-8>>. Citado 2 vezes nas páginas 53 e 56.

SHABAN, Warda M.; RABIE, Asmaa H.; SALEH, Ahmed I.; ABO-ELSOUUD, M.A. A new covid-19 patients detection strategy (cpds) based on hybrid feature selection and enhanced knn classifier. *Knowledge-Based Systems*, v. 205, p. 106270, 2020. ISSN 0950-7051. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950705120304573>>. Citado na página 53.

SILLA, Carlos N.; FREITAS, Alex A. A survey of hierarchical classification across different application domains. *Data Mining and Knowledge Discovery*, v. 22, n. 1, p. 31–72, 2011. ISSN 1573-756X. Disponível em: <<https://doi.org/10.1007/s10618-010-0175-9>>. Citado 11 vezes nas páginas 7, 34, 35, 36, 37, 38, 39, 40, 63, 65 e 75.

SIVANANDAM, S.N.; DEEPA, S.N. Genetic algorithms. In: \_\_\_\_\_. *Introduction to Genetic Algorithms*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 15–37. ISBN 978-3-540-73190-0. Disponível em: <[https://doi.org/10.1007/978-3-540-73190-0\\_2](https://doi.org/10.1007/978-3-540-73190-0_2)>. Citado na página 32.

SOARES, Eduardo; ANGELOV, Plamen; BIASO, Sarah; FROES, Michele Higa; ABE, Daniel Kanda. Sars-cov-2 ct-scan dataset: A large dataset of real patients ct scans for sars-cov-2 identification. *medRxiv*, Cold Spring Harbor Laboratory Press, 2020. Disponível

em: <<https://www.medrxiv.org/content/early/2020/05/14/2020.04.24.20078584>>. Citado na página 51.

SOHRABI, Catrin; ALSAFI, Zaid; O'NEILL, Niamh; KHAN, Mehdi; KERWAN, Ahmed; AL-JABIR, Ahmed; IOSIFIDIS, Christos; AGHA, Riaz. World health organization declares global emergency: A review of the 2019 novel coronavirus (covid-19). *International Journal of Surgery*, v. 76, p. 71–76, 2020. ISSN 1743-9191. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1743919120301977>>. Citado na página 23.

SONG, Tiecheng; LI, Hongliang; MENG, Fanman; WU, Qingbo; CAI, Jianfei. Letrist: Locally encoded transform feature histogram for rotation-invariant texture classification. *IEEE Transactions on Circuits and Systems for Video Technology*, v. 28, n. 7, p. 1565–1579, 2018. Citado na página 61.

SOUI, Makram; MANSOURI, Nesrine; ALHAMAD, Raed; KESSENTINI, Marouane; GHEDIRA, Khaled. Nsga-ii as feature selection technique and adaboost classifier for covid-19 prediction using patient's symptoms. *Nonlinear Dynamics*, v. 106, n. 2, p. 1453–1475, 2021. ISSN 1573-269X. Disponível em: <<https://doi.org/10.1007/s11071-021-06504-1>>. Citado 4 vezes nas páginas 42, 43, 53 e 56.

STHLE, Lars; WOLD, Svante. Analysis of variance (anova). *Chemometrics and Intelligent Laboratory Systems*, v. 6, n. 4, p. 259–272, 1989. ISSN 0169-7439. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0169743989800954>>. Citado 2 vezes nas páginas 28 e 29.

SUN, Liang; MO, Zhanhao; YAN, Fuhua; XIA, Liming; SHAN, Fei; DING, Zhongxiang; SONG, Bin; GAO, Wanchun; SHAO, Wei; SHI, Feng; YUAN, Huan; JIANG, Huiting; WU, Dijia; WEI, Ying; GAO, Yaozong; SUI, He; ZHANG, Daoqiang; SHEN, Dinggang. Adaptive feature selection guided deep forest for covid-19 classification with chest ct. *IEEE Journal of Biomedical and Health Informatics*, v. 24, n. 10, p. 2798–2805, 2020. Citado 3 vezes nas páginas 51, 53 e 56.

SYED, Asif Hassan; KHAN, Tabrej; ALROMEMA, Nashwan. A hybrid feature selection approach to screen a novel set of blood biomarkers for early covid-19 mortality prediction. *Diagnostics*, v. 12, n. 7, 2022. ISSN 2075-4418. Disponível em: <<https://www.mdpi.com/2075-4418/12/7/1604>>. Citado 2 vezes nas páginas 53 e 56.

SZEGEDY, Christian; VANHOUCKE, Vincent; IOFFE, Sergey; SHLENS, Jon; WOJNA, Zbigniew. Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 2818–2826. Citado na página 60.

Tayarani N., Mohammad-H. Applications of artificial intelligence in battling against covid-19: A literature review. *Chaos, Solitons & Fractals*, v. 142, p. 110338, 2021. ISSN 0960-0779. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960077920307335>>. Citado na página 24.

TOO, Jingwei; MIRJALILI, Seyedali. A hyper learning binary dragonfly algorithm for feature selection: A covid-19 case study. *Knowledge-Based Systems*, v. 212, p. 106553, 2021. ISSN 0950-7051. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950705120306821>>. Citado 2 vezes nas páginas 24 e 31.

TOO, Jingwei; MIRJALILI, Seyedali. A hyper learning binary dragonfly algorithm for feature selection: A covid-19 case study. *Knowledge-Based Systems*, v. 212, p. 106553, 2021. ISSN 0950-7051. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950705120306821>>. Citado 2 vezes nas páginas 53 e 56.

VATEEKUL, Peerapon; KUBAT, Miroslav; SARINNAPAKORN, Kanoksri. Hierarchical multi-label classification with svms: A case study in gene function prediction. *Intelligent Data Analysis*, IOS Press, v. 18, n. 4, p. 717–738, 2014. ISSN 1571-4128. Citado 3 vezes nas páginas 45, 46 e 47.

Wolfram Research. Patient medical data for novel coronavirus covid-19. Wolfram Data Repository, 2020. Citado na página 51.

WU, Feihong; ZHANG, Jun; HONAVAR, Vasant. Learning classifiers using hierarchically structured class taxonomies. In: ZUCKER, Jean-Daniel; SAITTA, Lorenza (Ed.). *Abstraction, Reformulation and Approximation*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. p. 313–320. ISBN 978-3-540-31882-8. Citado na página 35.

XIA, Tian; SUN, Qibo; ZHOU, Ao; WANG, Shanguang; XIONG, Shilong; GAO, Siyi; LI, Jinglin; YUAN, Quan. Improving the performance of stock trend prediction by applying ga to feature selection. In: *2018 IEEE 8th International Symposium on Cloud and Service Computing (SC2)*. [S.l.: s.n.], 2018. p. 122–126. Citado na página 33.

YAN, Li; ZHANG, Hai-Tao; GONCALVES, Jorge; XIAO, Yang; WANG, Maolin; GUO, Yuqi; SUN, Chuan; TANG, Xiuchuan; JING, Liang; ZHANG, Mingyang; HUANG, Xiang; XIAO, Ying; CAO, Haosen; CHEN, Yanyan; REN, Tongxin; WANG, Fang; XIAO, Yaru; HUANG, Sufang; TAN, Xi; HUANG, Niannian; JIAO, Bo; CHENG, Cheng; ZHANG, Yong; LUO, Ailin; MOMBAERTS, Laurent; JIN, Junyang; CAO, Zhiguo; LI, Shusheng; XU, Hui; YUAN, Ye. An interpretable mortality prediction model for covid-19 patients. *Nature Machine Intelligence*, v. 2, n. 5, p. 283–288, 2020. ISSN 2522-5839. Disponível em: <<https://doi.org/10.1038/s42256-020-0180-7>>. Citado na página 51.

YANG, Xingyi; HE, Xuehai; ZHAO, Jinyu; ZHANG, Yichen; ZHANG, Shanghang; XIE, Pengtao. *COVID-CT-Dataset: A CT Scan Dataset about COVID-19*. arXiv, 2020. Disponível em: <<https://arxiv.org/abs/2003.13865v3>>. Citado na página 51.

ZOABI, Yazeed; DERI-ROZOV, Shira; SHOMRON, Noam. Machine learning-based prediction of covid-19 diagnosis based on symptoms. *npj Digital Medicine*, v. 4, n. 1, p. 3, 2021. ISSN 2398-6352. Disponível em: <<https://doi.org/10.1038/s41746-020-00372-6>>. Citado na página 51.



## APÊNDICE A – Número de Experimentos

Esta seção apresenta na Figura 32 como foi calculado o número total de experimentos realizados. Sendo em (a) os experimentos feitos no cenário plano e (b, c) no cenário hierárquico, compartilhando assim suas baselines (com todos os atributos). Finalizando em (d) a somatória destes valores já contando com sua multiplicação pelo número de extratores no trabalho, uma vez que cada uma das operações (a, b, c) foram realizadas de forma individual para cada um deles.

PORCENTAGEM ATRIBUTOS	100% / Baselines			90%		80%		70%		60%	
	MI	ANV	AG	MI	ANV	MI	ANV	MI	ANV	MI	ANV
MÉTODO DE SELEÇÃO	DT			DT	DT	DT	DT	DT	DT	DT	DT
CLASSIFICADORES / CLASSIFICAÇÕES	RF			RF	RF	RF	RF	RF	RF	RF	RF
	KNN 3			KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3
	KNN 5			KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5
	MLP			MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP
	SVM			SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM
SOMA	6			12		12		12		12	
PORCENTAGEM ATRIBUTOS	50%		40%		30%		20%		10%		OUTRAS %
	MI	ANV	MI	ANV	MI	ANV	MI	ANV	MI	ANV	AG
MÉTODO DE SELEÇÃO	DT	DT	DT	DT	DT	DT	DT	DT	DT	DT	DT
CLASSIFICADORES / CLASSIFICAÇÕES	RF	RF	RF	RF	RF	RF	RF	RF	RF	RF	RF
	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3
	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5
	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP
	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM
SOMA	12		12		12		12		12		6
PORCENTAGENS	11		6		12		12		12		120 EXPERIMENTOS PARA CADA EXTRATOR 120 * 8 = 960
CLASSIFICADORES	6		12		12		12		12		
MÉTODOS FS	3		12		6		SOMA 120				
EXTRADORES	8						PORCENTAGENS * CLASSIFICADORES * MÉTODOS FS				

(a) Total experimentos cenário Plano.

PORCENTAGEM ATRIBUTOS	100% / Baselines			90%		80%		70%		60%	
	MI	ANV	AG	MI	ANV	MI	ANV	MI	ANV	MI	ANV
MÉTODO DE SELEÇÃO	DT			DT	DT	DT	DT	DT	DT	DT	DT
CLASSIFICADORES / CLASSIFICAÇÕES	RF			RF	RF	RF	RF	RF	RF	RF	RF
	KNN 3			KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3
	KNN 5			KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5
	MLP			MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP
	SVM			SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM
SOMA	6			12		12		12		12	
PORCENTAGEM ATRIBUTOS	50%		40%		30%		20%		10%		OUTRAS %
	MI	ANV	MI	ANV	MI	ANV	MI	ANV	MI	ANV	AG
MÉTODO DE SELEÇÃO	DT	DT	DT	DT	DT	DT	DT	DT	DT	DT	DT
CLASSIFICADORES / CLASSIFICAÇÕES	RF	RF	RF	RF	RF	RF	RF	RF	RF	RF	RF
	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3
	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5
	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP
	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM
SOMA	12		12		12		12		12		6
PORCENTAGENS	11		6		12		12		12		120 EXPERIMENTOS PARA CADA EXTRATOR 120 * 8 = 960
CLASSIFICADORES	6		12		12		12		12		
MÉTODOS FS	3		12		6		SOMA 120				
EXTRADORES	8						PORCENTAGENS * CLASSIFICADORES * MÉTODOS FS				

(b) Total experimentos cenário H-Plano.

PORCENTAGEM ATRIBUTOS	100% / Baselines			90%		80%		70%		60%	
	MI	ANV	AG	MI	ANV	MI	ANV	MI	ANV	MI	ANV
MÉTODO DE SELEÇÃO	DT			DT	DT	DT	DT	DT	DT	DT	DT
CLASSIFICADORES / CLASSIFICAÇÕES	RF			RF	RF	RF	RF	RF	RF	RF	RF
	KNN 3			KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3
	KNN 5			KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5
	MLP			MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP
	SVM			SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM
SOMA	6			12		12		12		12	
PORCENTAGEM ATRIBUTOS	50%		40%		30%		20%		10%		OUTRAS %
	MI	ANV	MI	ANV	MI	ANV	MI	ANV	MI	ANV	AG
MÉTODO DE SELEÇÃO	DT	DT	DT	DT	DT	DT	DT	DT	DT	DT	DT
CLASSIFICADORES / CLASSIFICAÇÕES	RF	RF	RF	RF	RF	RF	RF	RF	RF	RF	RF
	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3	KNN 3
	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5	KNN 5
	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP	MLP
	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM	SVM
SOMA	12		12		12		12		12		6
PORCENTAGENS	11		0		12		12		12		114 EXPERIMENTOS PARA CADA EXTRATOR 120 * 8 = 912
CLASSIFICADORES	6		12		12		12		12		
MÉTODOS FS	3		12		6		SOMA 114				
EXTRADORES	8						PORCENTAGENS * CLASSIFICADORES * MÉTODOS FS				

(c) Total experimentos cenário H-Local.

Cenário Plano	960
Cenário H Plano	960
Cenário H Local	912
<b>TOTAL EXPERIMENTOS</b>	<b>2832</b>

(d) Somatória Experimentos

Figura 32 – Número de Experimentos

## APÊNDICE B – Metas de Baselines

Esta seção apresenta nas Tabelas 18 e 19 os baselines dos cenários covid e macro respectivamente. Estes baselines dizem respeito aos experimentos realizados neste artigo a partir da combinação de um Extrator (EXT) com um Classificador (CLF) sem a utilização qualquer seleção de atributos, ou seja, os experimentos usando todos (100%) os atributos de determinado extrator, tanto no cenário de classificação Plano quanto Hierárquico (H), estando destacado o melhor resultado de cada tabela/cenário.

Tabela 18 – Baseline - Todos os Atributos - Cenário Covid (Covid F1)

EXT	CLF	PLANO	H	EXT	CLF	PLANO	H
BSIF	DT	0,4706	0,4231	EQP	DT	0,6250	0,5957
	KNN 3	0,5128	0,5128		KNN 3	0,5333	0,5909
	KNN 5	0,4444	0,5263		KNN 5	0,5000	0,5238
	MLP	0,7857	0,5909		MLP	0,6552	0,6275
	RF	0,1739	0,3182		RF	0,5833	0,5417
	SVM	0,4211	0,6222		SVM	0,2424	0,4500
INCEPTION	DT	0,2456	0,2500	LBP	DT	0,5490	0,4706
	KNN 3	0,1667	0,1111		KNN 3	0,6000	0,5714
	KNN 5	0,1290	0,1212		KNN 5	0,6250	0,5833
	MLP	0,5000	0,5714		MLP	0,6923	0,6792
	RF	0,3200	0,3830		RF	0,5957	0,5000
	SVM	0,1818	0,3721		SVM	0,2424	0,2703
LDN	DT	0,6786	0,6984	LETRIST	DT	0,7308	0,7273
	KNN 3	0,6250	0,6250		KNN 3	0,6383	0,6222
	KNN 5	0,6250	0,6250		KNN 5	0,6222	0,6522
	MLP	0,0000	0,0000		MLP	0,1333	0,0000
	RF	0,2500	0,4103		RF	0,4211	0,6341
	SVM	0,7500	0,7368		SVM	0,7273	0,7368
LPQ	DT	0,6786	0,6349	OBIF	DT	0,7368	0,6792
	KNN 3	0,6222	0,5714		KNN 3	0,5581	0,4615
	KNN 5	0,4615	0,4878		KNN 5	0,4103	0,4103
	MLP	0,8475	0,7931		MLP	0,0000	0,0000
	RF	0,2857	0,5200		RF	0,1905	0,2424
	SVM	0,7143	0,7667		SVM	0,7037	0,7143

Tabela 19 – Baseline - Todos os Atributos - Cenário Macro (Macro Avg)

EXT	CLF	PLANO	H	EXT	CLF	PLANO	H
BSIF	DT	0,2333	0,3050	EQP	DT	0,2286	0,2968
	KNN 3	0,3059	0,3063		KNN 3	0,3282	0,3347
	KNN 5	0,2818	0,3073		KNN 5	0,2800	0,2838
	MLP	0,3251	0,4471		MLP	0,2817	0,3424
	RF	0,3510	0,3630		RF	0,3524	0,2920
	SVM	0,1960	0,2263		SVM	0,1694	0,2006
INCEPTION	DT	0,1677	0,2252	LBP	DT	0,2813	0,2047
	KNN 3	0,2297	0,2218		KNN 3	0,2244	0,2203
	KNN 5	0,1523	0,1516		KNN 5	0,2275	0,2218
	MLP	0,2887	0,4039		MLP	0,3439	0,3498
	RF	0,2362	0,1913		RF	0,3897	0,3690
	SVM	0,1607	0,1896		SVM	0,1694	0,1742
LDN	DT	0,3879	0,2407	LETRIST	DT	0,3737	0,3018
	KNN 3	0,3248	0,3248		KNN 3	0,3947	0,4496
	KNN 5	0,3248	0,3248		KNN 5	0,3820	0,3761
	MLP	0,1335	0,1344		MLP	0,0221	0,1309
	RF	0,3486	0,2671		RF	0,3650	0,3717
	SVM	0,2470	0,2453		SVM	0,2437	0,2453
LPQ	DT	0,2370	0,2720	OBIF	DT	0,3529	0,2371
	KNN 3	0,4217	0,4859		KNN 3	0,3420	0,3010
	KNN 5	0,3821	0,3867		KNN 5	0,3054	0,2934
	MLP	0,4063	0,3915		MLP	0,0026	0,1335
	RF	0,2969	0,3576		RF	0,2912	0,2289
	SVM	0,2419	0,2503		SVM	0,2399	0,2419

# APÊNDICE C – Resultados com Seleção Filter

Esta seção apresenta todos os resultados obtidos durante a pesquisa para os métodos de seleção Filter. Para fins de organização, estes resultados encontram-se divididos entre os cenários de classificação Plano, H-Plano e H-Local presentes respectivamente nas Seções C.1, C.2 e C.3. Neles, os resultados dos baselines foram replicados em cada uma das tabelas para facilitar a comparação, visualização e análise. Contendo em destacado amarelo o melhor resultado presente na tabela, estando marcado em caso de empate o resultado com menor seleção e em caso de o baseline ser o melhor resultado obtido, o segundo melhor (usando seleção) também se encontra destacado.

## C.1 (Plano) Classificação Plana com Seleção Plana

Esta seção apresenta os resultados de todas as classificações feitas, para todos os extratores utilizados durante a pesquisa, no cenário de Classificação Plano utilizando Seleção Plana. Sendo os extratores: BSIF, EQP, INCEPTION, LBP, LDN, LETRIST, LPQ E OBIF, seus resultados se encontram respectivamente nas subseções C.1.1, C.1.2, C.1.3, C.1.4, C.1.5, C.1.6, C.1.7 e C.1.8.

### C.1.1 Resultados Extrator BSIF

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 20) e o cenário Macro (Tabela 21).

Tabela 20 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator BSIF

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,4706	0,4706	0,4706	0,4706	0,4706	0,4667	0,4516	0,5385	0,7541	0,4364
	MI	0,4706	0,4912	0,4912	0,4667	0,4912	0,5000	0,4082	0,4615	0,4151	0,4906
KNN 3	ANV	0,5128	0,5000	0,4211	0,4324	0,4737	0,5641	0,4737	0,5581	0,6512	0,5778
	MI	0,5128	0,5000	0,4615	0,4324	0,4324	0,4324	0,4324	0,4615	0,4390	0,5306
KNN 5	ANV	0,4444	0,4000	0,4000	0,4000	0,4444	0,4444	0,4444	0,5500	0,6000	0,5500
	MI	0,4444	0,4324	0,4865	0,4865	0,4000	0,4000	0,3529	0,4211	0,4878	0,4878
MLP	ANV	0,7857	0,7619	0,6923	0,7541	0,7119	0,6909	0,5714	0,5957	0,4615	0,0000
	MI	0,7857	0,7419	0,7667	0,7419	0,6667	0,5926	0,5217	0,5490	0,6038	0,5000
RF	ANV	0,1739	0,3556	0,2791	0,2162	0,3265	0,3556	0,2791	0,3111	0,3256	0,1081
	MI	0,1739	0,3415	0,2326	0,3810	0,3556	0,2326	0,3830	0,2667	0,1739	0,2051
SVM	ANV	0,4211	0,3784	0,3333	0,3333	0,3784	0,4103	0,2857	0,3333	0,4324	0,6087
	MI	0,4211	0,4211	0,4211	0,3784	0,3333	0,2857	0,2857	0,3333	0,3243	0,2778

Tabela 21 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator BSIF

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2333	0,2333	0,2333	0,2333	0,2333	0,2319	0,2000	0,2149	0,2478	0,2279
	MI	0,2333	0,2362	0,2362	0,2319	0,2362	0,2377	0,1942	0,2012	0,1943	0,2074
KNN 3	ANV	0,3059	0,3042	0,2923	0,2937	0,3001	0,3136	0,2998	0,3395	0,3535	0,3342
	MI	0,3059	0,3042	0,2985	0,2939	0,2937	0,2937	0,2937	0,2022	0,1985	0,2124
KNN 5	ANV	0,2818	0,2753	0,2750	0,2750	0,2816	0,2820	0,2954	0,3114	0,3183	0,2976
	MI	0,2818	0,2799	0,2878	0,2878	0,2750	0,2748	0,2679	0,1962	0,2068	0,2780
MLP	ANV	0,3251	0,2491	0,4299	0,2482	0,2422	0,2385	0,3913	0,3186	0,2502	0,1335
	MI	0,3251	0,2467	0,3727	0,2467	0,2763	0,2222	0,2128	0,2174	0,2245	0,2088
RF	ANV	0,3510	0,3648	0,3744	0,3777	0,3514	0,3311	0,3068	0,2932	0,3181	0,2817
	MI	0,3510	0,3848	0,3202	0,3661	0,3097	0,3232	0,3309	0,3409	0,2342	0,3111
SVM	ANV	0,1960	0,1897	0,1830	0,1830	0,1897	0,1947	0,1760	0,1830	0,2690	0,2245
	MI	0,1960	0,1960	0,1960	0,1897	0,1830	0,1760	0,1760	0,1830	0,1820	0,1751

### C.1.2 Resultados Extrator EQP

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 22) e o cenário Macro (Tabela 23).

Tabela 22 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator EQP

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,6250	0,6129	0,5763	0,5000	0,5763	0,5763	0,5763	0,6296	0,5862	0,6538
	MI	0,6250	0,6250	0,6250	0,6250	0,6250	0,6250	0,6250	0,6250	0,6250	0,6333
KNN 3	ANV	0,5333	0,5333	0,5333	0,5116	0,5116	0,5217	0,6250	0,6415	0,6000	0,6383
	MI	0,5333	0,5455	0,5455	0,5778	0,6939	0,6250	0,7083	0,7600	0,6122	0,6415
KNN 5	ANV	0,5000	0,5000	0,5000	0,4878	0,4878	0,5116	0,5000	0,5455	0,6364	0,6364
	MI	0,5000	0,5581	0,5238	0,4878	0,5581	0,5532	0,7111	0,6047	0,6222	0,5833
MLP	ANV	0,6552	0,6071	0,7037	0,5965	0,6071	0,7037	0,6552	0,6333	0,6545	0,2424
	MI	0,6552	0,6000	0,6667	0,6786	0,6780	0,6538	0,5660	0,5957	0,3590	0,0000
RF	ANV	0,5833	0,6250	0,6275	0,5490	0,5385	0,5778	0,5957	0,6122	0,5818	0,5769
	MI	0,5833	0,6087	0,6222	0,5957	0,5091	0,6667	0,5957	0,5600	0,5455	0,6154
SVM	ANV	0,2424	0,2424	0,2941	0,2424	0,2941	0,4444	0,3529	0,3030	0,3429	0,3784
	MI	0,2424	0,1935	0,1935	0,1935	0,1935	0,1935	0,3529	0,4000	0,4000	0,6364

Tabela 23 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator EQP

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2286	0,2269	0,2210	0,2099	0,2210	0,2210	0,2210	0,2277	0,2205	0,2309
	MI	0,2286	0,2286	0,2286	0,2286	0,2286	0,2286	0,2286	0,2286	0,2286	0,2296
KNN 3	ANV	0,3282	0,3282	0,3282	0,4107	0,4107	0,3071	0,2271	0,3008	0,2945	0,2766
	MI	0,3282	0,2729	0,2726	0,2772	0,2378	0,2987	0,3108	0,3046	0,3218	0,3448
KNN 5	ANV	0,2800	0,2800	0,2657	0,2785	0,2785	0,2814	0,2086	0,2150	0,2999	0,2999
	MI	0,2800	0,2747	0,2696	0,2642	0,2747	0,2168	0,3110	0,2809	0,2990	0,3356
MLP	ANV	0,2817	0,2266	0,2882	0,2255	0,2744	0,3295	0,2336	0,2310	0,2814	0,1694
	MI	0,2817	0,2666	0,2351	0,2368	0,2369	0,2809	0,2195	0,2238	0,2170	0,1335
RF	ANV	0,3524	0,4248	0,3745	0,2586	0,3906	0,4065	0,3348	0,3535	0,3741	0,3145
	MI	0,3524	0,4100	0,3710	0,4092	0,2822	0,3268	0,2813	0,3609	0,2902	0,3842
SVM	ANV	0,1694	0,1694	0,1770	0,1694	0,1770	0,1989	0,1854	0,1781	0,1842	0,1897
	MI	0,1694	0,1620	0,1620	0,1620	0,1620	0,1620	0,1854	0,1923	0,1923	0,2281

### C.1.3 Resultados Extrator INCEPTION

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 24) e o cenário Macro (Tabela 25).

Tabela 24 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator INCEPTION

% de Classificador	Atributos -> Ranqueador	100% 2048	90% 1843	80% 1638	70% 1434	60% 1229	50% 1024	40% 819	30% 614	20% 410	10% 205
DT	ANV	0,2456	0,2593	0,2593	0,2593	0,2593	0,1509	0,1509	0,1509	0,1481	0,1429
	MI	0,2456	0,2593	0,2456	0,2456	0,2456	0,2456	0,2456	0,2069	0,2069	0,0816
KNN 3	ANV	0,1667	0,2051	0,1111	0,1538	0,2051	0,2105	0,2632	0,2857	0,3684	0,3810
	MI	0,1667	0,1143	0,2162	0,2105	0,2051	0,2105	0,2105	0,2778	0,3158	0,3721
KNN 5	ANV	0,1290	0,1250	0,1290	0,1875	0,1250	0,1714	0,1875	0,3030	0,4211	0,2857
	MI	0,1290	0,1333	0,1290	0,1290	0,1290	0,1212	0,1875	0,2500	0,1875	0,3684
MLP	ANV	0,5000	0,4444	0,4615	0,4815	0,4400	0,4444	0,5517	0,5574	0,5614	0,6182
	MI	0,5000	0,5091	0,4681	0,4444	0,5106	0,5357	0,4314	0,4490	0,4783	0,4490
RF	ANV	0,3200	0,3265	0,1702	0,4000	0,3830	0,3846	0,3265	0,4000	0,3043	0,4364
	MI	0,3200	0,2609	0,3556	0,3830	0,1905	0,1860	0,1905	0,3448	0,3529	0,3448
SVM	ANV	0,1818	0,1818	0,2353	0,2286	0,2778	0,3243	0,2778	0,3590	0,3590	0,3415
	MI	0,1818	0,1818	0,2353	0,2857	0,2778	0,3243	0,3243	0,3243	0,3158	0,3158

Tabela 25 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator INCEPTION

% de Classificador	Atributos -> Ranqueador	100% 2048	90% 1843	80% 1638	70% 1434	60% 1229	50% 1024	40% 819	30% 614	20% 410	10% 205
DT	ANV	0,1677	0,1699	0,1704	0,1704	0,1704	0,1538	0,1538	0,1538	0,1531	0,1518
	MI	0,1677	0,1704	0,1677	0,1677	0,1677	0,1677	0,1677	0,1614	0,1614	0,1435
KNN 3	ANV	0,2297	0,2356	0,2215	0,2283	0,2354	0,2368	0,2441	0,2474	0,2599	0,1900
	MI	0,2297	0,2224	0,2372	0,2362	0,2356	0,2364	0,2361	0,2460	0,2523	0,2608
KNN 5	ANV	0,1523	0,1520	0,1523	0,1609	0,1522	0,2304	0,1613	0,1782	0,1964	0,1764
	MI	0,1523	0,1532	0,1528	0,1528	0,1530	0,2233	0,2325	0,1702	0,2185	0,2454
MLP	ANV	0,2887	0,3227	0,2503	0,3532	0,4219	0,2475	0,2729	0,3682	0,4224	0,3769
	MI	0,2887	0,2480	0,4089	0,2911	0,4108	0,3990	0,3386	0,3246	0,2879	0,2563
RF	ANV	0,2362	0,2943	0,1570	0,1910	0,1887	0,1884	0,1806	0,1920	0,2832	0,3016
	MI	0,2362	0,2287	0,1853	0,1890	0,2552	0,1590	0,2025	0,2527	0,2072	0,2174
SVM	ANV	0,1607	0,1607	0,1686	0,1674	0,1746	0,1815	0,1746	0,1869	0,1869	0,1848
	MI	0,1607	0,1607	0,1686	0,1760	0,1746	0,1815	0,1815	0,1815	0,1805	0,1805



### C.1.4 Resultados Extrator LBP

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 26) e o cenário Macro (Tabela 27).

Tabela 26 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LBP

% de Classificador	Atributos -> Ranqueador	100% 59	90% 53	80% 47	70% 41	60% 35	50% 30	40% 24	30% 18	20% 12	10% 6
DT	ANV	0,5490	0,5490	0,5490	0,5385	0,5306	0,6296	0,5957	0,5417	0,5455	0,4528
	MI	0,5490	0,5490	0,5098	0,5098	0,5000	0,5000	0,5306	0,4545	0,4255	0,4545
KNN 3	ANV	0,6000	0,6000	0,5833	0,5833	0,6250	0,6122	0,5455	0,5581	0,5581	0,4186
	MI	0,6000	0,5333	0,5455	0,5333	0,5333	0,6087	0,6383	0,6383	0,4545	0,5455
KNN 5	ANV	0,6250	0,5833	0,5532	0,5532	0,5532	0,6250	0,5581	0,5909	0,5909	0,4286
	MI	0,6250	0,5652	0,5778	0,5652	0,5333	0,5652	0,6087	0,5909	0,4286	0,4103
MLP	ANV	0,6923	0,6984	0,6452	0,6939	0,6786	0,6429	0,6383	0,5532	0,4878	0,2778
	MI	0,6923	0,6552	0,6250	0,6800	0,6538	0,6939	0,6154	0,5926	0,4186	0,2500
RF	ANV	0,5957	0,4545	0,6122	0,5385	0,5106	0,5385	0,4314	0,4545	0,3922	0,3415
	MI	0,5957	0,5185	0,6122	0,6047	0,5532	0,6038	0,6087	0,5000	0,5769	0,5200
SVM	ANV	0,2424	0,2424	0,2424	0,2424	0,2424	0,3030	0,3030	0,3030	0,3030	0,5532
	MI	0,2424	0,1875	0,2424	0,1875	0,2424	0,2424	0,3030	0,3030	0,6538	0,4615

Tabela 27 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LBP

% de Classificador	Atributos -> Ranqueador	100% 59	90% 53	80% 47	70% 41	60% 35	50% 30	40% 24	30% 18	20% 12	10% 6
DT	ANV	0,2813	0,2813	0,2813	0,2795	0,2789	0,3150	0,3097	0,2147	0,2159	0,2011
	MI	0,2813	0,2813	0,2750	0,2750	0,2733	0,2731	0,2779	0,2669	0,1976	0,2884
KNN 3	ANV	0,2244	0,2244	0,2935	0,2935	0,2994	0,2974	0,2148	0,2167	0,2167	0,1967
	MI	0,2244	0,2147	0,3144	0,2555	0,2555	0,3211	0,2292	0,2294	0,2501	0,2150
KNN 5	ANV	0,2275	0,2214	0,2168	0,2168	0,2168	0,2990	0,2167	0,2216	0,2216	0,1981
	MI	0,2275	0,2183	0,2199	0,2183	0,2138	0,2188	0,2248	0,2218	0,1988	0,2663
MLP	ANV	0,3439	0,2407	0,3524	0,3823	0,3091	0,2800	0,2768	0,2166	0,2544	0,1751
	MI	0,3439	0,2829	0,4772	0,4041	0,3736	0,4442	0,2268	0,2231	0,1965	0,1707
RF	ANV	0,3897	0,4509	0,3777	0,3669	0,3648	0,3074	0,3120	0,2751	0,2488	0,3034
	MI	0,3897	0,2825	0,4391	0,3387	0,3661	0,4451	0,3785	0,3217	0,3057	0,2270
SVM	ANV	0,1694	0,1694	0,1694	0,1694	0,1694	0,1781	0,1781	0,1781	0,1781	0,2168
	MI	0,1694	0,1613	0,1694	0,1613	0,1694	0,1694	0,1781	0,1781	0,2323	0,2020

### C.1.5 Resultados Extrator LDN

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 28) e o cenário Macro (Tabela 29).

Tabela 28 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LDN

% de Classificador	Atributos -> Ranqueador	100% 56	90% 50	80% 45	70% 39	60% 34	50% 28	40% 22	30% 17	20% 11	10% 6
DT	ANV	0,6786	0,6531	0,6792	0,6792	0,7018	0,6897	0,6780	0,6207	0,7170	0,7333
	MI	0,6786	0,6531	0,6792	0,6792	0,6780	0,7018	0,7018	0,7018	0,7018	0,6667
KNN 3	ANV	0,6250	0,6250	0,6250	0,6250	0,6250	0,6122	0,6531	0,6667	0,6667	0,6792
	MI	0,6250	0,6250	0,6383	0,6383	0,6383	0,6383	0,6383	0,7037	0,6538	0,5833
KNN 5	ANV	0,6250	0,6250	0,6250	0,6250	0,6250	0,6400	0,6400	0,7059	0,6383	0,6923
	MI	0,6250	0,6250	0,6809	0,6809	0,6383	0,5957	0,6250	0,6275	0,5532	0,5600
MLP	ANV	0,0000	0,0000	0,1463	0,0000	0,0714	0,0000	0,0000	0,0000	0,0645	0,0000
	MI	0,0000	0,0000	0,1463	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
RF	ANV	0,2500	0,0000	0,2424	0,2581	0,1333	0,1818	0,2941	0,1212	0,1875	0,1212
	MI	0,2500	0,0714	0,3889	0,1935	0,0690	0,1935	0,0690	0,0645	0,0606	0,0690
SVM	ANV	0,7500	0,7500	0,7500	0,7500	0,7500	0,7500	0,7273	0,7037	0,7037	0,7037
	MI	0,7500	0,7500	0,7500	0,7500	0,7500	0,7500	0,7500	0,7368	0,7368	0,7143

Tabela 29 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LDN

% de Classificador	Atributos -> Ranqueador	100% 56	90% 50	80% 45	70% 39	60% 34	50% 28	40% 22	30% 17	20% 11	10% 6
DT	ANV	0,3879	0,3665	0,3092	0,3092	0,2408	0,2393	0,2364	0,2987	0,3204	0,2450
	MI	0,3879	0,3665	0,3092	0,3092	0,2374	0,2408	0,2408	0,2408	0,2408	0,2355
KNN 3	ANV	0,3248	0,3248	0,3248	0,3248	0,3248	0,3232	0,3288	0,3308	0,3308	0,3328
	MI	0,3248	0,3248	0,3269	0,3269	0,3269	0,3269	0,3269	0,3227	0,3156	0,2948
KNN 5	ANV	0,3248	0,3248	0,3248	0,3248	0,3248	0,3272	0,3272	0,3485	0,3386	0,3347
	MI	0,3248	0,3248	0,3328	0,3328	0,3269	0,3209	0,3250	0,3116	0,3012	0,2201
MLP	ANV	0,1335	0,0025	0,0209	0,0025	0,0110	0,0025	0,2160	0,0025	0,1431	0,1335
	MI	0,1335	0,0025	0,0209	0,0025	0,1343	0,0025	0,0025	0,1335	0,1335	0,1339
RF	ANV	0,3486	0,2662	0,3479	0,2867	0,2663	0,2369	0,3103	0,2553	0,3204	0,2536
	MI	0,3486	0,2635	0,3290	0,2752	0,2926	0,3172	0,1734	0,2309	0,2124	0,2236
SVM	ANV	0,2470	0,2470	0,2470	0,2470	0,2470	0,2470	0,2437	0,2404	0,2404	0,2404
	MI	0,2470	0,2470	0,2470	0,2470	0,2470	0,2470	0,2470	0,2453	0,2453	0,2419

### C.1.6 Resultados Extrator LETRIST

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 30) e o cenário Macro (Tabela 31).

Tabela 30 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LETRIST

% de Classificador	Atributos -> Ranqueador	100% 413	90% 372	80% 330	70% 289	60% 248	50% 206	40% 165	30% 124	20% 83	10% 41
DT	ANV	0,7308	0,6531	0,6923	0,7241	0,7241	0,7241	0,7119	0,7119	0,7667	0,7037
	MI	0,7308	0,7308	0,8214	0,6538	0,8421	0,7273	0,6909	0,6429	0,7018	0,6154
KNN 3	ANV	0,6383	0,6383	0,6383	0,7083	0,7083	0,7083	0,7083	0,6809	0,6667	0,6400
	MI	0,6383	0,6383	0,6383	0,6383	0,6383	0,6809	0,6809	0,6809	0,6364	0,7600
KNN 5	ANV	0,6222	0,6222	0,6222	0,6522	0,6522	0,6522	0,6364	0,6047	0,7273	0,6250
	MI	0,6222	0,6222	0,6222	0,6222	0,6222	0,6222	0,6222	0,6222	0,6047	0,7600
MLP	ANV	0,1333	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
	MI	0,1333	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
RF	ANV	0,4211	0,3784	0,5263	0,3590	0,3529	0,3429	0,5405	0,2286	0,4865	0,4186
	MI	0,4211	0,3529	0,2564	0,3030	0,2500	0,2500	0,1935	0,0690	0,0000	0,0690
SVM	ANV	0,7273	0,7273	0,7273	0,7407	0,7407	0,7273	0,7273	0,7170	0,7600	0,6538
	MI	0,7273	0,7273	0,7273	0,7407	0,7407	0,7273	0,7407	0,7273	0,7273	0,7037

Tabela 31 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LETRIST

% de Classificador	Atributos -> Ranqueador	100% 413	90% 372	80% 330	70% 289	60% 248	50% 206	40% 165	30% 124	20% 83	10% 41
DT	ANV	0,3737	0,3386	0,2966	0,3585	0,2440	0,2440	0,2424	0,2427	0,2505	0,2406
	MI	0,3737	0,3737	0,3300	0,2974	0,3687	0,3403	0,3347	0,2319	0,2405	0,2277
KNN 3	ANV	0,3947	0,3947	0,3947	0,4181	0,4181	0,4181	0,4181	0,3904	0,4124	0,3131
	MI	0,3947	0,3947	0,3947	0,3947	0,3947	0,4142	0,4142	0,4142	0,3838	0,4441
KNN 5	ANV	0,3820	0,3820	0,3820	0,3863	0,3863	0,3863	0,3838	0,3713	0,4461	0,3520
	MI	0,3820	0,3820	0,3820	0,3820	0,3820	0,3820	0,3820	0,3820	0,3713	0,4010
MLP	ANV	0,0221	0,0025	0,0197	0,0025	0,0085	0,0017	0,0028	0,0025	0,1225	0,0025
	MI	0,0221	0,0025	0,0026	0,0060	0,0025	0,0008	0,0027	0,0025	0,1335	0,0025
RF	ANV	0,3650	0,3141	0,4722	0,3141	0,3338	0,3636	0,4068	0,3103	0,3536	0,3058
	MI	0,3650	0,3572	0,2743	0,3209	0,3321	0,3263	0,3010	0,3147	0,3534	0,2861
SVM	ANV	0,2437	0,2437	0,2437	0,3028	0,3028	0,2437	0,2437	0,2416	0,3187	0,2330
	MI	0,2437	0,2437	0,2437	0,3028	0,3028	0,2437	0,3028	0,2437	0,2435	0,2399

### C.1.7 Resultados Extrator LPQ

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 32) e o cenário Macro (Tabela 33).

Tabela 32 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LPQ

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,6786	0,6786	0,6296	0,6296	0,6296	0,7241	0,7119	0,7119	0,7273	0,6122
	MI	0,6786	0,6786	0,6182	0,6296	0,6296	0,6296	0,7119	0,7458	0,5306	0,5714
KNN 3	ANV	0,6222	0,6522	0,6222	0,6667	0,6667	0,6222	0,6667	0,6047	0,6667	0,5641
	MI	0,6222	0,5909	0,6809	0,6222	0,7234	0,7234	0,6522	0,6364	0,5714	0,5778
KNN 5	ANV	0,4615	0,5366	0,5714	0,6047	0,5909	0,6222	0,6047	0,6818	0,6047	0,5641
	MI	0,4615	0,5500	0,5366	0,5714	0,6047	0,6512	0,6190	0,6667	0,5238	0,5714
MLP	ANV	0,8475	0,8136	0,8000	0,7941	0,8302	0,8197	0,7826	0,8000	0,8421	0,6341
	MI	0,8475	0,8065	0,8065	0,8060	0,8060	0,8148	0,8276	0,0000	0,0000	0,0000
RF	ANV	0,2857	0,3529	0,3721	0,5357	0,2564	0,2727	0,2979	0,3636	0,1667	0,1860
	MI	0,2857	0,4186	0,3902	0,2791	0,4783	0,4074	0,3556	0,1667	0,4651	0,2174
SVM	ANV	0,7143	0,7143	0,7143	0,7143	0,7037	0,7143	0,7368	0,7719	0,7451	0,7660
	MI	0,7143	0,7143	0,7143	0,6909	0,6909	0,7273	0,7407	0,7059	0,7059	0,7083

Tabela 33 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LPQ

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2370	0,2374	0,2710	0,2710	0,2710	0,2845	0,2830	0,2830	0,2848	0,2733
	MI	0,2370	0,2374	0,2634	0,2710	0,2710	0,2710	0,2830	0,2883	0,2500	0,2777
KNN 3	ANV	0,4217	0,4262	0,4219	0,4142	0,4147	0,3928	0,4283	0,3890	0,4142	0,3733
	MI	0,4217	0,4172	0,4305	0,4076	0,4368	0,4366	0,4264	0,4086	0,2784	0,3171
KNN 5	ANV	0,3821	0,3935	0,4138	0,3896	0,3878	0,4071	0,4192	0,4304	0,4190	0,3406
	MI	0,3821	0,3952	0,3935	0,3989	0,4039	0,4256	0,4057	0,4278	0,3117	0,3187
MLP	ANV	0,4063	0,3706	0,3791	0,2561	0,3451	0,2588	0,2542	0,2546	0,2604	0,3504
	MI	0,4063	0,2564	0,3647	0,2575	0,2575	0,4143	0,2587	0,1335	0,1335	0,1335
RF	ANV	0,2969	0,3321	0,3355	0,4069	0,3307	0,3755	0,3015	0,3384	0,2693	0,2528
	MI	0,2969	0,4381	0,3956	0,3150	0,4751	0,3539	0,4109	0,2797	0,3563	0,3243
SVM	ANV	0,2419	0,2419	0,2419	0,2419	0,2399	0,2419	0,2453	0,2503	0,2451	0,3189
	MI	0,2419	0,2419	0,2419	0,2383	0,2383	0,2435	0,2452	0,2395	0,2395	0,2392

### C.1.8 Resultados Extrator OBIF

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 34) e o cenário Macro (Tabela 35).

Tabela 34 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator OBIF

% de Classificador	Atributos -> Ranqueador	100% 484	90% 436	80% 387	70% 339	60% 290	50% 242	40% 194	30% 145	20% 97	10% 48
DT	ANV	0,7368	0,7368	0,6667	0,6923	0,6792	0,6792	0,6792	0,6296	0,6909	0,6531
	MI	0,7368	0,7241	0,7241	0,7059	0,7458	0,7368	0,6538	0,6296	0,6296	0,7241
KNN 3	ANV	0,5581	0,5455	0,5778	0,5778	0,6087	0,6250	0,6087	0,6383	0,5532	0,7170
	MI	0,5581	0,5581	0,5957	0,5957	0,5455	0,5333	0,5455	0,6250	0,6250	0,5455
KNN 5	ANV	0,4103	0,5714	0,6047	0,6047	0,5909	0,6087	0,6383	0,5957	0,5957	0,6400
	MI	0,4103	0,4103	0,5000	0,5366	0,6047	0,6047	0,5909	0,6087	0,5333	0,5652
MLP	ANV	0,0000	0,0000	0,1270	0,0000	0,1173	0,0000	0,0000	0,1463	0,0000	0,0000
	MI	0,0000	0,0000	0,0000	0,0714	0,0000	0,0000	0,0000	0,1333	0,0000	0,0000
RF	ANV	0,1905	0,1765	0,3784	0,1765	0,1875	0,1176	0,1622	0,1250	0,1538	0,0000
	MI	0,1905	0,1905	0,0000	0,0690	0,2727	0,2353	0,1935	0,2564	0,1875	0,1765
SVM	ANV	0,7037	0,6792	0,7500	0,7500	0,7500	0,7500	0,7500	0,7273	0,7273	0,7547
	MI	0,7037	0,7037	0,7037	0,7037	0,6792	0,6792	0,6792	0,7500	0,7273	0,6792

Tabela 35 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator OBIF

% de Classificador	Atributos -> Ranqueador	100% 484	90% 436	80% 387	70% 339	60% 290	50% 242	40% 194	30% 145	20% 97	10% 48
DT	ANV	0,3529	0,3274	0,3419	0,3456	0,3437	0,3437	0,3437	0,2703	0,2798	0,2340
	MI	0,3529	0,3256	0,3256	0,3366	0,3289	0,3412	0,3282	0,2703	0,2703	0,2845
KNN 3	ANV	0,3420	0,3130	0,3178	0,3178	0,2746	0,2770	0,3463	0,2789	0,3009	0,4567
	MI	0,3420	0,3420	0,3204	0,3204	0,3130	0,2732	0,3128	0,2770	0,2770	0,2812
KNN 5	ANV	0,3054	0,3439	0,3489	0,3489	0,2721	0,2746	0,2789	0,2728	0,3068	0,3455
	MI	0,3054	0,3054	0,3184	0,3236	0,3487	0,3487	0,3462	0,2746	0,2636	0,2614
MLP	ANV	0,0026	0,0009	0,1437	0,1335	0,0215	0,0025	0,0025	0,0209	0,1335	0,1335
	MI	0,0026	0,0025	0,0025	0,1420	0,0025	0,1337	0,0311	0,0190	0,0025	0,1335
RF	ANV	0,2912	0,3012	0,2725	0,2985	0,2705	0,3397	0,3326	0,2805	0,3034	0,2822
	MI	0,2912	0,2641	0,2816	0,2761	0,2646	0,2882	0,2775	0,2353	0,2820	0,2641
SVM	ANV	0,2399	0,2362	0,2470	0,2470	0,2470	0,2470	0,2470	0,2435	0,2435	0,2470
	MI	0,2399	0,2399	0,2399	0,2399	0,2362	0,2362	0,2362	0,2470	0,2435	0,2369

## C.2 (H-Plano) Classificação Hierárquica com Seleção Plana

Esta seção apresenta os resultados de todas as classificações feitas, para todos os extratores utilizados durante a pesquisa, no cenário de Classificação Plano utilizando Seleção Plana. Sendo os extratores: BSIF, EQP, INCEPTION, LBP, LDN, LETRIST, LPQ E OBIF, seus resultados se encontram respectivamente nas subseções C.2.1, C.2.2, C.2.3, C.2.4, C.2.5, C.2.6, C.2.7 e C.2.8.

### C.2.1 Resultados Extrator BSIF

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 36) e o cenário Macro (Tabela 37).

Tabela 36 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator BSIF

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,4231	0,4286	0,4286	0,4898	0,4898	0,4727	0,5714	0,4681	0,4091	0,4068
	MI	0,4231	0,3673	0,4068	0,4407	0,4286	0,4898	0,5098	0,4800	0,4000	0,4483
KNN 3	ANV	0,5128	0,4737	0,4324	0,4324	0,4737	0,4865	0,3889	0,5581	0,5854	0,5238
	MI	0,5128	0,4737	0,4737	0,4324	0,4324	0,4324	0,4324	0,4615	0,4103	0,4651
KNN 5	ANV	0,5263	0,5263	0,4444	0,4865	0,4865	0,4865	0,4865	0,5500	0,5641	0,5500
	MI	0,5263	0,5500	0,5263	0,5641	0,4444	0,4444	0,4444	0,4103	0,5116	0,5652
MLP	ANV	0,5909	0,7692	0,6939	0,6250	0,5532	0,5333	0,6531	0,6786	0,0000	0,0000
	MI	0,5909	0,5882	0,6909	0,7037	0,6923	0,6154	0,5882	0,6154	0,0000	0,5200
RF	ANV	0,3182	0,2609	0,4091	0,4091	0,3556	0,3556	0,4082	0,3256	0,2927	0,2105
	MI	0,3182	0,3913	0,2927	0,3913	0,4286	0,3721	0,2439	0,3182	0,2857	0,4103
SVM	ANV	0,6222	0,6222	0,5909	0,5909	0,6087	0,6087	0,6087	0,5714	0,6047	0,6538
	MI	0,6222	0,6222	0,6222	0,5909	0,5909	0,5909	0,5581	0,5581	0,5778	0,5455

Tabela 37 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator BSIF

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,3050	0,3058	0,3058	0,3153	0,3153	0,3119	0,3146	0,3476	0,2717	0,2339
	MI	0,3050	0,2969	0,3012	0,3068	0,2558	0,3860	0,3370	0,3306	0,3193	0,2948
KNN 3	ANV	0,3063	0,3579	0,3656	0,2939	0,3003	0,3025	0,2741	0,3397	0,3443	0,3509
	MI	0,3063	0,3579	0,3719	0,2942	0,2939	0,2937	0,2937	0,2022	0,1944	0,3173
KNN 5	ANV	0,3073	0,3073	0,2950	0,3012	0,3014	0,2881	0,3017	0,3114	0,3404	0,3549
	MI	0,3073	0,3105	0,3071	0,3130	0,2952	0,2948	0,2948	0,1946	0,2107	0,2181
MLP	ANV	0,4471	0,3801	0,4160	0,4409	0,2767	0,2972	0,4703	0,2374	0,1335	0,1335
	MI	0,4471	0,2591	0,3598	0,3229	0,2968	0,2277	0,2232	0,2273	0,1335	0,2826
RF	ANV	0,3630	0,2797	0,4168	0,3471	0,3751	0,3963	0,3578	0,2846	0,2951	0,2522
	MI	0,3630	0,2843	0,3798	0,4105	0,3362	0,2869	0,2960	0,3124	0,2679	0,2941
SVM	ANV	0,2263	0,2263	0,2216	0,2216	0,2245	0,2245	0,2245	0,2183	0,2950	0,2323
	MI	0,2263	0,2263	0,2263	0,2216	0,2216	0,2216	0,2167	0,2167	0,2199	0,2151

## C.2.2 Resultados Extrator EQP

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 38) e o cenário Macro (Tabela 39).

Tabela 38 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator EQP

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,5957	0,5778	0,4651	0,3415	0,3636	0,5306	0,5106	0,4746	0,5172	0,4918
	MI	0,5957	0,5000	0,5172	0,5574	0,5846	0,6230	0,5614	0,5200	0,5283	0,5882
KNN 3	ANV	0,5909	0,5909	0,5909	0,5854	0,5854	0,5652	0,6087	0,6800	0,6667	0,6667
	MI	0,5909	0,5581	0,5581	0,5581	0,6383	0,6250	0,6957	0,7500	0,6400	0,5882
KNN 5	ANV	0,5238	0,5238	0,5238	0,4762	0,4762	0,5238	0,5116	0,5455	0,6383	0,6190
	MI	0,5238	0,5581	0,5238	0,5238	0,6364	0,5778	0,6818	0,6047	0,6087	0,6222
MLP	ANV	0,6275	0,5882	0,5769	0,6087	0,6122	0,6545	0,4800	0,6316	0,6349	0,3333
	MI	0,6275	0,6545	0,6038	0,6250	0,6000	0,6154	0,5714	0,5926	0,0000	0,0000
RF	ANV	0,5417	0,5200	0,6809	0,4706	0,5882	0,5957	0,7200	0,4681	0,5217	0,4815
	MI	0,5417	0,5417	0,5306	0,5769	0,5455	0,5490	0,6545	0,6250	0,6667	0,6939
SVM	ANV	0,4500	0,4500	0,4500	0,4500	0,4500	0,5128	0,4615	0,4324	0,4615	0,4500
	MI	0,4500	0,3784	0,3333	0,3333	0,3333	0,2941	0,4324	0,5714	0,6222	0,6275

Tabela 39 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator EQP

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2968	0,3050	0,2569	0,2593	0,2564	0,2716	0,2592	0,2038	0,2102	0,2063
	MI	0,2968	0,3319	0,2392	0,2189	0,2228	0,3712	0,3266	0,3086	0,2145	0,2224
KNN 3	ANV	0,3347	0,3347	0,3347	0,4119	0,4119	0,3323	0,2247	0,3063	0,3040	0,2901
	MI	0,3347	0,2747	0,2744	0,2744	0,2296	0,2987	0,2947	0,2937	0,3020	0,3372
KNN 5	ANV	0,2838	0,2838	0,2838	0,2627	0,2627	0,3255	0,2098	0,2150	0,2285	0,2831
	MI	0,2838	0,2749	0,2698	0,2698	0,3412	0,2775	0,2923	0,2811	0,3402	0,3495
MLP	ANV	0,3424	0,2241	0,2939	0,2982	0,2760	0,3535	0,2379	0,3269	0,2317	0,1834
	MI	0,3424	0,2912	0,4170	0,4228	0,4148	0,4148	0,2852	0,2240	0,1335	0,1335
RF	ANV	0,2920	0,2892	0,3659	0,2299	0,3905	0,2480	0,2607	0,2470	0,2518	0,2047
	MI	0,2920	0,2517	0,2466	0,2927	0,2844	0,2461	0,2321	0,3885	0,3683	0,3952
SVM	ANV	0,2006	0,2006	0,2006	0,2006	0,2006	0,2093	0,2020	0,1974	0,2020	0,2006
	MI	0,2006	0,1897	0,1830	0,1830	0,1830	0,1770	0,1974	0,2183	0,2263	0,2283



### C.2.3 Resultados Extrator INCEPTION

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 40) e o cenário Macro (Tabela 41).

Tabela 40 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator INCEPTION

% de Classificador	Atributos -> Ranqueador	100% 2048	90% 1843	80% 1638	70% 1434	60% 1229	50% 1024	40% 819	30% 614	20% 410	10% 205
DT	ANV	0,2500	0,2000	0,2500	0,2500	0,1154	0,1277	0,1429	0,1961	0,2308	0,2632
	MI	0,2500	0,1026	0,1951	0,3673	0,3556	0,3478	0,3111	0,3182	0,2745	0,2449
KNN 3	ANV	0,1111	0,2051	0,1111	0,1579	0,2051	0,2000	0,2051	0,2778	0,3590	0,3415
	MI	0,1111	0,1111	0,1667	0,1622	0,2162	0,2162	0,2105	0,2778	0,3158	0,3810
KNN 5	ANV	0,1212	0,1212	0,1212	0,1765	0,1176	0,1622	0,1818	0,2286	0,3500	0,3158
	MI	0,1212	0,1212	0,1212	0,1250	0,1212	0,1143	0,1667	0,2222	0,1714	0,3500
MLP	ANV	0,5714	0,5614	0,5574	0,5000	0,5763	0,5397	0,5429	0,5455	0,5846	0,5294
	MI	0,5714	0,5862	0,5246	0,5614	0,5246	0,5246	0,5333	0,5000	0,5000	0,5091
RF	ANV	0,3830	0,3077	0,2857	0,3333	0,3600	0,3265	0,3478	0,3111	0,5357	0,3137
	MI	0,3830	0,3846	0,2553	0,2449	0,3333	0,2609	0,2857	0,4783	0,3860	0,2857
SVM	ANV	0,3721	0,3636	0,3556	0,3556	0,3913	0,3913	0,4000	0,4167	0,4400	0,4906
	MI	0,3721	0,3721	0,3636	0,3556	0,3913	0,3750	0,3750	0,3750	0,3556	0,3830

Tabela 41 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator INCEPTION

% de Classificador	Atributos -> Ranqueador	100%	90%	80%	70%	60%	50%	40%	30%	20%	10%
DT	ANV	0,2252	0,2305	0,2252	0,2252	0,1671	0,1759	0,2133	0,2351	0,1931	0,2291
	MI	0,2252	0,1710	0,2245	0,1854	0,2149	0,1820	0,2022	0,1783	0,1710	0,1675
KNN 3	ANV	0,2218	0,2356	0,2215	0,2289	0,2354	0,2353	0,3073	0,2463	0,3299	0,2419
	MI	0,2218	0,2220	0,2301	0,2293	0,2372	0,3086	0,3076	0,3603	0,3238	0,2478
KNN 5	ANV	0,1516	0,1516	0,1516	0,1597	0,1513	0,1579	0,1605	0,1676	0,1860	0,1807
	MI	0,1516	0,1521	0,1521	0,1524	0,1521	0,1511	0,1583	0,1667	0,1592	0,1856
MLP	ANV	0,4039	0,2757	0,2749	0,2086	0,3660	0,2145	0,2146	0,2505	0,2680	0,3300
	MI	0,4039	0,2538	0,3078	0,2594	0,3271	0,2697	0,2710	0,3444	0,2655	0,3264
RF	ANV	0,1913	0,1788	0,2113	0,1818	0,1873	0,2128	0,2337	0,1787	0,2693	0,2590
	MI	0,1913	0,1914	0,1712	0,1697	0,2873	0,2441	0,3046	0,2718	0,2485	0,2150
SVM	ANV	0,1896	0,1886	0,1872	0,1872	0,1926	0,1926	0,1936	0,1962	0,1999	0,2078
	MI	0,1896	0,1896	0,1882	0,1868	0,1926	0,1902	0,1907	0,1902	0,1872	0,1916

## C.2.4 Resultados Extrator LBP

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 42) e o cenário Macro (Tabela 43).

Tabela 42 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LBP

% de Classificador	Atributos -> Ranqueador	100% 59	90% 53	80% 47	70% 41	60% 35	50% 30	40% 24	30% 18	20% 12	10% 6
DT	ANV	0,4706	0,4898	0,4800	0,5217	0,5417	0,5417	0,5652	0,4783	0,3902	0,4211
	MI	0,4706	0,4800	0,5957	0,5532	0,5532	0,5652	0,5652	0,4545	0,5217	0,4231
KNN 3	ANV	0,5714	0,5714	0,5417	0,5417	0,5833	0,5833	0,5455	0,5581	0,5581	0,4286
	MI	0,5714	0,5217	0,5116	0,5000	0,5000	0,5532	0,6383	0,6087	0,4651	0,4762
KNN 5	ANV	0,5833	0,5714	0,5714	0,5714	0,5600	0,6250	0,5581	0,5909	0,5909	0,3902
	MI	0,5833	0,5532	0,5652	0,5532	0,5714	0,5417	0,6087	0,6087	0,4545	0,4615
MLP	ANV	0,6792	0,6087	0,6522	0,5882	0,6400	0,6667	0,5455	0,4091	0,2857	0,2353
	MI	0,6792	0,5306	0,6809	0,6122	0,5957	0,6667	0,5714	0,3478	0,2632	0,2941
RF	ANV	0,5000	0,4091	0,5417	0,5532	0,5000	0,5283	0,5185	0,5098	0,4783	0,1765
	MI	0,5000	0,5417	0,5200	0,5455	0,5600	0,5106	0,6441	0,5185	0,5660	0,4800
SVM	ANV	0,2703	0,2703	0,2703	0,2703	0,2703	0,3529	0,3030	0,3030	0,3030	0,5532
	MI	0,2703	0,2703	0,2703	0,2703	0,2703	0,2703	0,3030	0,3030	0,6296	0,5455

Tabela 43 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LBP

% de Classificador	Atributos -> Ranqueador	100% 59	90% 53	80% 47	70% 41	60% 35	50% 30	40% 24	30% 18	20% 12	10% 6
DT	ANV	0,2047	0,2070	0,2054	0,2404	0,2156	0,2147	0,2181	0,2058	0,1919	0,1964
	MI	0,2047	0,2061	0,2231	0,2175	0,2172	0,2181	0,2185	0,2018	0,2121	0,1980
KNN 3	ANV	0,2203	0,2203	0,2161	0,2161	0,2220	0,2789	0,2148	0,2167	0,2167	0,1981
	MI	0,2203	0,2132	0,3095	0,2507	0,2507	0,2539	0,2292	0,2252	0,2516	0,2052
KNN 5	ANV	0,2218	0,2206	0,2201	0,2203	0,2187	0,2756	0,2167	0,2216	0,2216	0,1929
	MI	0,2218	0,2173	0,2185	0,2171	0,2206	0,2165	0,2248	0,2245	0,2025	0,2593
MLP	ANV	0,3498	0,4354	0,3007	0,3132	0,3389	0,4673	0,3783	0,3241	0,2487	0,2262
	MI	0,3498	0,3190	0,5284	0,3920	0,3873	0,3860	0,2493	0,2189	0,1736	0,1772
RF	ANV	0,3690	0,2699	0,3078	0,2905	0,2386	0,2444	0,2745	0,2385	0,2045	0,1631
	MI	0,3690	0,2734	0,3499	0,2729	0,2765	0,3676	0,2945	0,2121	0,2829	0,2330
SVM	ANV	0,1742	0,1742	0,1742	0,1742	0,1742	0,1854	0,1781	0,1781	0,1781	0,2168
	MI	0,1742	0,1742	0,1742	0,1742	0,1742	0,1742	0,1781	0,1781	0,2293	0,2151





## C.2.7 Resultados Extrator LPQ

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 48) e o cenário Macro (Tabela 49).

Tabela 48 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LPQ

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,6349	0,6349	0,6349	0,6349	0,6349	0,4912	0,4912	0,5172	0,7458	0,5532
	MI	0,6349	0,6349	0,6349	0,6349	0,6349	0,6349	0,5263	0,5614	0,4255	0,4583
KNN 3	ANV	0,5714	0,6047	0,6047	0,6364	0,6522	0,6364	0,6512	0,6047	0,6364	0,4865
	MI	0,5714	0,5714	0,6364	0,6364	0,6957	0,7111	0,6667	0,6512	0,5957	0,5778
KNN 5	ANV	0,4878	0,5714	0,6047	0,6667	0,6522	0,6222	0,5714	0,6512	0,5238	0,5128
	MI	0,4878	0,5366	0,5714	0,5714	0,6364	0,6667	0,6047	0,6977	0,5714	0,5455
MLP	ANV	0,7931	0,6923	0,7241	0,7778	0,5833	0,7059	0,8438	0,8302	0,0000	0,7778
	MI	0,7931	0,7018	0,7273	0,7857	0,7600	0,7059	0,0000	0,7347	0,0000	0,0000
RF	ANV	0,5200	0,5106	0,5417	0,5200	0,4255	0,4167	0,4186	0,5652	0,4255	0,4348
	MI	0,5200	0,5217	0,4000	0,4348	0,3810	0,5926	0,4091	0,3158	0,4545	0,4898
SVM	ANV	0,7667	0,7797	0,7797	0,7797	0,8000	0,8000	0,7667	0,7869	0,8214	0,7451
	MI	0,7667	0,7667	0,7541	0,7667	0,7667	0,7667	0,7667	0,7241	0,7636	0,7308

Tabela 49 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LPQ

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2720	0,2710	0,2710	0,2710	0,2710	0,2573	0,2573	0,2542	0,2871	0,2590
	MI	0,2720	0,2720	0,2710	0,2710	0,2710	0,2710	0,2555	0,2816	0,2396	0,2452
KNN 3	ANV	0,4859	0,4623	0,4623	0,4099	0,4031	0,3948	0,4118	0,4053	0,4003	0,3622
	MI	0,4859	0,4859	0,4670	0,4668	0,4329	0,5063	0,4999	0,4822	0,4009	0,3171
KNN 5	ANV	0,3867	0,3989	0,4190	0,4132	0,4116	0,4073	0,4004	0,4260	0,4076	0,3335
	MI	0,3867	0,3939	0,3989	0,3991	0,4089	0,4283	0,4039	0,4322	0,2614	0,2579
MLP	ANV	0,3915	0,3549	0,3496	0,3816	0,3282	0,4338	0,4482	0,3160	0,1335	0,3578
	MI	0,3915	0,3379	0,3578	0,3468	0,3713	0,4110	0,1335	0,2917	0,1335	0,1335
RF	ANV	0,3576	0,3550	0,2809	0,3494	0,3941	0,3836	0,4064	0,4643	0,3757	0,3438
	MI	0,3576	0,3572	0,3727	0,3074	0,3390	0,3881	0,2866	0,3447	0,4386	0,2995
SVM	ANV	0,2503	0,2519	0,2519	0,2519	0,2550	0,2550	0,2503	0,2534	0,2572	0,3168
	MI	0,2503	0,2503	0,2487	0,2503	0,2503	0,2503	0,2503	0,2437	0,2487	0,2433

## C.2.8 Resultados Extrator OBIF

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 50) e o cenário Macro (Tabela 51).

Tabela 50 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator OBIF

% de Classificador	Atributos -> Ranqueador	100% 484	90% 436	80% 387	70% 339	60% 290	50% 242	40% 194	30% 145	20% 97	10% 48
DT	ANV	0,6792	0,6800	0,6800	0,6792	0,7059	0,7037	0,6792	0,7143	0,6538	0,6984
	MI	0,6792	0,6800	0,6800	0,6545	0,6545	0,6545	0,7059	0,7059	0,6939	0,6415
KNN 3	ANV	0,4615	0,5455	0,5581	0,5455	0,5778	0,5333	0,5116	0,4762	0,5532	0,6923
	MI	0,4615	0,4615	0,5455	0,5455	0,5455	0,5455	0,5116	0,5333	0,5652	0,5116
KNN 5	ANV	0,4103	0,6190	0,6364	0,6364	0,5909	0,6087	0,6087	0,5652	0,6250	0,6667
	MI	0,4103	0,4103	0,5366	0,5714	0,6190	0,5854	0,5714	0,6087	0,5652	0,6383
MLP	ANV	0,0000	0,0000	0,1429	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
	MI	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
RF	ANV	0,2424	0,1875	0,1250	0,2222	0,2286	0,2424	0,2500	0,3030	0,2941	0,1379
	MI	0,2424	0,2941	0,1935	0,1333	0,1875	0,2941	0,2222	0,1290	0,2941	0,1818
SVM	ANV	0,7143	0,7273	0,7500	0,7500	0,7368	0,7368	0,7368	0,7368	0,7273	0,7500
	MI	0,7143	0,7143	0,7143	0,7143	0,7273	0,7273	0,7037	0,7368	0,7143	0,7500

Tabela 51 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator OBIF

% de Classificador	Atributos -> Ranqueador	100% 484	90% 436	80% 387	70% 339	60% 290	50% 242	40% 194	30% 145	20% 97	10% 48
DT	ANV	0,2371	0,2370	0,2370	0,2369	0,2407	0,2403	0,2369	0,2419	0,2339	0,2400
	MI	0,2371	0,2370	0,2370	0,2338	0,2338	0,2338	0,2407	0,2407	0,2389	0,2310
KNN 3	ANV	0,3010	0,3130	0,3014	0,3132	0,2702	0,2639	0,3086	0,2489	0,3009	0,4532
	MI	0,3010	0,3010	0,2996	0,2996	0,3130	0,3130	0,3079	0,2639	0,2684	0,2843
KNN 5	ANV	0,2934	0,3354	0,3534	0,3534	0,2653	0,2678	0,2678	0,2616	0,3110	0,3494
	MI	0,2934	0,2934	0,3236	0,3286	0,3354	0,3306	0,3281	0,2678	0,2614	0,2786
MLP	ANV	0,1335	0,1335	0,1490	0,1334	0,1335	0,1335	0,1335	0,1335	0,1335	0,1296
	MI	0,1335	0,1335	0,1335	0,1335	0,1335	0,1335	0,1337	0,1335	0,1335	0,1335
RF	ANV	0,2289	0,2378	0,2443	0,2514	0,2799	0,2304	0,3382	0,3289	0,2498	0,3130
	MI	0,2289	0,2409	0,2522	0,2206	0,1995	0,2143	0,2593	0,2152	0,2663	0,3693
SVM	ANV	0,2419	0,2435	0,2470	0,2470	0,2453	0,2453	0,2453	0,2453	0,2435	0,2470
	MI	0,2419	0,2419	0,2419	0,2419	0,2435	0,2435	0,2399	0,2453	0,2419	0,2470

### **C.3 (H-Local) Classificação Hierárquica com Seleção LCPN**

Esta seção apresenta os resultados de todas as classificações feitas, para todos os extratores utilizados durante a pesquisa, no cenário de Classificação Plano utilizando Seleção Plana. Sendo os extratores: BSIF, EQP, INCEPTION, LBP, LDN, LETRIST, LPQ E OBIF, seus resultados se encontram respectivamente nas subseções C.3.1, C.3.2, C.3.3, C.3.4, C.3.5, C.3.6, C.3.7 e C.3.8.

### C.3.1 Resultados Extrator BSIF

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 52) e o cenário Macro (Tabela 53).

Tabela 52 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator BSIF

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,4231	0,4348	0,4889	0,4889	0,4231	0,3404	0,3415	0,3721	0,3750	0,4762
	MI	0,4231	0,4727	0,5600	0,5000	0,5000	0,5172	0,5000	0,4727	0,4186	0,2857
KNN 3	ANV	0,5128	0,4211	0,4324	0,4324	0,5263	0,3889	0,3784	0,4500	0,4762	0,4286
	MI	0,5128	0,4737	0,4324	0,4324	0,4324	0,4444	0,5128	0,5128	0,4103	0,4615
KNN 5	ANV	0,5263	0,4737	0,4865	0,4865	0,5263	0,5263	0,4737	0,4000	0,5116	0,4878
	MI	0,5263	0,5500	0,5128	0,4737	0,4444	0,4000	0,4000	0,3529	0,3333	0,4500
MLP	ANV	0,5909	0,6038	0,7667	0,5882	0,7500	0,6923	0,7170	0,5957	0,0000	0,6316
	MI	0,5909	0,5926	0,6667	0,7636	0,7368	0,5000	0,6316	0,6250	0,5600	0,5957
RF	ANV	0,3182	0,3333	0,2727	0,3404	0,3750	0,2791	0,4000	0,3600	0,3333	0,3182
	MI	0,3182	0,3636	0,4800	0,1951	0,2727	0,3000	0,3111	0,2222	0,3556	0,3256
SVM	ANV	0,6222	0,5909	0,6364	0,5909	0,6087	0,6364	0,6047	0,5366	0,5455	0,5366
	MI	0,6222	0,6222	0,6222	0,6222	0,5909	0,5909	0,5909	0,5581	0,5581	0,5238

Tabela 53 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator BSIF

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,3050	0,3068	0,3152	0,3152	0,3050	0,3338	0,3653	0,3337	0,3563	0,2985
	MI	0,3050	0,3128	0,3255	0,3167	0,3165	0,3185	0,3865	0,3693	0,3486	0,3285
KNN 3	ANV	0,3063	0,2921	0,2939	0,2939	0,3078	0,2741	0,2320	0,2016	0,2056	0,2338
	MI	0,3063	0,3005	0,2942	0,2939	0,2939	0,2952	0,2673	0,2821	0,2529	0,3178
KNN 5	ANV	0,3073	0,2994	0,3012	0,3012	0,3073	0,3073	0,2456	0,1938	0,2107	0,2476
	MI	0,3073	0,3105	0,3052	0,2992	0,2948	0,2748	0,2648	0,2688	0,2322	0,2969
MLP	ANV	0,4471	0,2673	0,4217	0,3116	0,5851	0,2863	0,3547	0,2222	0,1335	0,2270
	MI	0,4471	0,2655	0,4609	0,3856	0,3984	0,2933	0,2305	0,2853	0,3139	0,2705
RF	ANV	0,3630	0,2975	0,3387	0,3463	0,4164	0,3453	0,3461	0,2912	0,3490	0,3442
	MI	0,3630	0,3296	0,3899	0,3449	0,3271	0,3892	0,3418	0,3192	0,3317	0,3220
SVM	ANV	0,2263	0,2216	0,2281	0,2216	0,2245	0,2281	0,2233	0,2131	0,2146	0,2131
	MI	0,2263	0,2263	0,2263	0,2263	0,2216	0,2216	0,2216	0,2167	0,2167	0,2115



### C.3.2 Resultados Extrator EQP

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 54) e o cenário Macro (Tabela 55).

Tabela 54 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator EQP

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,5957	0,5652	0,4000	0,5833	0,4898	0,5385	0,4000	0,4545	0,4000	0,4615
	MI	0,5957	0,6250	0,6122	0,5957	0,5957	0,6122	0,6122	0,6122	0,4400	0,6032
KNN 3	ANV	0,5909	0,5581	0,5366	0,4878	0,4762	0,5116	0,5778	0,6250	0,5000	0,4898
	MI	0,5909	0,6190	0,5854	0,6364	0,6222	0,6364	0,5714	0,6667	0,5116	0,5000
KNN 5	ANV	0,5238	0,4878	0,5000	0,4878	0,5000	0,4762	0,4390	0,5909	0,4878	0,5306
	MI	0,5238	0,5500	0,5854	0,5128	0,6222	0,6957	0,6047	0,5778	0,5217	0,5455
MLP	ANV	0,6275	0,5652	0,6000	0,6538	0,6296	0,6400	0,5455	0,1818	0,4167	0,3684
	MI	0,6275	0,6275	0,6122	0,6383	0,6038	0,5714	0,6038	0,5600	0,0000	0,5283
RF	ANV	0,5417	0,5660	0,5926	0,6154	0,5882	0,5714	0,4706	0,5818	0,6538	0,5600
	MI	0,5417	0,5490	0,5417	0,5306	0,6154	0,5532	0,5455	0,6182	0,4528	0,5490
SVM	ANV	0,4500	0,4500	0,4500	0,5128	0,4737	0,4737	0,4737	0,4324	0,3684	0,4878
	MI	0,4500	0,3784	0,3784	0,3333	0,5500	0,5500	0,5714	0,5581	0,6047	0,4737

Tabela 55 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator EQP

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2968	0,2990	0,2378	0,2865	0,2443	0,2141	0,1939	0,2015	0,1934	0,2010
	MI	0,2968	0,3061	0,3107	0,2968	0,2968	0,3107	0,3107	0,3107	0,3229	0,2726
KNN 3	ANV	0,3347	0,3157	0,3906	0,3834	0,3242	0,3868	0,3394	0,4173	0,3271	0,2070
	MI	0,3347	0,4169	0,3976	0,4051	0,3874	0,3416	0,3242	0,3765	0,3399	0,3018
KNN 5	ANV	0,2838	0,2787	0,3376	0,2780	0,2795	0,2759	0,2710	0,2936	0,2782	0,2133
	MI	0,2838	0,3858	0,3910	0,3802	0,3965	0,3566	0,3432	0,3493	0,2842	0,3202
MLP	ANV	0,3424	0,2779	0,2267	0,2979	0,2785	0,3294	0,2184	0,1611	0,2687	0,1893
	MI	0,3424	0,2304	0,3327	0,3153	0,2256	0,2781	0,2664	0,2770	0,1335	0,2627
RF	ANV	0,2920	0,2207	0,2550	0,3003	0,2443	0,2207	0,2683	0,2422	0,2563	0,2371
	MI	0,2920	0,2172	0,2393	0,2332	0,3809	0,2837	0,2585	0,3829	0,2790	0,2380
SVM	ANV	0,2006	0,2006	0,2006	0,2093	0,2035	0,2035	0,2035	0,1974	0,1885	0,2057
	MI	0,2006	0,1897	0,1897	0,1830	0,2148	0,2148	0,2183	0,2167	0,2233	0,2035

### C.3.3 Resultados Extrator INCEPTION

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 56) e o cenário Macro (Tabela 57).

Tabela 56 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator INCEPTION

% de Classificador	Atributos -> Ranqueador	100% 2048	90% 1843	80% 1638	70% 1434	60% 1229	50% 1024	40% 819	30% 614	20% 410	10% 205
DT	ANV	0,2500	0,2000	0,2500	0,2500	0,2500	0,2500	0,0889	0,1000	0,1333	0,1081
	MI	0,2500	0,2632	0,2632	0,2632	0,2500	0,2564	0,2222	0,2857	0,2917	0,2326
KNN 3	ANV	0,1111	0,1579	0,1579	0,1081	0,2105	0,2105	0,2162	0,3500	0,3636	0,3077
	MI	0,1111	0,0588	0,2703	0,2222	0,2564	0,1667	0,2162	0,1667	0,2927	0,2632
KNN 5	ANV	0,1212	0,1250	0,1212	0,1250	0,0645	0,1212	0,1714	0,2703	0,3500	0,2564
	MI	0,1212	0,1212	0,1250	0,1818	0,1290	0,1290	0,1212	0,1143	0,2162	0,2222
MLP	ANV	0,5714	0,5263	0,6071	0,4839	0,5373	0,5397	0,4667	0,5079	0,5185	0,5455
	MI	0,5714	0,5357	0,5263	0,5614	0,5938	0,5085	0,5079	0,4667	0,4918	0,4912
RF	ANV	0,3830	0,3182	0,4000	0,3265	0,4286	0,2791	0,4706	0,3860	0,3265	0,3396
	MI	0,3830	0,2593	0,2667	0,2927	0,4314	0,3922	0,3137	0,5200	0,5000	0,3396
SVM	ANV	0,3721	0,3636	0,3556	0,3478	0,3556	0,3556	0,4167	0,4082	0,3750	0,4528
	MI	0,3721	0,3636	0,4000	0,4000	0,4000	0,4255	0,4167	0,4490	0,3913	0,3830

Tabela 57 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator INCEPTION

% de Classificador	Atributos -> Ranqueador	100% 2048	90% 1843	80% 1638	70% 1434	60% 1229	50% 1024	40% 819	30% 614	20% 410	10% 205
DT	ANV	0,2252	0,2305	0,2252	0,2252	0,2252	0,2252	0,2026	0,1735	0,2104	0,2064
	MI	0,2252	0,2324	0,2324	0,2324	0,2339	0,2321	0,2114	0,2280	0,2248	0,2205
KNN 3	ANV	0,2218	0,2284	0,2289	0,2211	0,2371	0,2366	0,2379	0,2574	0,2587	0,3224
	MI	0,2218	0,2145	0,2452	0,2383	0,2432	0,3015	0,3087	0,2300	0,2481	0,2446
KNN 5	ANV	0,1516	0,1520	0,1516	0,1524	0,1436	0,1516	0,1588	0,1738	0,1856	0,1724
	MI	0,1516	0,1516	0,1524	0,1607	0,1528	0,1528	0,1521	0,1511	0,1663	0,1671
MLP	ANV	0,4039	0,2691	0,3140	0,2058	0,2136	0,3283	0,2753	0,2664	0,3253	0,2872
	MI	0,4039	0,3697	0,3113	0,2186	0,2796	0,2103	0,3074	0,2031	0,2951	0,3601
RF	ANV	0,1913	0,1797	0,1918	0,2387	0,2845	0,2681	0,2030	0,3031	0,3348	0,2707
	MI	0,1913	0,1705	0,1728	0,2890	0,3088	0,1916	0,2637	0,2946	0,3046	0,2545
SVM	ANV	0,1896	0,1882	0,1872	0,1864	0,1872	0,1872	0,1962	0,1952	0,1902	0,2020
	MI	0,1896	0,1882	0,1936	0,1936	0,1936	0,1972	0,1962	0,2010	0,1926	0,1916

### C.3.4 Resultados Extrator LBP

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 58) e o cenário Macro (Tabela 59).

Tabela 58 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LBP

% de Classificador	Atributos -> Ranqueador	100% 59	90% 53	80% 47	70% 41	60% 35	50% 30	40% 24	30% 18	20% 12	10% 6
DT	ANV	0,4706	0,5600	0,3846	0,4815	0,4255	0,5263	0,5116	0,4583	0,4545	0,4545
	MI	0,4706	0,5600	0,5306	0,5957	0,5957	0,5417	0,5417	0,5778	0,4783	0,4390
KNN 3	ANV	0,5714	0,5833	0,5714	0,5833	0,5652	0,5778	0,6364	0,5500	0,5714	0,5909
	MI	0,5714	0,5417	0,5106	0,5455	0,5778	0,5778	0,5417	0,6047	0,6667	0,6222
KNN 5	ANV	0,5833	0,6000	0,6122	0,6154	0,5882	0,6122	0,6087	0,5500	0,6190	0,5854
	MI	0,5833	0,5532	0,5532	0,5909	0,5778	0,5490	0,5238	0,5909	0,6667	0,6364
MLP	ANV	0,6792	0,5417	0,5581	0,5778	0,6667	0,6250	0,6250	0,4000	0,2286	0,1176
	MI	0,6792	0,6667	0,6364	0,7059	0,6792	0,5833	0,5833	0,5333	0,7170	0,1818
RF	ANV	0,5000	0,5306	0,5833	0,5778	0,6154	0,5091	0,5614	0,4167	0,5091	0,2667
	MI	0,5000	0,5283	0,5833	0,5385	0,5000	0,5306	0,4706	0,5556	0,5185	0,2791
SVM	ANV	0,2703	0,2703	0,2703	0,3429	0,2941	0,2941	0,3030	0,3030	0,3030	0,3030
	MI	0,2703	0,2703	0,2703	0,2703	0,2703	0,2778	0,2778	0,3030	0,3030	0,3529

Tabela 59 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LBP

% de Classificador	Atributos -> Ranqueador	100% 59	90% 53	80% 47	70% 41	60% 35	50% 30	40% 24	30% 18	20% 12	10% 6
DT	ANV	0,2047	0,2184	0,2319	0,2063	0,2175	0,2129	0,2328	0,2016	0,2011	0,2011
	MI	0,2047	0,2184	0,2142	0,2224	0,2224	0,2152	0,2147	0,2208	0,2052	0,1989
KNN 3	ANV	0,2203	0,2935	0,2203	0,2935	0,2906	0,2922	0,3013	0,3348	0,3473	0,2787
	MI	0,2203	0,2161	0,2114	0,3593	0,3636	0,2779	0,3349	0,2954	0,3047	0,2986
KNN 5	ANV	0,2218	0,2244	0,2262	0,2268	0,2227	0,2976	0,2250	0,3584	0,3687	0,2210
	MI	0,2218	0,2173	0,2168	0,2794	0,2779	0,2171	0,2535	0,2220	0,3045	0,2283
MLP	ANV	0,3498	0,3775	0,4309	0,3402	0,2831	0,3482	0,4436	0,2838	0,2165	0,1524
	MI	0,3498	0,4215	0,4541	0,4000	0,2852	0,2551	0,2232	0,2720	0,2901	0,2185
RF	ANV	0,3690	0,3041	0,2798	0,2774	0,3217	0,2785	0,3278	0,2579	0,2667	0,1869
	MI	0,3690	0,3793	0,3201	0,2519	0,3815	0,2816	0,2289	0,3653	0,2931	0,2368
SVM	ANV	0,1742	0,1742	0,1742	0,1842	0,1770	0,1770	0,1781	0,1781	0,1781	0,1783
	MI	0,1742	0,1742	0,1742	0,1742	0,1742	0,1751	0,1751	0,1781	0,1781	0,1854





### C.3.7 Resultados Extrator LPQ

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 64) e o cenário Macro (Tabela 65).

Tabela 64 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator LPQ

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,6349	0,6349	0,6349	0,6032	0,6032	0,6032	0,6032	0,6071	0,5818	0,6071
	MI	0,6349	0,6349	0,6349	0,6349	0,6349	0,6349	0,6667	0,6441	0,6441	0,5455
KNN 3	ANV	0,5714	0,5909	0,6222	0,6364	0,6222	0,6522	0,6047	0,6667	0,5455	0,6809
	MI	0,5714	0,6047	0,6190	0,6667	0,6818	0,6522	0,6667	0,6957	0,5957	0,6087
KNN 5	ANV	0,4878	0,5366	0,5714	0,6222	0,6522	0,6667	0,6383	0,6047	0,5238	0,5581
	MI	0,4878	0,5366	0,6047	0,6364	0,6364	0,6047	0,6667	0,6364	0,5714	0,5217
MLP	ANV	0,7931	0,7458	0,7273	0,7857	0,7200	0,6897	0,7692	0,7419	0,0000	0,7937
	MI	0,7931	0,7869	0,6667	0,7547	0,7869	0,8197	0,7541	0,6538	0,0000	0,0000
RF	ANV	0,5200	0,5116	0,5882	0,4490	0,5000	0,4167	0,5200	0,4000	0,4255	0,4783
	MI	0,5200	0,4255	0,3774	0,3556	0,4545	0,5000	0,5000	0,4091	0,3913	0,3600
SVM	ANV	0,7667	0,7667	0,7667	0,8065	0,7869	0,7869	0,7869	0,8000	0,8000	0,7719
	MI	0,7667	0,7667	0,7541	0,7541	0,7667	0,7667	0,7458	0,7500	0,7931	0,7778

Tabela 65 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator LPQ

% de Classificador	Atributos -> Ranqueador	100% 256	90% 230	80% 205	70% 179	60% 154	50% 128	40% 102	30% 77	20% 51	10% 26
DT	ANV	0,2720	0,2720	0,2710	0,2670	0,2670	0,2670	0,2670	0,3082	0,2994	0,2737
	MI	0,2720	0,2710	0,2710	0,2710	0,2710	0,2710	0,2761	0,2733	0,2733	0,2576
KNN 3	ANV	0,4859	0,4886	0,5362	0,5199	0,4933	0,5387	0,4908	0,3573	0,3240	0,3316
	MI	0,4859	0,4911	0,4637	0,4054	0,5021	0,4266	0,3571	0,4329	0,4043	0,3337
KNN 5	ANV	0,3867	0,3937	0,3989	0,4068	0,4111	0,4130	0,4094	0,4398	0,3709	0,3066
	MI	0,3867	0,3706	0,3900	0,3855	0,4089	0,4041	0,3292	0,3253	0,3989	0,2615
MLP	ANV	0,3915	0,4119	0,3646	0,3523	0,3974	0,3835	0,3094	0,3672	0,1335	0,2539
	MI	0,3915	0,3840	0,3734	0,3685	0,3496	0,4123	0,3692	0,4518	0,1335	0,1335
RF	ANV	0,3576	0,3987	0,3377	0,2767	0,4541	0,3307	0,3462	0,2914	0,4000	0,2389
	MI	0,3576	0,3473	0,2941	0,3150	0,4003	0,3183	0,3183	0,3958	0,2883	0,2983
SVM	ANV	0,2503	0,2503	0,2503	0,2564	0,2534	0,2534	0,2534	0,2550	0,2550	0,2506
	MI	0,2503	0,2503	0,2487	0,2487	0,2503	0,2503	0,2471	0,2470	0,2536	0,2505

### C.3.8 Resultados Extrator OBIF

Esta seção apresenta todos os resultados do Extrator BSIF obtidos pela seleção dos métodos Filters, estando divididos em duas tabelas para o cenário Covid (Tabela 66) e o cenário Macro (Tabela 67).

Tabela 66 – Todos os Resultados Filters de Covid-19 F1-Score para o Extrator OBIF

% de Classificador	Atributos -> Rankeador	100% 484	90% 436	80% 387	70% 339	60% 290	50% 242	40% 194	30% 145	20% 97	10% 48
DT	ANV	0,6792	0,6538	0,6792	0,6792	0,6792	0,6792	0,6792	0,7273	0,7037	0,6792
	MI	0,6792	0,7037	0,7368	0,6909	0,7368	0,7273	0,7018	0,6667	0,7500	0,7368
KNN 3	ANV	0,4615	0,4500	0,4390	0,4390	0,5116	0,5000	0,5652	0,5532	0,6122	0,6512
	MI	0,4615	0,4615	0,5128	0,4000	0,5000	0,5581	0,4762	0,5455	0,5000	0,5833
KNN 5	ANV	0,4103	0,4878	0,4878	0,4390	0,4762	0,5116	0,5455	0,5778	0,6250	0,6667
	MI	0,4103	0,4211	0,4737	0,5500	0,5128	0,6190	0,5778	0,6531	0,6667	0,5217
MLP	ANV	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,2000	0,0000	0,0000
	MI	0,0000	0,0000	0,0000	0,1250	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
RF	ANV	0,2424	0,2857	0,1935	0,1818	0,2857	0,3030	0,2424	0,1935	0,2000	0,2500
	MI	0,2424	0,2857	0,3030	0,2222	0,2424	0,2424	0,2941	0,3333	0,1765	0,1250
SVM	ANV	0,7143	0,7368	0,7500	0,7500	0,7500	0,7500	0,7500	0,7500	0,7143	0,7273
	MI	0,7143	0,7143	0,7143	0,7143	0,7143	0,7368	0,7500	0,7500	0,7500	0,7273

Tabela 67 – Todos os Resultados Filters de Macro-Avg F1-Score para o Extrator OBIF

% de Classificador	Atributos -> Rankeador	100% 484	90% 436	80% 387	70% 339	60% 290	50% 242	40% 194	30% 145	20% 97	10% 48
DT	ANV	0,2371	0,2332	0,2369	0,2369	0,2369	0,2369	0,2369	0,2437	0,2403	0,2369
	MI	0,2371	0,2406	0,2812	0,2385	0,2451	0,2727	0,2400	0,2353	0,2472	0,2451
KNN 3	ANV	0,3010	0,2996	0,2980	0,2980	0,3084	0,3065	0,2922	0,2903	0,3228	0,4355
	MI	0,3010	0,3010	0,3083	0,2686	0,2829	0,3150	0,2897	0,3251	0,2931	0,3186
KNN 5	ANV	0,2934	0,3050	0,3050	0,2980	0,3033	0,3084	0,3132	0,3178	0,3110	0,3645
	MI	0,2934	0,2950	0,3025	0,3136	0,3083	0,3356	0,3450	0,3558	0,3424	0,3098
MLP	ANV	0,1335	0,1335	0,1335	0,1335	0,1335	0,1335	0,1335	0,1629	0,1335	0,1335
	MI	0,1335	0,1335	0,1335	0,1515	0,1335	0,1335	0,1335	0,1335	0,1335	0,1335
RF	ANV	0,2289	0,2532	0,2521	0,2237	0,2299	0,2485	0,2591	0,2875	0,3132	0,2548
	MI	0,2289	0,3346	0,2488	0,2311	0,2570	0,2902	0,2555	0,2444	0,2136	0,2263
SVM	ANV	0,2419	0,2453	0,2470	0,2470	0,2470	0,2470	0,2470	0,2470	0,2419	0,2435
	MI	0,2419	0,2419	0,2419	0,2419	0,2419	0,2453	0,2470	0,2470	0,2470	0,2435





# APÊNDICE D – Resultados com Algoritmo Genético

Uma vez que, apesar do esperado, os resultados obtidos com as seleções feitas através do Algoritmo Genético não estiveram entre os melhores (desconsiderando o cenário covid H-Local), este Capítulo é focado em apresentar estes resultados de forma separada. Assim, ainda utilizando os cenários de análise covid e macro, eles se encontram divididos entre a *Classificação Plana com Seleção Plana*, a *Classificação Hierárquica com Seleção Plana* e a *Classificação Hierárquica com Seleção LCPN* se encontrando respectivamente nas Seções D.1, D.2, e D.3.

## D.1 (Plano) Classificação Plana com Seleção Plana

Com os melhores resultados do cenário de Classificação Plana com Seleção Plana sendo apresentados nas Tabelas de 68 a 71 elas se encontram divididas entre: os cinco melhores resultados nos cenários de análise covid (Tabela 68) e macro (Tabela 69); e entre o melhor resultado obtido para cada extrator nos cenários de análise covid (Tabela 70) e macro (Tabela 71). Desta forma, sendo cada resultado destas tabelas provenientes de um experimento, nele foi utilizado um classificador (CLF), um método de seleção (MS) e um extrator (EXT), além de ser necessário a seleção de uma quantidade (N°) e porcentagem (%) de atributos, o f1-score de sua respectiva baseline (classificação com todos os atributos) também é apresentado.

Tabela 68 – Melhores cinco resultados do AG para Covid F1 no cenário Plano

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
1	LDN	SVM	GA	27 / 56	48,2%	0,7500	0,7500
2	OBIF	SVM	GA	251 / 484	51,9%	0,7037	0,7451
3	LETRIST	DT	GA	218 / 413	52,8%	0,7308	0,7407
4	LETRIST	KNN 5	GA	230 / 413	55,7%	0,6222	0,7347
5	LETRIST	SVM	GA	214 / 413	51,8%	0,7273	0,7273

Tabela 69 – Melhores cinco resultados do AG para Macro Avg no cenário Plano

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	EQP	RF	GA	126 / 256	49,2%	0,3524	0,4726
2	LETRIST	DT	GA	218 / 413	52,8%	0,3737	0,4135
3	LETRIST	RF	GA	210 / 413	50,8%	0,3650	0,4087
4	LBP	MLP	GA	40 / 59	67,8%	0,3439	0,4003
5	LPQ	KNN 5	GA	125 / 256	48,8%	0,3821	0,3952

Assim, como pode ser visto os cinco melhores resultados de covid f1-score se encontram entre os valores de  $0,7273$  a  $0,7500$ , e as variações que eles obtiveram de suas respectivas baselines se encontram de  $0,0$  a  $+0,1125$ , se encontrando assim na posição 50 no ranking com todos os experimentos (covid plano). Enquanto isso os melhores cinco resultados obtidos para macro-avg f1-score contém variações de seu baseline de  $+0,0131$  a  $+0,1201$ , permitindo chegar a resultados de  $0,3952$  a  $0,4726$  se localizando na posição 6 no ranking com todos os experimentos (macro plano).

Tabela 70 – Melhores resultados do AG para Covid F1 de cada extrator no cenário Plano

EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1
BSIF	MLP	GA	126 / 256	49,2%	0,7857	0,7037
EQP	KNN 3	GA	121 / 256	47,3%	0,5333	0,6364
INCEPTION	MLP	GA	1026 / 2048	50,1%	0,5000	0,4800
LBP	SVM	GA	27 / 59	45,8%	0,2424	0,6923
LDN	SVM	GA	27 / 56	48,2%	0,7500	0,7500
LETRIST	DT	GA	218 / 413	52,8%	0,7308	0,7407
LPQ	SVM	GA	128 / 256	50,0%	0,7143	0,7143
OBIF	SVM	GA	251 / 484	51,9%	0,7037	0,7451

Tabela 71 – Melhores resultados do AG para Macro Avg de cada extrator no cenário Plano

EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg
BSIF	MLP	GA	126 / 256	49,2%	0,3251	0,3475
EQP	RF	GA	126 / 256	49,2%	0,3524	0,4726
INCEPTION	MLP	GA	1026 / 2048	50,1%	0,2887	0,3826
LBP	MLP	GA	40 / 59	67,8%	0,3439	0,4003
LDN	DT	GA	19 / 56	33,9%	0,3879	0,3907
LETRIST	DT	GA	218 / 413	52,8%	0,3737	0,4135
LPQ	KNN 5	GA	125 / 256	48,8%	0,3821	0,3952
OBIF	SVM	GA	251 / 484	51,9%	0,2399	0,3887

Com isso, ao analisar o melhor experimento obtido para cada extrator, no cenário de análise covid temos resultados que variam de  $0,4800$  a  $0,7500$  com uma variação em relação ao seu baseline de  $-0,0820$  a  $+0,4499$ . Enquanto no cenário de análise macro resultados de  $0,3475$  a  $0,4726$  foram obtidos, com variações  $+0,0028$  a  $+0,1488$  em relação ao seu respectivo baseline.

## D.2 (H-Plano) Classificação Hierárquica com Seleção Plana

Com os melhores resultados do cenário de Classificação Hierárquica com Seleção Plana sendo apresentados nas Tabelas de 72 a 75 elas se encontram divididas entre: os cinco melhores resultados nos cenários de análise covid (Tabela 72) e macro (Tabela 73); e entre o melhor resultado obtido para cada extrator nos cenários de análise covid (Tabela 74) e macro (Tabela 75). Desta forma, sendo cada resultado destas tabelas provenientes

de um experimento, nele foi utilizado um classificador (CLF), um método de seleção (MS) e um extrator (EXT), além de ser necessário a seleção de uma quantidade (N°) e porcentagem (%) de atributos, o f1-score de sua respectiva baseline (classificação com todos os atributos) também é apresentado.

Tabela 72 – Melhores cinco resultados do AG para Covid F1 no cenário HPlano

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
1	LPQ	MLP	GA	117 / 256	45,7%	0,7931	0,7813
2	LPQ	SVM	GA	128 / 256	50,0%	0,7667	0,7667
3	LETRIST	SVM	GA	214 / 413	51,8%	0,7368	0,7500
3	OBIF	SVM	GA	215 / 484	51,9%	0,7143	0,7500
4	LDN	SVM	GA	27 / 56	48,2%	0,7368	0,7368
5	BSIF	SVM	GA	125 / 256	48,8%	0,6222	0,7308

Tabela 73 – Melhores cinco resultados do AG para Macro Avg no cenário HPlano

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	BSIF	MLP	GA	126 / 256	49,2%	0,4471	0,4554
2	LPQ	KNN 3	GA	134 / 256	52,3%	0,4859	0,4427
3	LPQ	MLP	GA	117 / 256	45,7%	0,3915	0,4059
3	LPQ	KNN 5	GA	125 / 256	48,8%	0,3867	0,4059
4	LPQ	RF	GA	126 / 256	49,2%	0,3576	0,3956
5	LETRIST	DT	GA	218 / 413	52,8%	0,3018	0,3867

Assim, como pode ser visto os cinco melhores resultados de covid f1-score se encontram entre os valores de  $0,7308$  a  $0,7813$ , e as variações que eles obtiveram de suas respectivas baselines se encontram de  $-0,1119$  a  $+0,1086$ , se encontrando assim na posição 15 no ranking com todos os experimentos (Covid HPlano). Enquanto isso os melhores cinco resultados obtidos para macro-avg f1-score contém variações de seu baseline de  $-0,0431$  a  $+0,0849$ , permitindo chegar a resultados de  $0,3867$  a  $0,4554$  se localizando na posição 23 no ranking com todos os experimentos (Macro HPlano).

Tabela 74 – Melhores resultados do AG para Covid F1 de cada extrator no cenário HPlano

EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1
BSIF	SVM	GA	125 / 256	48,8%	0,6222	0,7308
EQP	KNN 3	GA	121 / 256	47,3%	0,5909	0,6047
INCEPTION	MLP	GA	1026 / 2048	50,1%	0,5714	0,4912
LBP	SVM	GA	27 / 59	45,8%	0,2703	0,6786
LDN	SVM	GA	27 / 56	48,2%	0,7368	0,7368
LETRIST	SVM	GA	214 / 413	51,8%	0,7368	0,7500
LPQ	MLP	GA	117 / 256	45,7%	0,7931	0,7813
OBIF	SVM	GA	215 / 484	51,9%	0,7143	0,7500

Com isso, ao analisar o melhor experimento obtido para cada extrator, no cenário de análise covid temos resultados que variam de  $0,4912$  a  $0,7813$  com uma variação em relação ao seu baseline de  $-0,0802$  a  $+0,4083$ . Enquanto no cenário de análise macro

Tabela 75 – Melhores resultados do AG para Macro Avg de cada extrator no cenário HPlano

EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg
BSIF	MLP	GA	126 / 256	49,2%	0,4471	0,4554
EQP	KNN 5	GA	125 / 256	48,8%	0,2838	0,3562
INCEPTION	KNN 3	GA	1018 / 2048	49,7%	0,2218	0,2372
LBP	RF	GA	33 / 59	55,9%	0,3690	0,3245
LDN	RF	GA	29 / 56	51,8%	0,2671	0,3199
LETRIST	DT	GA	218 / 413	52,8%	0,3018	0,3867
LPQ	KNN 3	GA	134 / 256	52,3%	0,4859	0,4427
OBIF	KNN 5	GA	246 / 484	50,8%	0,2934	0,2967

resultados de 0,2372 a 0,4554 foram obtidos, com variações -0,0445 a +0,0849 em relação ao seu respectivo baseline.

### D.3 (H-Local) Classificação Hierárquica com Seleção LCPN

Com os melhores resultados do cenário de Classificação Hierárquica com Seleção LCPN sendo apresentados nas Tabelas de 76 a 79 elas se encontram divididas entre: os cinco melhores resultados nos cenários de análise covid (Tabela 76) e macro (Tabela 77); e entre o melhor resultado obtido para cada extrator nos cenários de análise covid (Tabela 78) e macro (Tabela 79). Desta forma, sendo cada resultado destas tabelas provenientes de um experimento, nele foi utilizado um classificador (CLF), um método de seleção (MS) e um extrator (EXT), além de ser necessário a seleção de uma quantidade (N°) e porcentagem (%) de atributos, o f1-score de sua respectiva baseline (classificação com todos os atributos) também é apresentado.

Tabela 76 – Melhores cinco resultados do AG para Covid F1 no cenário HLocal

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Covid F1 ↓
1	LPQ	MLP	GA	- / 256	-	0,7931	0,8136
2	LPQ	SVM	GA	- / 256	-	0,7667	0,7869
3	LETRIST	SVM	GA	- / 413	-	0,7368	0,7500
3	OBIF	SVM	GA	- / 484	-	0,7143	0,7500
4	LDN	SVM	GA	- / 56	-	0,7368	0,7368
5	LDN	DT	GA	- / 56	-	0,6984	0,7333

Tabela 77 – Melhores cinco resultados do AG para Macro Avg no cenário HLocal

#	EXT	CLF	MS	N° Atributos	% Atributos	Baseline	Macro Avg ↓
1	LPQ	KNN 3	GA	- / 256	-	0,4859	0,4653
2	LPQ	MLP	GA	- / 256	-	0,3915	0,4434
3	BSIF	MLP	GA	- / 256	-	0,4471	0,4183
4	LETRIST	DT	GA	- / 413	-	0,3018	0,3956
5	LPQ	KNN 5	GA	- / 256	-	0,3867	0,3902

Assim, como pode ser visto os cinco melhores resultados de covid f1-score se encontram entre os valores de  $0,7333$  a  $0,8136$ , e as variações que eles obtiveram de suas respectivas baselines se encontram de  $0,0$  a  $+0,0357$ , se encontrando assim na posição 2 no ranking com todos os experimentos (Covid HLocal). Enquanto isso os melhores cinco resultados obtidos para macro-avg f1-score contém variações de seu baseline de  $-0,0288$  a  $+0,0938$ , permitindo chegar a resultados de  $0,3902$  a  $0,4653$  se localizando na posição 26 no ranking com todos os experimentos (Macro HLocal).

Tabela 78 – Melhores resultados do AG para Covid F1 de cada extrator no cenário HLocal

EXT	CLF	MS	Nº Atributos	% Atributos	Baseline	Covid F1
BSIF	MLP	GA	- / 256	-	0,5909	0,7083
EQP	RF	GA	- / 256	-	0,5417	0,6786
INCEPTION	MLP	GA	- / 2048	-	0,5714	0,4643
LBP	SVM	GA	- / 59	-	0,2703	0,6786
LDN	SVM	GA	- / 56	-	0,7368	0,7368
LETRIST	SVM	GA	- / 413	-	0,7368	0,7500
LPQ	MLP	GA	- / 256	-	0,7931	0,8136
OBIF	SVM	GA	- / 484	-	0,7143	0,7500

Tabela 79 – Melhores resultados do AG para Macro Avg de cada extrator no cenário HLocal

EXT	CLF	MS	Nº Atributos	% Atributos	Baseline	Macro Avg
BSIF	MLP	GA	- / 256	-	0,4471	0,4183
EQP	KNN 3	GA	- / 256	-	0,3347	0,3605
INCEPTION	MLP	GA	- / 2048	-	0,4039	0,2910
LBP	MLP	GA	- / 59	-	0,3498	0,3699
LDN	KNN 5	GA	- / 56	-	0,3248	0,3248
LETRIST	DT	GA	- / 413	-	0,3018	0,3956
LPQ	KNN 3	GA	- / 256	-	0,4859	0,4653
OBIF	KNN 5	GA	- / 484	-	0,2934	0,3445

Com isso, ao analisar o melhor experimento obtido para cada extrator, no cenário de análise covid temos resultados que variam de  $0,4643$  a  $0,8136$  com uma variação em relação ao seu baseline de  $-0,1071$  a  $+0,4083$ . Enquanto no cenário de análise macro resultados de  $0,2910$  a  $0,4653$  foram obtidos, com variações  $-0,1129$  a  $+0,0938$  em relação ao seu respectivo baseline.



# Anexos





## ANEXO A – Metas de Resultados

Esta anexo apresenta nas Tabelas de 80 a 83 os melhores resultados apresentados por Pereira et al. (2020) em seu artigo. Em cada um dos cenários, estes resultados representam metas a serem alcançadas uma vez que a mesma base de dados foi utilizada. Desta forma, o cenário de classificação plana se encontra nas Tabelas 80 (covid) e 81 (macro) enquanto os resultados atingidos no cenário de classificação hierárquico encontram-se nas Tabelas 82 (covid) e 83 (macro), estando destacado o melhor resultado de cada tabela/cenário.

Tabela 80 – Melhores resultados de (PEREIRA et al., 2020) para Covid F1 no cenário Plano

Prediction Schema	Feature(s)	Classifier(s)	Resampling(s)	F1-Score
Individual	LQP	MLP	ENN or None	0,8333
Early Fusion	LBP & LPQ	MLP	AllKNN or RENN	0,8000
Late Fusion (Top-5)	LPQ	MLP	ENN	0,8333
Late Fusion (Top-Features)	BSIF, EQP & LPQ	MLP	ENN & RENN	0,8333
Late Fusion (Top-Classifiers)	LDN & LPQ	MLP & DT	SMOTE+TL & ENN	0,8333

Tabela 81 – Melhores resultados de (PEREIRA et al., 2020) para Macro Avg no cenário Plano

Prediction Schema	Feature(s)	Classifier(s)	Resampling(s)	F1-Score
Individual	LBP	MLP	RENN or AllKNN	0,6491
Early Fusion	BSIF & EQP & LPQ	MLP	TomekLink	0,5563
Late Fusion (Top-5)	LBP	MLP	AllKNN & RENN	0,6491
Late Fusion (Top-Features)	BSIF & LBP	MLP	RENN & SMOTE-B2	0,6491
Late Fusion (Top-Classifiers)	LDN & LETRIST	DT & KNN-3	RENN or None	0,4500

Tabela 82 – Melhores resultados de (PEREIRA et al., 2020) para Covid F1 no cenário Hierárquico

Prediction Schema	Feature(s)	Resampling(s)	F1-Score
Individual	BSIF	SMOTE-B1	0,8387
Early Fusion	BSIF & EQP & LPQ	SMOTE or TL	0,8889
Late Fusion (Top-5)	BSIF & OBIF	SMOTE-B1 & None	0,8276
Late Fusion (Top-Features)	BSIF & EQP	SMOTE-B2 & None	0,2676

Tabela 83 – Melhores resultados de (PEREIRA et al., 2020) para Macro Avg no cenário Hierárquico

Prediction Schema	Feature(s)	Resampling(s)	F1-Score
Individual	LETRIST	SMOTE-B2	0,4615
Early Fusion	LBP & INCEPTION-V3 & LETRIST	SMOTE-B1	0,5669
Late Fusion (Top-5)	LDN & LETRIST	SMOTE & SMOTE-B2	0,4751
Late Fusion (Top-Features)	BSIF & LETRIST	SMOTE-B1 & SMOTE	0,4751