

Dissertação apresentada à Pró-Reitoria de Pós-Graduação do Instituto Tecnológico de Aeronáutica, como parte dos requisitos para obtenção do título de Mestre em Ciências no Programa de Pós-Graduação em Engenharia Eletrônica e Computação, Área de Telecomunicações.

Fabiano Gabriel da Silva

AVALIAÇÃO DE TÉCNICAS DE *MACHINE LEARNING* NA CLASSIFICAÇÃO DE ALVOS MARÍTIMOS EM IMAGENS SAR NA BANDA C

Dissertação aprovada em sua versão final pelos abaixo assinados:

Prof. Dr. Renato Machado

Orientador

Prof^a. Dr^a. Bruna Gregory Palm

Coorientadora

Prof^a. Dr^a. Emília Villani

Pró-Reitora de Pós-Graduação

Campo Montenegro
São José dos Campos, SP - Brasil
2022

Dados Internacionais de Catalogação-na-Publicação (CIP)
Divisão de Informação e Documentação

da Silva, Fabiano Gabriel
Avaliação de Técnicas de *Machine Learning* na Classificação de Alvos Marítimos em Imagens SAR na Banda C / Fabiano Gabriel da Silva.
São José dos Campos, 2022.
106f.

Dissertação de Mestrado – Curso de Engenharia Eletrônica e Computação. Área de Telecomunicações – Instituto Tecnológico de Aeronáutica, 2022. Orientador: Prof. Dr. Renato Machado. Coorientadora: Prof^a. Dr^a. Bruna Gregory Palm.

1. SAR-ATR. 2. Machine Learning. 3. Deep Learning. I. Instituto Tecnológico de Aeronáutica. II. Avaliação de Técnicas de *Machine Learning* na Classificação de Alvos Marítimos em Imagens SAR na Banda C.

REFERÊNCIA BIBLIOGRÁFICA

DA SILVA, Fabiano Gabriel. **Avaliação de Técnicas de *Machine Learning* na Classificação de Alvos Marítimos em Imagens SAR na Banda C.** 2022. 106f.
Dissertação de Mestrado em Telecomunicações – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Fabiano Gabriel da Silva

TÍTULO DO TRABALHO: Avaliação de Técnicas de *Machine Learning* na Classificação de Alvos Marítimos em Imagens SAR na Banda C.

TIPO DO TRABALHO/ANO: Dissertação / 2022

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias desta dissertação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação pode ser reproduzida sem a autorização do autor.

Fabiano Gabriel da Silva
Rua José Machado Faria, 276, Jardim Colorado
12.227-730 – São José dos Campos–SP

AVALIAÇÃO DE TÉCNICAS DE *MACHINE LEARNING* NA CLASSIFICAÇÃO DE ALVOS MARÍTIMOS EM IMAGENS SAR NA BANDA C

Fabiano Gabriel da Silva

Composição da Banca Examinadora:

| | | | | |
|---------------------------------------|------------------------------|----------------|---|---------|
| Prof. Dr. | Marcelo da Silva Pinho | Presidente | - | ITA |
| Prof. Dr. | Renato Machado | Orientador | - | ITA |
| Prof ^a . Dr ^a . | Bruna Gregory Palm | Coorientadora | - | BTH |
| Prof. Dr. | Dimas Irion Alves | Membro Interno | - | ITA |
| Dr. | Rafael Antônio da Silva Rosa | Membro Externo | - | Visiona |

À minha mãe Francisca pela dedicação na minha criação e de meu irmão, por todos os exemplos de superação que enfrentou para nos dar uma boa educação.

Agradecimentos

Primeiramente, gostaria de agradecer a Deus por conceder saúde, força e determinação para vencer os obstáculos que surgem no dia a dia.

Ao meu Orientador Professor Renato Machado pela orientação no desenvolvimento da pesquisa e da escrita científica, pelas revisões nos artigos e textos da dissertação, pelos ensinamentos de vida, pela paciência, por sempre ter palavras de incentivo e motivação.

A minha Coorientadora Professora Bruna Palm pela orientação, ensinamentos sobre a metodologia e escrita científica, pelas revisões nos artigos e texto da dissertação, pelos incentivos e motivação no desenvolvimento da pesquisa.

Ao Maj Falqueto pelo fornecimento das imagens e materiais complementares que permitiram essa pesquisa, por todos os esclarecimentos de dúvidas e explicações.

À Marinha do Brasil pela autorização na realização do mestrado.

À Força Área Brasileira pela oportunidade de estudar no ITA, instituição que tanto orgulha o Brasil por possuir Professores do mais alto nível de conhecimento, por formar e capacitar profissionais com excelente nível técnico.

À Coordenação do PPGAO composta pelo Cel Olympio, T Cel Duncan, T Cel Rebouças, T Cel Fausto, Ten Natália e Sgt Leonan pela dedicação, empenho e suporte prestados aos alunos do PPGAO. Ao LabGE pela estrutura de apoio, sua equipe pelos ensinamentos e pela dedicação nos treinamentos e trabalhos técnicos desenvolvidos.

Aos Oficiais-Alunos do PPGAO da FAB - Cel Severo, T Cel Gustavo, T Cel Gustavo Vieira, T Cel Moreira, Ten Marcelo; EB - T Cel Vitor, T Cel Luis Carlos, T Cel Marcelo; MB - CF Paim, CF Robson, CF Alessandro, CT Luis Vito, CT Antônio Pedro, pelo companheirismo, pela conversa descontraídas nos intervalos de aula, pelas trocas de experiências.

Ao INPE pela oportunidade de cursar disciplinas na área de Sensoriamento Remoto.

A Patrícia pelo companheirismo em todos os momentos, meus familiares e amigos que mesmo distante estão sempre na torcida com pensamentos positivos.

*“O sonho é que leva a gente para a frente.
Se a gente for seguir a razão, fica aquietado, acomodado.”*

— ARIANO SUASSUNA

Resumo

Esta pesquisa faz uma avaliação da classificação de alvos em ambiente marítimo através de imagens de radar de abertura sintética - *synthetic aperture radar* (SAR), técnicas de *machine learning* (ML) e *deep learning* (DL). Os alvos de interesse são plataformas e navios localizados na baía de Campos/RJ. Para identificação dos alvos, utiliza-se um banco de imagens SAR polarimétricas vertical-horizontal (VH) e vertical-vertical (VV) obtidas de sensores orbitais do sistema Sentinel-1. Duas redes neurais convolucionais - *convolutional neural network* (CNN), *visual geometry group* (VGG), VGG-16 e VGG-19 são utilizadas para vetorização e extração de atributos. A classificação das imagens é dividida em seis formas distintas, considerando as seguintes técnicas de ML: *logistic regression* (LR), *support vector machine* (SVM), *random forest* (RF), *k nearest neighbor* (kNN), *naive Bayes* (NB), *decision tree* (DT), *adaboost* (ADBST) e *neural network* (NET). As amostras são geradas através da técnica *bootstrap*. Utiliza-se treinamento supervisionado, com 80% das amostras para treino e 20% das amostras para teste. A metodologia considera seis métodos de classificação. Para cada método são realizadas 50 classificações. Todos os classificadores foram avaliados em relação a CNN (VGG-16 e VGG-19) e a polarização (VH e VV). Os maiores níveis de acurácia são obtidos pelo LR com 85,5% e 86,5%. A técnica *principal components analysis* (PCA) aumenta a performance dos classificadores NB e RF. A combinação dos *data sets* permite aumentar a variabilidade das amostras de treinamento, proporcionando maior capacidade de generalização. A técnica *stacking* apresenta melhores resultados que as classificações individuais. Os índices de acurácia superiores a 80% concentram-se no canal de polarização VH e são distribuídos de forma equivalente entre as CNN VGG-16 e VGG-19. Por fim, os resultados foram comparados pelos testes estatísticos Kruskal-Wallis e Dunn que comprovam haver diferença significativa entre os métodos de classificação, ou seja, as otimizações (configurações de parâmetros e combinações de técnicas) proporcionam resultados competitivos com a literatura. Diante disso, a pesquisa contribui para ampliação dos métodos de vigilância da Amazônia Azul através de técnicas de inteligência artificial consideradas estado da arte.

Abstract

This research evaluates the classification of targets in a maritime environment through synthetic aperture radar (SAR) images, machine learning (ML), and deep learning (DL) techniques. The targets of interest are platforms and vessels located in the Campos/RJ basin. A data set of polarimetric vertical-horizontal (VH) and vertical-vertical (VV) SAR images obtained from orbital sensors of the Sentinel-1 system is used to identify the targets. Two convolutional neural networks (CNN), visual geometry group (VGG), VGG-16, and VGG-19, are used for vectorization and feature extraction. The classification of images is divided into six different ways, considering the following ML techniques: logistic regression (LR), support vector machine (SVM), random forest (RF), k nearest neighbor (kNN), naive Bayes (NB), decision tree (DT), adaboost (ADBOST), and neural network (NET). Samples are generated using the bootstrap technique. Supervised training is used, with 80% of samples for training and 20% of samples for testing. The methodology considers six classification methods. For each method 50 classifications are performed. All classifiers were evaluated about CNN (VGG-16 and VGG-19) and polarization (VH and VV). The LR obtains the highest levels of accuracy with 85.5% and 86.5%. The principal components analysis (PCA) technique increases the performance of NB and RF classifiers. The combination of data sets increases the variability of training samples, providing greater generalization capacity. The stacking technique presents better results than the individual classifications. Accuracy indices greater than 80% are concentrated in the VH polarization channel and are evenly distributed between VGG-16 and VGG-19 CNNs. Finally, the results were compared by the Kruskal-Wallis and Dunn statistical tests, which prove that there is a significant difference between the classification methods, that is, optimizations (parameter settings and combinations of techniques) provide results competitive with the literature. Therefore, the research contributes to expanding surveillance methods in the Blue Amazon through artificial intelligence techniques considered state of the art.

Lista de Figuras

| | |
|---|----|
| FIGURA 2.1 – Modelo ilustrativo do sistema Sentinel-1. Imagem extraída de (European Space Agency, 2022). | 28 |
| FIGURA 2.2 – Modos de aquisição de dados a partir do imageamento do Sentinel-1 durante o seu deslocamento (European Space Agency, 2022) | 30 |
| FIGURA 2.3 – Localização plataformas de petróleo na bacia de Campos/RJ. | 34 |
| FIGURA 2.4 – Tipos de plataformas petrolíferas marítimas. Imagem extraída de (MORAIS, 2013). | 34 |
| FIGURA 2.5 – Comparação da imagens ópticas de plataformas de petróleo e suas respectivas imagens SAR com as seguintes características banda C, resolução espacial - <i>High Resolution</i> (HR), (20 m × 22 m) (<i>range</i> × <i>azimuth</i>), polarizações VH e VV. Imagens óticas e SAR extraídas de (MARINHA DO BRASIL. Diretoria de Portos e Costas., 2021; FALQUETO <i>et al.</i> , 2019), respectivamente. | 35 |
| FIGURA 2.6 – Separação de dados por hiperplano | 37 |
| FIGURA 2.7 – Aplicação do SVM indicando os vetores de suporte e margem. Os pontos delimitando as margens são os vetores de suporte e separam os dois conjuntos de dados. | 37 |
| FIGURA 2.8 – Diagrama árvore de decisão. | 38 |
| FIGURA 2.9 – Diagrama <i>Naive Bayes</i> | 40 |
| FIGURA 2.10 – Rede neural Perceptron. | 44 |
| FIGURA 2.11 – Rede neural MLP. | 44 |
| FIGURA 2.12 – <i>Data set</i> de imagens SAR Sentinel-1, polarização VH, utilizadas como fonte para extração dos <i>patches</i> dos alvos. | 47 |
| FIGURA 2.13 – <i>Data set</i> de imagens SAR Sentinel-1, polarização VV, utilizadas como fonte para extração dos <i>patches</i> dos alvos. | 48 |

| | |
|--|----|
| FIGURA 2.14 –Localização dos <i>patches</i> de plataformas nas imagens SAR 20180430 F80C com polarização VH e VV. | 50 |
| FIGURA 2.15 – <i>Flowchart</i> do <i>data set</i> de imagens Sentinel-1 usado neste trabalho. | 51 |
| FIGURA 2.16 –(a) Estrutura de formação da VGG-16 com suas 13 camadas convolucionais; (b) Estrutura de formação da VGG-19 com suas 16 camadas convolucionais. | 52 |
| FIGURA 2.17 –Aplicação da VGG-16 modificada utilizada neste trabalho. Um <i>patch</i> de alvo é fornecido à camada convolucional 1. A camada FC7 fornece aos classificadores os atributos vetorizados. | 53 |
| FIGURA 2.18 –Extração de atributos por redes CNN VGG-16 e VGG-19. | 53 |
| FIGURA 2.19 –Processo de formação dos grupos de treinamento e teste. | 54 |
| FIGURA 2.20 –Metodologia. Os <i>patches</i> gerados no <i>data set</i> são vetorizados pelo bloco <i>deep learning</i> . Logo após, são gerados os 50 grupos de treinamento e teste. Cada grupo é classificado utilizando os seis métodos e os oito classificadores. Os resultados são avaliados pela acurácia e validados com os testes estatísticos. | 55 |
| FIGURA 2.21 –Fluxograma resumido da metodologia considerando os dados SAR, <i>deep learning</i> , os seis métodos de análise aplicados, os grupos de treinamento e testes estatísticos. | 56 |
| FIGURA 3.1 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-16VH. | 61 |
| FIGURA 3.2 – Diagrama de análise com a biblioteca Scikit-learn. | 64 |
| FIGURA 3.3 – Variância cumulativa explicada das componentes principais da VGG-16VH. Sendo o valor máximo de variância cumulativa explicada: (a) 80%; (b) 94,54%; (c) 97%; (d) 98%. | 65 |
| FIGURA 3.4 – Curva ROC dos resultados de classificação do LR em relação as CNN VGG-16/19 e polarizações VH/VV. | 66 |
| FIGURA 3.5 – Curva ROC dos melhores resultados de classificação considerando as CNN VGG-16/19 e as polarizações VH/VV. | 67 |
| FIGURA B.1 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-16VV | 98 |
| FIGURA B.2 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-19VH | 99 |

| | |
|--|-----|
| FIGURA B.3 –Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-19VV | 99 |
| FIGURA C.1 –Variância cumulativa explicada das componentes principais da VGG-16VV. Sendo o valor máximo de variância cumulativa explicada: (a) 89%; (b) 95%; (c) 97%; (d) 98%. | 101 |
| FIGURA C.2 –Variância cumulativa explicada das componentes principais da VGG-19VH. Sendo o valor máximo de variância cumulativa explicada: (a) 87,7%; (b) 94,5%; (c) 96,7%; (d) 98%. | 102 |
| FIGURA C.3 –Variância cumulativa explicada das componentes principais da VGG-19VV. Sendo o valor máximo de variância cumulativa explicada: (a) 88,6%; (b) 94,9%; (c) 97%; (d) 98,2%. | 103 |
| FIGURA C.4 –Curva ROC dos resultados de classificação do SVM considerando as CNN VGG-16/VGG-19 e polarizações VH/VV. | 104 |
| FIGURA C.5 –Curva ROC dos resultados de classificação do NET considerando as CNN VGG-16/VGG-19 e polarizações VH/VV. | 105 |
| FIGURA C.6 –Curva ROC dos resultados de classificação do RF considerando as CNN VGG-16/VGG-19 e polarizações VH/VV. | 106 |

Lista de Tabelas

| | |
|---|----|
| TABELA 2.1 – Parâmetros e característica do sistema Sentinel-1 | 29 |
| TABELA 2.2 – Alguns fatos históricos da produção de petróleo no Brasil. | 33 |
| TABELA 2.3 – Recursos computacionais de software e hardware utilizados no desenvolvimento da pesquisa. | 45 |
| TABELA 2.4 – Número de alvos extraídos na polarização VH por imagens SAR e separados por tipo de plataforma e navio. | 46 |
| TABELA 2.5 – Número de alvos extraídos na polarização VV por imagens SAR e separados por tipo de plataforma e navio. | 49 |
| TABELA 2.6 – Distribuição das amostras de treinamento e teste. | 56 |
| TABELA 2.7 – Relação de parâmetros por classificadores. | 57 |
| TABELA 2.8 – Parâmetros ajustados. | 58 |
| TABELA 2.9 – Parâmetros ajustados no método M2. | 58 |
| TABELA 3.1 – Resumo com os dois melhores índices de acurácia por métodos de classificação. O símbolo “-” indica que a classificação não está entre os dois melhores resultados. | 60 |
| TABELA 3.2 – Resumo melhores ganhos por métodos de classificação. O símbolo “-” indica que os ganhos são negativos. | 62 |
| TABELA 3.3 – Resumo geral da média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG - 16 e 19 e polarização VH e VV. Em negrito destacam-se os melhores resultados. O símbolo (i) “-” indica classificação não utilizada e (ii) “x” indica que os classificadores são combinados para o resultado final no método M6 | 69 |

| | |
|--|----|
| TABELA 3.4 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG - 16 e polarização VH e ganho de rendimento em relação a \mathbf{M}_{Ref} . O simbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final no método M6 e (iii) “*” indica ganho não calculado por ser o método de referência. | 70 |
| TABELA 3.5 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG-16, polarização VV e ganho de rendimento em relação a \mathbf{M}_{Ref} . O simbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final no método M6 e (iii) “*” indica ganho não calculado por ser o método de referência. | 71 |
| TABELA 3.6 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG-19, polarização VH e ganho de rendimento em relação a \mathbf{M}_{Ref} . O simbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final no método M6 e (iii) “*” indica ganho não calculado por ser o método de referência. | 72 |
| TABELA 3.7 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG-19, polarização VV e ganho de rendimento em relação a \mathbf{M}_{Ref} . O simbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final do método M6 e (iii) “*” indica ganho não calculado por ser o método de referência. | 73 |
| TABELA 3.8 – Testes Kruskal-Wallis e Dunn comparando os resultados dos classificadores que apresentaram diferença significativa. Em destaque, as comparações em relação aos resultados reproduzidos de (FALQUETO <i>et al.</i> , 2019) (M1). | 74 |
| TABELA 3.9 – <i>Ranking</i> de acurácia e ganho dos classificadores quando comparados com M_{Ref} | 75 |
| TABELA 3.10 – <i>Ranking</i> de acurácia considerando os 20 melhores resultados de Acc. | 75 |
| TABELA A.1 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M1. | 86 |
| TABELA A.2 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M2. | 87 |

| | |
|---|----|
| TABELA A.3 –Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M3. | 87 |
| TABELA A.4 –Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M4. | 88 |
| TABELA A.5 –Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M5. | 88 |
| TABELA A.6 –Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M6. | 89 |
| TABELA A.7 –Teste de normalidade Shapiro-Wilk. | 89 |
| TABELA A.8 –Resultados por métricas e parâmetros do classificador SVM. | 90 |
| TABELA A.9 –Resultados por métricas e parâmetros do classificador LR. | 91 |
| TABELA A.10 –Resultados por métricas e parâmetros do classificador RF. | 92 |
| TABELA A.11 –Resultados por métricas e parâmetros do classificador RF. | 93 |
| TABELA A.12 –Resultados por métricas e parâmetros do classificador kNN. | 94 |
| TABELA A.13 –Resultados por métricas e parâmetros do classificador DT. | 94 |
| TABELA A.14 –Resultados por métricas e parâmetros do classificador NET. | 95 |
| TABELA A.15 –Resultados por métricas e parâmetros do classificador ADBST. | 96 |
| TABELA A.16 –Parâmetros otimizados com a biblioteca Scikit-learn. | 97 |

Lista de Abreviaturas e Siglas

| | |
|-------|--|
| ADBST | AdaBoost |
| AI | Artificial Intelligence |
| AIS | Automatic Identification System |
| ATR | Automatic Target Recognition |
| Acc | Accuracy |
| AUC | Area Under the Curve |
| CNN | Convolutional Neural Network |
| DL | Deep Learning |
| DNN | Deep Neural Network |
| DT | Decision Tree |
| EW | Extra-Wide |
| GAN | Generative Adversarial Network |
| GRD | Ground Range Detected |
| IW | Interferometric Wide |
| kNN | k-Nearest Neighbor |
| LR | Logistic Regression |
| ML | Machine Learning |
| MLP | Multilayer Perceptron |
| MSTAR | Moving and Stationary Target Acquisition and Recognition |
| NB | Naive Bayes |
| NET | Neural Networks |
| NLP | Natural Language Processing |
| PCA | Principal Component Analysis |
| RF | Random Forest |
| RNN | Recurrent Neural Network |
| SAR | Synthetic Aperture Radar |
| SLC | Single Look Complex |
| SM | Stripmap |
| SVM | Support Vector Machine |
| VGG | Visual Geometry Group |

Lista de Símbolos

| | |
|---------------|--|
| σ_{PQ} | Seção transversal do alvo |
| χ | Espaço de atributos |
| σ^2 | Variância |
| σ | Desvio padrão |
| λ | Comprimento de onda |
| π | Constante matemática com valor de 3,1415 |
| Θ_k | Vetores aleatórios |
| ν | Etiqueta de classe |
| S | Matriz de espalhamento |
| X | Vetor de atributos |
| Y | Classe prevista para um classificado |
| $\sigma(x)$ | Função sigmoide |
| e | Número de Euler com valor de 2,7182 |

Sumário

| | | |
|-------|--|----|
| 1 | INTRODUÇÃO | 19 |
| 1.1 | Reconhecimento Automático de Alvos em Imagens SAR | 20 |
| 1.2 | Aprendizados de Máquinas e Profundo | 21 |
| 1.3 | Classificação de Alvos em Imagens SAR | 22 |
| 1.4 | Objetivos da Dissertação | 24 |
| 1.4.1 | Objetivos Gerais | 24 |
| 1.4.2 | Objetivos Específicos | 25 |
| 1.5 | Principais Contribuições dessa Pesquisa de Mestrado | 26 |
| 1.6 | Organização da Dissertação | 26 |
| 1.7 | Conclusão | 26 |
| 2 | MATERIAIS E MÉTODOS | 27 |
| 2.1 | Missão Sentinel-1 | 27 |
| 2.1.1 | Produtos e Algoritmos | 28 |
| 2.2 | Sensoriamento Remoto por Imagens de Radar | 29 |
| 2.3 | Propriedades de Imagens SAR | 29 |
| 2.4 | Localização da Área Marítima de Interesse e Plataformas Petrolíferas | 31 |
| 2.5 | Classificação baseada em aprendizado supervisionado | 33 |
| 2.5.1 | Medidas de avaliação de desempenho | 34 |
| 2.5.2 | Algoritmos classificadores | 36 |
| 2.5.3 | <i>Principal Components Analysis</i> | 44 |
| 2.6 | Metodologia | 45 |
| 2.7 | Conclusão | 54 |

| | | |
|-----|---|-----|
| 3 | ANÁLISE NUMÉRICA | 59 |
| 3.1 | Análise com otimizações | 63 |
| 3.2 | Conclusão | 64 |
| 4 | CONCLUSÃO E TRABALHOS FUTUROS | 76 |
| | REFERÊNCIAS | 78 |
| | APÊNDICE A – TABELAS COM DETALHAMENTO DAS CLASSIFICA- ÇÕES | 86 |
| | APÊNDICE B – GRÁFICOS DOS MELHORES CLASSIFICADORES . . . | 98 |
| | APÊNDICE C – GRÁFICOS DE ANÁLISES DE OTIMIZAÇÕES | 100 |

1 Introdução

O Brasil possui uma extensa faixa litorânea rica em biodiversidade e recursos naturais (petróleo e gás natural) (MARINHA DO BRASIL. Comissão Interministerial para os Recursos do Mar., 2022). Essa faixa litorânea é conhecida como Amazônia Azul (SOARES *et al.*, 2017) por causa de sua similaridade, em termos de área e biodiversidade, com a Floresta Amazônica. Nela estão as reservas do pré-sal. Em relação a produção nacional de petróleo, gás natural e pescado, essa área marítima é responsável por 75% da produção de gás, 85% da produção de petróleo e 45% da produção de pescado. Em particular, destaca-se a Bacia de Campos como um dos maiores produtores de petróleo e gás natural do Brasil. Ela está localizada no litoral norte do estado do Rio de Janeiro, entre as cidades de Vitória/ES e Cabo Frio/RJ e abrange uma área de 120.000 km² (ARMELENTI *et al.*, 2016). Pelas rotas marítimas brasileiras são escoados 95% do comércio exterior. Diante de sua importância econômica, é fundamental a proteção das águas marítimas brasileiras.

Para isso, a vigilância marítima por meio de sensoriamento remoto é uma das formas de auxiliar nessa proteção e evitar atos ilícitos de exploração ilegal e pirataria. Sistemas com Radar de Abertura Sintética - *Synthetic Aperture Radar* (SAR) vêm sendo utilizados há mais de 30 anos no sensoriamento remoto da terra para aplicações em geociências, mudanças climáticas (MOREIRA *et al.*, 2013) e acidentes ambientais causados por derramamento de óleo (CANTORNA *et al.*, 2019; SOLBERG, 2012). Além disso, também é uma técnica utilizada na vigilância marítima (BRUSCH *et al.*, 2010; RANE; SANGILI, 2020). Sistemas SAR passaram a fornecer imagens do oceano de alta qualidade possibilitando a vigilância operacional de navios, com destaque para o Sistema de Monitoramento do Oceano (OMW), o sistema SAR de Demonstração do Alasca (AKDEMO), o sistema do Centro Comum de Pesquisa da Comunidade Européia (JRC) e o sistema MaST do Qinetiq (CRISP, 2004), sistema Copernicus da Agência Espacial Européia (ESA) (POTIN *et al.*, 2019).

Os sistemas SAR podem ser espaciais ou aerotransportados. Os sistemas espaciais fornecem cobertura mais extensa e revista frequente, sendo melhor para vigilância de área ampla, enquanto que o SAR aerotransportado é melhor para tarefas mais pontuais ou que exijam maior flexibilidade, com o compromisso de cobrirem uma área bem menor em relação aos sistemas espaciais. Com isso, a maioria dos sistemas de detecção de navios são projetados para imagens SAR satelitais (CRISP, 2004).

Uma importante propriedade dos sensores SAR é o fato de poderem gerar imagens em quaisquer condições climáticas (SHARIFZADEH *et al.*, 2019; SOLBERG, 2012), não são afetados por nuvens e não dependem da iluminação solar (CANTORNA *et al.*, 2019). A capacidade de monitoramento em todas as condições meteorológicas e durante o dia ou noite torna-se essencial para obter informações precisas sobre a localização de navios no mar (European Space Agency, 2022).

O primeiro radar de imageamento da terra, a partir do espaço, foi fornecido pela missão Seasat, lançada em 1978 pelos EUA. A ESA desenvolveu e lançou seus primeiros radares de microondas junto com os satélites ERS-1 (lançado em 17 de julho de 1991) e o ERS-2 (lançado em 20 de abril de 1995) (SNOEIJ *et al.*, 2009). Esses sistemas satelitais citados anteriormente tinham radar SAR (JIANG *et al.*, 2021). A nova geração de sistemas SAR da ESA é composta pelo Sentinel-1A e Sentinel-1B, lançados em 3 de abril de 2014 e 25 de abril de 2016, respectivamente (SCHUBERT *et al.*, 2015; POTIN *et al.*, 2019; GEUDTNER *et al.*, 2021). Os sistemas Sentinel-1 permitem o mapeamento de gelo e de icebergs para ajudar na navegação segura. Os sistemas Sentinel geram diversos tipos de produtos de imagens que podem ser adquiridos através do Copernicus Open Hub (European Space Agency, 2021).

As seções seguintes apresentam mais detalhes sobre o reconhecimento automático de alvos através de imagens de radar de abertura sintética (SAR-ATR, synthetic aperture radar-automatic target recognition), técnicas clássicas de classificação utilizando aprendizado de máquinas (ML, *machine learning*) e aprendizado profundo (DL, *deep learning*) e algumas outras técnicas híbridas de classificação consideradas nessa dissertação de mestrado.

1.1 Reconhecimento Automático de Alvos em Imagens SAR

A tecnologia de reconhecimento automático de alvos (ATR, *automatic target recognition*) utilizando imagens SAR visa obter informações sobre o alvo e melhorar a capacidade de processamento automático das informações. O SAR-ATR é um sistema que consiste em três estágios: detecção, reconhecimento e classificação (GAO *et al.*, 2019). Um sistema SAR é capaz de adquirir diversas características de retroespalhamento ou *backscattering* que contém informações únicas de identificação dos atributos do alvo. Essas informações são difíceis de serem interpretadas baseando-se apenas na visão humana. O ATR tornou-se uma das tarefas mais importantes e desafiadoras na aplicação de SAR. O problema do SAR-ATR é localizar e reconhecer alvos em ambiente com *clutter* (WANG *et al.*, 2020). Os sistemas de vigilância utilizados sobre grandes áreas oceânicas são os SAR e o sistema de identificação automática (AIS). Este último está obrigatoriamente presente em navios com massa superior a 300 toneladas (LIVINGSTONE *et al.*, 2014. (DRDC-RDDC-2014-R17)).

Geralmente, as imagens SAR são utilizadas para classificação de alvos terrestres (WAGNER, 2016; SCHUMACHER; SCHILLER, 2005), e mais recentemente para monitoramento de embarcações em alto mar. Em particular, os sistemas SAR oferecem recursos distintos de sensoriamento remoto ativo para aplicações civis e militares (EL-DARYMLI *et al.*, 2013), a saber, detecção e monitoramento marítimo de navios por facilitar a identificação dos alvos, principalmente quando sujeitos a condições atmosféricas adversas (SHARIFZADEH *et al.*, 2019). A detecção de alvos na superfície do mar depende da frequência do sensor SAR, como por exemplo, banda-X (12-7,5 GHz), banda-C (7,5-3,75 GHz), banda-S (3,75-2 GHz), banda-L (2-1 GHz) ou banda-P (0,5-0,25 GHz).

Além das várias bandas, os sensores SAR podem operar com diferentes polarizações (SOLBERG, 2012). Técnicas de processamento de imagens são utilizadas no sensoriamento remoto para detecção de alvos. Uma das técnicas mais comuns é a taxa constante de falso alarme (CFAR, *constant false-alarm rate*) (LIU *et al.*, 2017). A precisão desta técnica depende dos pixels que envolvem o local de interesse que muitas vezes são envolvidos por planos de fundo complexos (SHARIFZADEH *et al.*, 2019). Por outro lado, nos últimos anos métodos de inteligência artificial (AI, *artificial intelligence*) como ML (LIANG *et al.*, 2019) e DL (GAO *et al.*, 2019), têm se destacado em aplicações de sensoriamento remoto para classificação de alvos em imagens SAR (KUCK *et al.*, 2021; LAPINI *et al.*, 2020).

Desta forma, o objetivo deste trabalho é fazer uma análise comparativa entre diferentes técnicas de ML e DL. Mais precisamente, o foco desse trabalho é a classificação de alvos com técnicas de ML no qual são explorados algoritmos como floresta aleatória (RF, *random forest*), regressão logística (LR, *logistic regression*), redes neurais (NET, *neural networks*), máquina de vetores de suporte (SVM, *support vector machine*), *boosting* adaptativo (ADBST, *AdaBoosting*), vizinhos mais próximos (kNN, *k-Nearest-Neighbours*), árvore de decisão (DT, *Decision Tree*), Bayes ingênuo (NB, *Naive Bayes*), utilizando técnicas de DL para extração de atributos.

1.2 Aprendizados de Máquinas e Profundo

Técnicas de ML e DL têm se destacado nos últimos anos nos estudos de pesquisas para detecção de alvos no mar (GAO *et al.*, 2019). Em especial, o uso de técnicas de DL em imagens SAR têm aumentado (SHARIFZADEH *et al.*, 2019) e permitido avanços no reconhecimento de objetos (HUANG *et al.*, 2017). ML é um subconjunto de AI que habilita sistemas computacionais a aprender com experiências passadas e melhorar seu comportamento para determinadas tarefas (IGUAL; SEGUÍ, 2017; NGUYEN *et al.*, 2019). Dentre as técnicas de ML estão, por exemplo, LR, SVM, RF, NB, kNN, DT, ADBST, clusterização (*k-means clustering*) entre outras. As redes NET são um subconjunto de ML inspirado

nas redes neurais biológicas, sendo representadas por neurônios artificiais conectados em camadas (SHARIFZADEH *et al.*, 2019; NGUYEN *et al.*, 2019). Por outro lado, DL é uma técnica de redes neurais que organiza os neurônios em diversas camadas (NGUYEN *et al.*, 2019; KUBAT, 2017); São exemplos de DL: redes neurais profundas (DNN, *Deep Neural Network*), redes neurais convolucionais (CNN, *Convolutional Neural Network*), redes neurais recorrentes (RNN, *Recurrent Neural Network*) e rede adversativa generativa (GAN, *Generative Adversarial Network*) (NGUYEN *et al.*, 2019).

O DL se popularizou devido a sua acurada capacidade na detecção de objetos, classificação de alvos em imagens, segmentação semântica e processamento de linguagem natural (WANG *et al.*, 2018). Isso pode ser evidenciado, por exemplo, em (WANG *et al.*, 2017) que utiliza a CNN VGG-16 para ampliar os *data set* de treino e teste na detecção de navios com imagens SAR do Gaofen-3.

1.3 Classificação de Alvos em Imagens SAR

O desempenho na classificação de alvos em imagens SAR está associado ao número limitado de imagens e informações disponíveis pelo sensor, presença de ruído (*speckle* - característico do processo de formação da imagem), limitação humana para interpretação dos dados complexos fornecidos pelos sensores espaciais, pequena proporção entre o tamanho do espaço de atributos de entrada e as amostras de treinamento (ERSAHIN *et al.*, 2010; NATH *et al.*, 2014). Diante desses aspectos, procedimentos computacionais para análise são necessários (ERSAHIN *et al.*, 2010).

A combinação de técnicas na classificação, como pode ser visto no estudo realizado por (BAEK; JUNG, 2021) que compara imagens SAR com uma e duas polarizações através de SVM, RF e DNN, possui melhor desempenho do que o seu uso individual. Como mostrado, por exemplo em (SHARIFZADEH *et al.*, 2019), desenvolveu-se uma rede neural híbrida com algoritmos CNN e *perceptron* multicamadas (CNN-MLP). O algoritmo foi treinado com imagens SAR dos sistemas Sentinel e RADARSAT-2 e apresentou resultados melhores do que o estado da arte. Técnicas de ML, como LR e NET, são utilizadas para detecção de manchas de óleo em imagens SAR de sistemas orbitais Sentinel-1 (CANTORNA *et al.*, 2019). (MORGAN, 2015) realiza uma aplicação SAR-ATR com o *data set* público MSTAR, no qual a utilização de CNN se mostrou competitiva com os métodos considerados estado da arte. Um estudo com redes neurais convolucionais regionais mais rápidas (*Faster R-CNN*, *Faster-Regions Convolutional Neural Network*) é apresentado por (KUMAR; ZHANG, 2019) e gerou um ganho de acurácia na detecção de navios ao comparar com uma simples CNN.

Um arquitetura de radar SAR para ATR é descrita por (ZHAO *et al.*, 2000) para estimar a velocidade de um alvo com alto grau de precisão. Para isso, são elaboradas

três estratégias de aprendizagem e representação para construir o espaço padrão e funções discriminantes são comparadas: SVM, uma função de custo de informação mútua quadrática (QMI), uma análise de componentes principais (PCA, *Principal Componentes Analysis*) estendida com multirresolução (PCA-M). O experimento SAR-ATR utilizou o banco de dados MSTAR para classificar três alvos. A rede neural convolucional complexa (CV-CNN, *Complex-Valued Convolution Neural Network*) e um modelo de aprendizado por reforço para conduzir muitos trabalhos na classificação de alvos em imagens SAR são utilizados por (HIROSE, 2003).

Dados ópticos (Landsat-8) e SAR (Sentinel-1) são utilizados por (KUSSUL *et al.*, 2017) para mapear estruturas complexas em redes neurais profundas multinível (*Multi-Level Deep Learning Network*).

Um codificador automático (AE, *Automatic Encoder*) e uma CNN são utilizados por (CASTRO *et al.*, 2017) para classificar a colheita de dados ópticos multitemporais e de dados SAR. Os resultados mostraram que a classificação com AE e CNN foi melhor quando comparado com os métodos tradicionais.

Com base em rede neural recursiva (RNN, *Deep Recursive Neural network*), (NDIKUMANA *et al.*, 2018), (NDIKUMANA *et al.*, 2018) analisa dados do Sentinel-1. A partir dessa análise, o resultado de dois classificadores com redes RNN apresentou melhores resultados do que os métodos clássicos de classificação.

Um método de aprendizado por transferência é proposto por (HUANG *et al.*, 2017) para tornar o conhecimento aprendido com as imagens SAR não classificadas. Esse conhecimento é transferido para a etapa de classificação do alvo e no treinamento da CNN. Um grande número de imagens de cena SAR não identificadas é usado para treinar o caminho de reconstrução com auto-codificadores convolucionais empilhados (SCAE). Em seguida, essas camadas convolucionais pré-treinadas são reutilizadas para transferir conhecimento para tarefas de classificação de SAR. (PAN *et al.*, 2016) projeta um método baseado em representação esparsa ponderada para suprimir a interferência causada por objetos próximos ao alvo. Também é demonstrado o melhor desempenho na fusão de múltiplos classificadores do que em um único classificador (YU *et al.*, 2011).

Um método de fusão por representação esparsa e SVM é proposto por (LIU; LI, 2013) para realizar a fusão dos resultados de dois classificadores que obedecem a regra Bayesiana para tomar a decisão. Diferentemente do método baseado na extração manual dos atributos (*features*), a *deep* CNN é baseada no método automático de aprendizagem dos atributos a partir de um conjunto de dados em larga escala e alcança ótima performance no reconhecimento de objetos (HUANG *et al.*, 2017).

O treinamento de uma CNN é baseado em grande conjunto de dados, como o ImageNet, que contém cerca de 22.000 classes e aproximadamente 15 milhões de imagens classificadas.

Por enquanto, não existe um conjunto de dados SAR comparável ao ImageNet.

Dessa forma, como os bancos de dados disponíveis para pesquisa são limitados, o problema de reconhecimento de alvo atuais relacionados a CNN se concentram em aumentar os dados de treinamento (*data Augmentation*) (HUANG *et al.*, 2017; DING *et al.*, 2016), projetando uma rede menos complexa e evitando excesso de ajustes (CHEN *et al.*, 2016).

1.4 Objetivos da Dissertação

O objetivo dessa pesquisa é avaliar técnicas de ML na classificação de alvos em imagens SAR polarimétricas em ambiente marítimo. Para isso, o local considerado é a Baía de Campos, litoral dos estados do Rio de Janeiro e Espírito Santo, focando no problema de classificação de plataformas de petróleo e navios. Ao melhor de nosso conhecimento, (FALQUETO *et al.*, 2019) é o único estudo relacionado a classificação de plataformas de petróleo e navios na baía de Campos através de imagens SAR orbitais do Sentinel-1. Para o estudo, consideraram-se imagens SAR com polarização vertical-horizontal (VH) e vertical-vertical (VV). O trabalho alinha-se com a Estratégia Nacional de Defesa (BRASIL, 2013) a qual tem como uma de suas diretrizes desenvolver as capacidades de monitorar e controlar o espaço aéreo, o território e as águas jurisdicionais brasileiras. Ela define que a Marinha do Brasil tem como objetivo estratégico a defesa proativa das plataformas petrolíferas. Com base nisso, a pesquisa é dividida em seis métodos: (M1) reprodução de resultados da referência (FALQUETO *et al.*, 2019); (M2) análise de sensibilidade dos classificadores; (M3) redução da dimensionalidade dos atributos a partir da técnica PCA; (M4) ampliação do *data set* de treinamento com concatenação total das amostras de polarização VH e VV; (M5) ampliação do *data set* de treinamento com concatenação de metade das amostras de polarização VH e VV e por fim, (M6) combinação dos resultados de classificadores utilizando a técnica *stacked generalization*. A seguir apresentam-se os objetivos gerais e específicos para cumprir cada um dos métodos.

1.4.1 Objetivos Gerais

Para alcançar os métodos listados anteriormente, foram definidos objetivos gerais e objetivos específicos descritos a seguir.

- Reproduzir os resultados obtidos por (FALQUETO *et al.*, 2019);
- Modificar os parâmetros dos classificadores e avaliar os resultados;
- Aplicar combinação de técnicas e avaliar os resultados;
- Realizar análise estatística para validação dos resultados.

1.4.2 Objetivos Específicos

Para atingir os objetivos gerais, a seguir são elencados os objetivos específicos.

1.4.2.1 Reprodução dos Resultados de (FALQUETO *et al.*, 2019)

- Dividir as amostras considerando 80% para treinamento e 20% para teste;
- Criar de forma aleatória cinquenta grupos para classificação para treinamento e teste;
- Realizar a classificação dos alvos em imagens SAR com polarizações VH e VV usando as técnicas de ML (LR, SVM, RF, NB, kNN, DT) com parâmetros na condição *default*;
- Realizar cinquenta classificações considerando os indicadores área abaixo da curva (AUC , *area under the curve*), classificação de acurácia (Acc, *accuracy*), F1 *Score*, *Precision* e *Recall*;
- Calcular as médias das classificações;
- Analisar o nível de significância entre os resultados das classificações por meio de testes estatísticos.

1.4.2.2 Otimização de Parâmetros dos Classificadores

- Incluir as técnicas ADBST e NET;
- Criar de forma aleatória cinquenta grupos de amostras através de técnica (*bootstrap*) e salvar cada grupo para garantir a reprodutibilidade dos resultados;
- Realizar a classificação dos alvos nas imagens SAR com polarizações VH e VV usando as técnicas de ML (LR, SVM, RF, NB, kNN, DT, ADBST e NET) com variação dos parâmetros, buscando ajustar os hiperparâmetros dos classificadores.

1.4.2.3 Combinação de Técnicas

- Avaliar técnica de redução de dimensionalidade PCA;
- Aplicar método de concatenação para ampliar os *data sets* de treinamento;
- Considerar *stacking generalization* para combinar os melhores resultados entre os classificadores.

1.5 Principais Contribuições dessa Pesquisa de Mestrado

- Utilizar técnicas de inteligência artificial consideradas estado da arte para extração de atributos e classificação de alvos em imagens SAR;
- Utilizar imagens SAR polarimétricas de sistemas satelitais disponíveis gratuitamente em repositórios na internet;
- Utilizar softwares livres para o desenvolvimento dos métodos propostos;
- Elaborar um conjunto fixo de 50 *data sets* de treinamento e teste utilizando técnica de *bootstrap* para validação cruzada dos resultados;
- Utilizar métodos estatísticos para comprovação de diferença significativa entre os resultados obtidos e os resultados de referência.

1.6 Organização da Dissertação

Este trabalho está organizado da seguinte forma: O Capítulo 1 - Introdução - descreve a contextualização da pesquisa e o estado da arte na classificação de alvos em imagens SAR com técnicas de ML e DL; O Capítulo 2 - Materiais e Métodos - descreve a missão Sentinel-1, o processo de formação da imagem SAR, os métodos e técnicas de classificação; O Capítulo 3 - Análise Numérica e Discussões - apresenta a média das cinquenta classificações nos seis métodos de análise, as análises estatísticas com teste de normalidade *Shapiro-Wilk* e teste não paramétrico de comparações múltiplas *Kruskal-Wallis*; além disso, são feitas as discussões sobre os resultados atingidos; Finalmente, o documento é encerrado com o Capítulo 4 - Conclusões, Trabalhos Apresentados e Trabalhos Futuros.

1.7 Conclusão

Neste capítulo contextualizou-se a aplicação de imagens SAR no sensoriamento remoto terrestre em diversas áreas, destacando a vigilância marítima para proteção da Amazônia Azul. Duas classes de alvos são de interesse na pesquisa, plataformas de petróleo e navios. Para automatizar o reconhecimento das imagens (SAR-ATR), destacou-se a aplicação de técnicas clássicas de ML e técnicas híbridas para classificação das imagens. Como base de referência para avaliação dos classificadores, utilizou-se o trabalho de (FALQUETO *et al.*, 2019). Para isso, foram definidos objetivos gerais e específicos. O Capítulo 2 detalha as técnicas utilizadas e a metodologia aplicada para atingir os objetivos.

2 Materiais e Métodos

Este capítulo apresenta os materiais e métodos utilizados no desenvolvimento desta pesquisa. Esta Seção é dividida em cinco Subseções. A Seção 2.1 exhibe as características da missão Sentinel-1, os produtos gerados por ela e o processo de formação das imagens SAR; a Seção 2.2 apresenta a área marítima de interesse e plataformas petrolíferas; a Seção 2.3 mostra uma breve revisão teórica sobre *Machine Learning* e *Deep Learning*, sendo dividida em quatro Subseções: a Subseção 2.3.1 apresenta medidas de avaliação de desempenho; a Subseção 2.3.2 técnicas de classificação; a Subseção 2.3.3 mostra a técnica de redução de dimensionalidade por PCA, métodos de combinação de classificadores (*ensembles methods*); a Seção 2.4 descreve a metodologia empregada na pesquisa; O capítulo é finalizado com a Seção 2.5 a qual faz as considerações finais/resumo do capítulo.

2.1 Missão Sentinel-1

O projeto Sentinel-1 foi motivado pela necessidade de continuação do fornecimento de dados das classes ERS/Envsat com melhor revisão, cobertura, periodicidade e confiabilidade do serviço (SNOEIJ *et al.*, 2009). O principal objetivo da operação do Sentinel é fornecer informações confiáveis aos usuários do Copernicus (POTIN *et al.*, 2019) que é um sistema de observação de dados terrestres e seus ecossistemas (GEUDTNER *et al.*, 2021). A missão Sentinel-1 é formada por uma constelação de dois satélites (TORRES *et al.*, 2012). Em 3 de abril de 2014, foi lançado o Sentinel-1A, e em 25 de abril de 2016, foi o lançado o Sentinel-1B. Os dois satélites fazem parte do sistema Sentinel-1 e estão em órbita quase polar, sincronizada com o sol, operando dia e noite, com ciclo de repetição de 12 dias e altitude de aproximadamente 693 km, produzindo imagens SAR na banda C (POTIN *et al.*, 2019; GEUDTNER *et al.*, 2021; European Space Agency, 2022).

O sistema orbital, que é apresentado na Figura 2.1, possui um sensor SAR capaz de gerar medições em média e alta resolução (European Space Agency, 2022). Na Tabela 2.1 são apresentadas algumas características do sistema Sentinel-1 (European Space Agency, 2022). Como por exemplo, consideram-se a banda de operação, largura de banda, tamanho da antena, peso da antena, frequência de repetição dos pulsos e massa total.



FIGURA 2.1 – Modelo ilustrativo do sistema Sentinel-1. Imagem extraída de (European Space Agency, 2022).

2.1.1 Produtos e Algoritmos

O feixe da antena do radar Sentinel-1 ilumina o solo do lado direito do satélite. Cada elemento-alvo permanece dentro do feixe de iluminação por um curto período de tempo, devido ao movimento do satélite e a largura do feixe ao longo da trilha (azimute) da antena (European Space Agency, 2022). De acordo com (European Space Agency, 2022), o Sentinel-1 pode adquirir os dados em quatro modos descritos a seguir e na Figura 2.2.

- *Stripmap* (SM): Este é um modo de imagem de mapa de faixa SAR padrão. A faixa do solo é iluminada por uma sequência contínua de pulsos e com feixe da antena apontado para um azimute e ângulo de elevação fixos.
- *Interferometric Wide swath* (IW): Os dados são adquiridos em três faixas usando a técnica de imagem *Terrain Observation With Progressive Scanning* SAR (TOPSAR).
- *Extra Wide swath* (EW): Os dados são gerados em cinco faixas usando a técnica de imagem TOPSAR. O modo EW proporciona uma cobertura de faixa muito grande à custa da resolução espacial.
- *Waver* (WV): Os dados são obtidos em pequenas cenas de *stripmap* chamadas “vignettes”, situadas em intervalos regulares de 100 km ao longo da faixa.

O sistema Sentinel-1 suporta operações com polarização simples (HH ou VV) e dupla polarização (HH + HV ou VV + VH), implementada por uma cadeia de transmissão (comutável entre H ou V) e duas cadeias paralelas de recepção para polarização H e V. Por outro lado, os produtos SM, IW e EW estão disponíveis com polarização simples ou duplas. O produto WV está disponível apenas com polarização simples (European Space Agency, 2022).

TABELA 2.1 – Parâmetros e característica do sistema Sentinel-1

| | |
|---|------------------------------------|
| Nome | Sentinel-1 |
| Banda | C |
| Largura de banda | 0-100 MHz (programável) |
| Frequência central | 5,405 GHz |
| Capacidade armazenamento | 1410 Gb |
| Polarização | HH+HV,VV+VH VV, HH |
| Ângulo de incidência | 20° - 46° |
| Direção de look | direita |
| Tipo de antena | <i>Slotted waveguide radiators</i> |
| Tamanho da antena | 12.3 m × 0.821 m |
| Peso da antena | 880 kg |
| Largura do feixe de azimute | 0.23° |
| PRF (Frequencia de repetição de pulsos) | 1- 3 kHz (programável) |
| Aquisição de dados | 10 bit |
| Massa total (incluindo antena) | 945 kg |

Fonte: (European Space Agency, 2022).

2.2 Sensoriamento Remoto por Imagens de Radar

O sensoriamento remoto é uma técnica para detecção, identificação e classificação de objetos através do uso de sensores para coleta de informações físicas desses alvos. Estudos mais recentes mostram que os sensores ativos (que emitem sinais e recebem os ecos desses sinais) estão com maior capacidade de resolução e gerando imagens com diferentes frequências, polarizações, resoluções (NATH *et al.*, 2014). Alguns tipos de sensores ativos são: detector de faixa de rádio (RADAR, *Radion Detection and Range*), SAR e detector de faixa de luz (LIDAR, *Light Detection and Range*)(YAMAGUCHI, 2020).

2.3 Propriedades de Imagens SAR

A polarização de uma onda eletromagnética é descrita em termos do vetor campo elétrico (E) e refere-se a localização desse vetor no plano perpendicular a direção de propagação. O estado de polarização de uma onda arbitrária é normalmente descrito pelo vetor campo elétrico e em termos de base de polarização padrão, consistindo em polarizações lineares horizontal (H) e vertical (V) (CRISP, 2004), da seguinte forma:

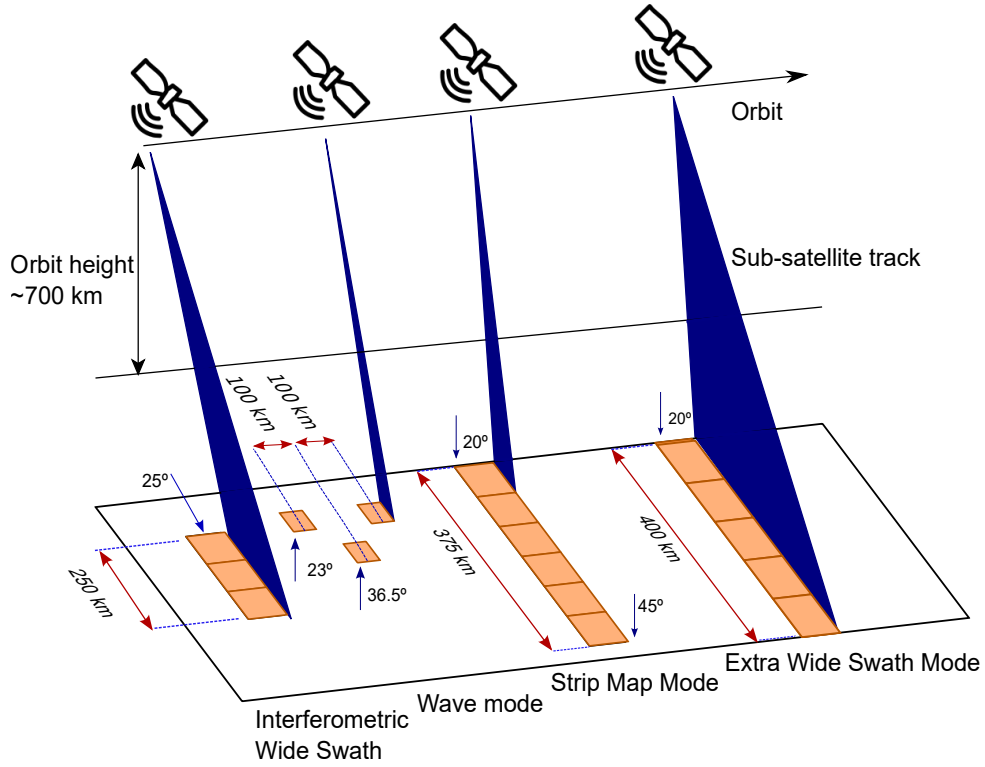


FIGURA 2.2 – Modos de aquisição de dados a partir do imageamento do Sentinel-1 durante o seu deslocamento (European Space Agency, 2022)

$$E = E_h \hat{h} + E_v \hat{v}, \quad (2.1)$$

em que, \hat{h} e \hat{v} são os vetores nas direções horizontal e vertical, respectivamente. Em particular, se a onda incidente for $E_i = E_h^i \hat{h} + E_v^i \hat{v}$ e a onda espalhada $E_s = E_h^s \hat{h} + E_v^s \hat{v}$ observada a uma distância R do espalhador, deriva-se

$$\begin{pmatrix} E_h^s \\ E_v^s \end{pmatrix} = \frac{e^{(i2\pi.R/\lambda)}}{R} \begin{pmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{pmatrix} \begin{pmatrix} E_h^i \\ E_v^i \end{pmatrix}, \quad (2.2)$$

sendo λ o comprimento de onda. Os termos S_{HH} , S_{HV} , S_{VH} e S_{VV} referem-se as amplitudes de espalhamento complexas ou refletividades complexas. As refletividades complexas incorporam informações de fase e amplitude. A partir de (2.2), conclui-se que a matriz de espalhamento definida como

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix}, \quad (2.3)$$

possui todas as informações para calcular a refletividade complexa para qualquer par de combinações de polarização de transmissão/recepção.

Levando-se em consideração a relação entre potência de onda radar e sua força de campo elétrico, a seção reta radar (RCS, radar cross section) do alvo é dada por

$$\sigma_{PQ} = 4\pi |S_{PQ}|^2, \quad (2.4)$$

em que S_{PQ} é a refletividade complexa para a combinação de polarizações transmitidas e recebidas especificadas por P e Q. Cada elemento da matriz de espalhamento é um número complexo que é determinado pela forma do alvo, tamanho, orientação, permissividade e frequência do radar (LOS *et al.*, 2019).

O processo de geração de imagens SAR é feito através da emissão de microondas por sistema orbital/aerotransportado e posterior recepção da onda refletida. As imagens SAR apresentam um padrão aleatório de pixels escuros e claros, chamado *speckle*, causado por interferências nas ondas recebidas pelo sensor que podem seguir caminhos diferentes (multi-caminhos) para a zona correspondente ao mesmo pixel (CANTORNA *et al.*, 2019). O *speckle* é gerado pela presença de múltiplos espalhadores elementares com uma distribuição aleatória dentro de uma célula de resolução. A soma coerente das suas amplitudes e fases resultam em fortes flutuações do *backscattering* de célula de resolução para célula de resolução (MOREIRA *et al.*, 2013). A redução do *speckle* é importante para interpretações da imagem SAR. Alguns métodos que podem atenuar o ruído *speckle* são: processamento *multilook* e algoritmos de processamento de filtragem (HUANG *et al.*, 2009). O *backscattering* (ou *backscatter*) é a reflexão das ondas, partículas ou sinais de retorno para a direção de origem, sendo um fenômeno no qual a radiação ou partículas são espalhados em ângulos maiores que 90° , em relação à direção original do movimento (USOWICZ, 2011).

2.4 Localização da Área Marítima de Interesse e Plataformas Petrolíferas

O local de estudos é a bacia de Campos, localizada no litoral norte do Rio de Janeiro, entre as cidades de Vitória/ES e Cabo Frio/RJ, conforme exibido na Figura 2.3. Ela abrange uma área de 120.000 km² (ARMELENTI *et al.*, 2016) e destaca-se na produção nacional de petróleo e gás natural como sendo uma das maiores bacias produtoras. De acordo com o Boletim Mensal n° 131 (AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS. (Brasil), 2021a), a produção marítima de petróleo corresponde a 97,1% e de gás natural corresponde a 82,5%. Dessa produção, a Bacia de Campos é responsável por 23,74% da produção nacional de petróleo e gás natural, ficando atrás apenas da Bacia de Santos com 69,07% da produção nacional petróleo e gás natural. O petróleo e gás são produzidos e extraídos do mar com auxílio de plataformas petrolíferas.

Elas têm por finalidade perfuração (*drilling*) ou produção (*production*), armazenamento de hidrocarbonetos (*storage*) ou outras atividades de apoio à produção *offshore*. Quanto a estrutura as plataformas podem ser fixas (*jacket*), flutuantes (*floating*) ou autoelevatórias (*jack-up*) (MORAIS, 2013). A Figura 2.4 ilustra os sistemas para extração de petróleo e gás em águas profundas. A seguir detalha-se a descrição dos tipos de plataformas.

A Figura 2.5 apresenta uma comparação entre a imagem óptica e sua respectiva imagem SAR com plataformas *Floating Production Storage and Offloading* (FPSO) P-58, *Floating and Production Unit* (FPU) P-53 e Semissubmersível (SS) P-56 que compõem o *data set*. Essas imagens tiveram como base o produto GRD (*Ground Range Detected*), modo IW (*Interferometric Wide Swath Mode*), resolução espacial - *High Resolution* (HR), $(20\text{ m} \times 22\text{ m})$ (*range* \times *azimuth*), *pixel spacing* - $(10\text{ m} \times 10\text{ m})$ (*range* \times *azimuth*), *number of looks* - (5×1) (*range* \times *azimuth*), *equivalent number of looks* (ENL) - 4.4 (SCHUBERT *et al.*, 2015).

- Fixas: feitas de aço ou concreto, ou combinando estrutura de concreto e convés (deck) de aço. São construídas para lâmina de água de 200 a 300 metros de profundidade, mas há plataformas mais altas, como a maior do mundo, Bullwinkle, construída a 412 metros dentro de águas marítimas e localizada no Green Canyon no Golfo do México;
- Semissubmersível (*Semi-submersible Floating Production Unit* - SS-FPU): utilizada na produção de hidrocarbonetos e em perfurações. Tem sua estrutura, de um ou mais conveses, apoiada sobre colunas, que se apoiam sobre fluadores submersos;
- Navio plataforma FPSO (*Floating, Production, Storage and Offloading*): construída a partir da adaptação de casco de navio petroleiro ou da construção de casco de navio novo. Tem função de produção, armazenamento e transbordo de petróleo e gás natural;
- *Tension Leg Platform* (TLP): plataforma de perfuração e produção, apoiada em um sistema de boias para flutuação, ancorada verticalmente no fundo do mar por tendões, isto é, cabos entrelaçados de aço tensionados;
- *Tension Leg Wellhead Platform* (TLWP): uma variação da TLP que permite a adaptação da cabeça de poço (*wellhead*) às condições do local de produção, ou seja, completação seca. É utilizada na produção de petróleo e gás;
- *Spar*: consiste em uma estrutura cilíndrica vertical flutuante, construída em aço, de largo diâmetro, ancorada no fundo do mar por um sistema de cabos tensionados *taut leg*;

- Autoelevável ou *Jack-up*: equipada com estruturas de apoio (*rig legs*). Destina-se a perfuração de poços de petróleo em águas rasas, com até 130 metros de lâmina d'água e que podem alcançar 170 metros.

A Tabela 2.2 apresenta o histórico da produção de petróleo no Brasil.

TABELA 2.2 – Alguns fatos históricos da produção de petróleo no Brasil.

| Período | Fato histórico |
|--------------------|--|
| 1953 | Criação da Petróleo Brasileiro S.A (Petrobrás) pela lei 2004 de 03 de outubro de 1953. |
| 1954 | Implementação operacional da Petrobrás. |
| 1963 | Descoberta do campo de Carmópolis. Na época um dos maiores campos com mais de 1 bilhão de barris de petróleo <i>in place</i> . |
| 1966 | Construção da plataforma de perfuração Petrobrás I, para operar em cotas batimétricas de até 30 m. |
| 1968 | Descoberta do Campo de Guaricema. |
| 1970 | Início das atividades exploratórias na plataforma continental da Bacia do Foz Amazonas. |
| 1974 | Primeira grande descoberta de petróleo na plataforma continental que foi o Campo Garoupa, em carbonatos albianos da Bacia de Campos. |
| | Ocorre o segundo choque do petróleo com o preço do barril chegando a US\$30,00. |
| 1979 | As reservas somam-se 2.7 bilhões de barris de óleo equivalente, principalmente em função da bacia de Campos. |
| 1981 | Descobertos na bacia Potiguar os campos Fazenda Belém, Alto do Rodrigues e Estreito. |
| Década de 80 | Primeira descoberta significativa na Amazônia com o Campo de Juruá |
| Meados dos anos 80 | Primeiras descobertas de petróleo em águas profundas na Bacia de Campos. |
| 1984 | A produção chega a 500.000 barris por dia. |
| 1996 | Última grande descoberta, ainda como estatal, o Campo de Roncador. |
| 1997 | A Petrobrás deixa de atuar com exclusividade no segmento de exploração. |
| 2003 | A produção chega a atingir 12,6 bilhões de barris de óleo-equivalente. |

Fonte: (MENDONÇA *et al.*, 2003)

2.5 Classificação baseada em aprendizado supervisionado

ML ou aprendizado de máquina nasceu na década de 60 como um campo da inteligência artificial que tinha como objetivo aprender padrões com base em dados (IZBICKI; SANTOS, 2020). Ele engloba um rico conjunto de algoritmos de aprendizagem a partir de dados com ênfase em reconhecimento de padrões e aprendizagem estatística, com os quais é possível fazer previsões com base em observações do passado. Em especial o aprendizado

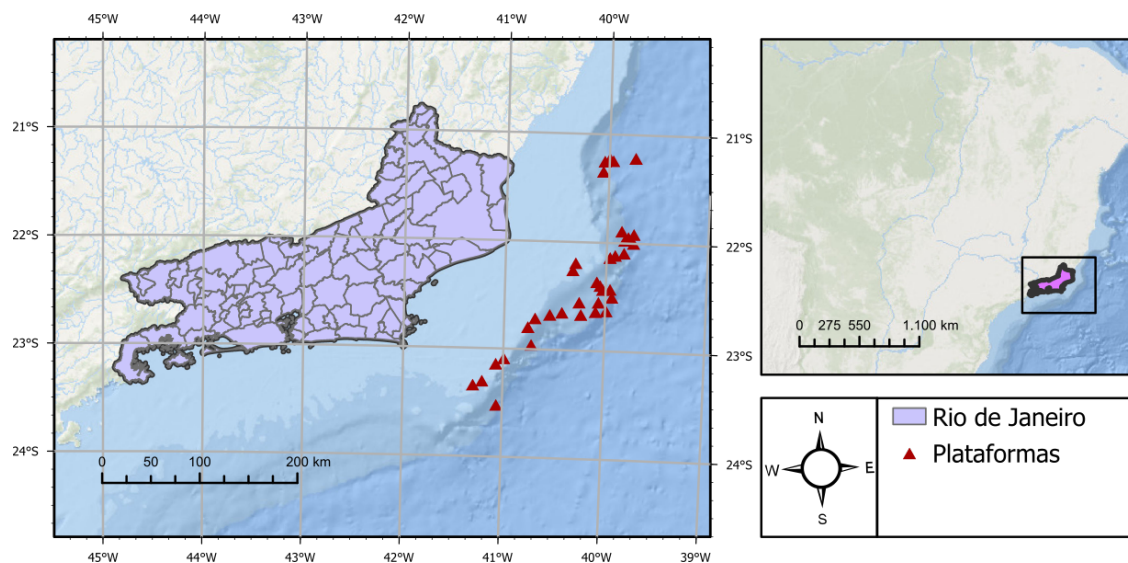


FIGURA 2.3 – Localização plataformas de petróleo na bacia de Campos/RJ.




FIGURA 2.4 – Tipos de plataformas petrolíferas marítimas. Imagem extraída de (MORAIS, 2013).

supervisionado está relacionado ao aprendizado e previsões a partir de dados da variável resposta que estão rotulados (IZBICKI; SANTOS, 2020). Baseado na observação, o foco do aprendizado supervisionado é o reconhecimento de relações funcionais entre padrões, onde etiquetas são utilizadas para treinar os modelos (KRAMER, 2016).

A classificação supervisionada tem a vantagem do operador poder detectar um erro e corrigí-lo. Uma desvantagem é o custo e tempo de processamento (NATH *et al.*, 2014). A classificação não supervisionada tem a vantagem de não haver necessidade de ação humana e não há necessidade de conhecimento prévio dos dados.

2.5.1 Medidas de avaliação de desempenho

Uma das formas de visualizar o desempenho de um modelo de classificação é através da matriz de confusão. Ela é uma tabulação cruzada das classes dos dados observados

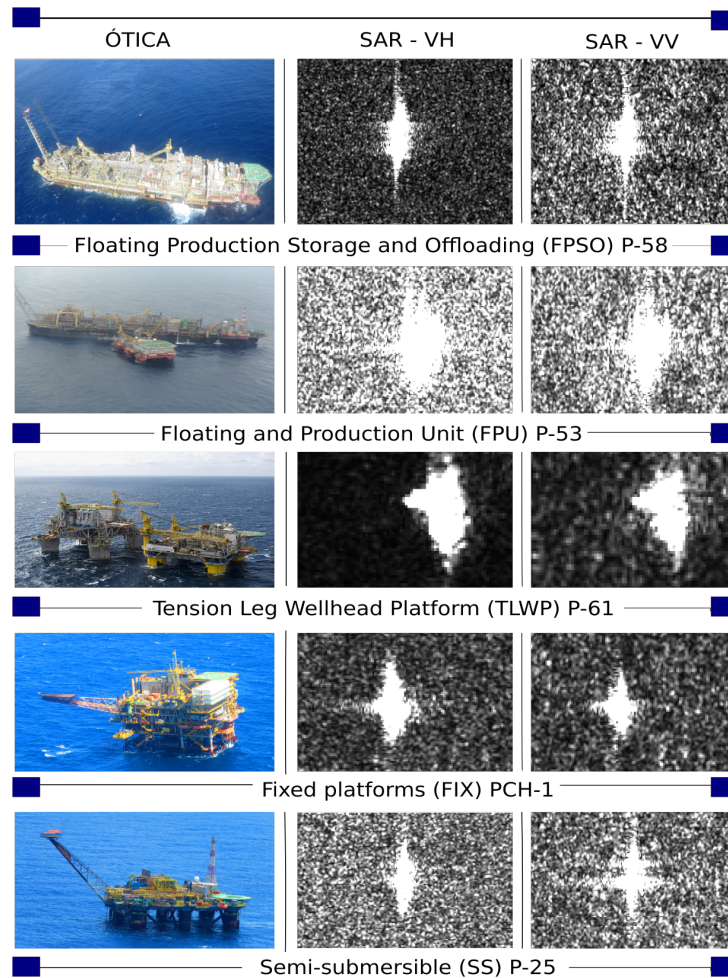


FIGURA 2.5 – Comparação da imagens ópticas de plataformas de petróleo e suas respectivas imagens SAR com as seguintes características banda C, resolução espacial - *High Resolution* (HR), $(20\text{ m} \times 22\text{ m})$ (*range* \times *azimuth*), polarizações VH e VV. Imagens ópticas e SAR extraídas de (MARINHA DO BRASIL. Diretoria de Portos e Costas., 2021; FALQUETO *et al.*, 2019), respectivamente.

e previstos. Nas células da diagonal estão as classes corretamente previstas enquanto nas outras células estão os erros para cada caso (KUHN *et al.*, 2013). Em nossa pesquisa utiliza-se a classificação supervisionada. Com isso, dentre as classes são estabelecidos os alvos de interesse. A partir da matriz de confusão são definidos os indicadores listados a seguir (FALQUETO *et al.*, 2019).

- AUC: área formada abaixo da curva ROC. Quanto maior a área, melhor o classificador;
- Acc: representa a acurácia global. Proporção de amostras corretamente classificadas perante o número total de amostras em um teste;
- *F1 Score*: mede a relação entre as amostras definidas como alvos corretamente classificadas com a média aritmética do total de amostras classificadas somadas ao

total de amostras que verdadeiramente são alvos;

- *Precision*: taxa de alvos corretamente classificados sobre a soma das amostras classificadas como alvos;
- *Recall*: também conhecida como *Sensitivity* ou *true positive rate*. É a proporção de alvos corretamente classificados sobre o total de alvos presentes no teste.

2.5.2 Algoritmos classificadores

Um classificador é uma função f que mapeia os vetores de entrada de atributos $\mathbf{x} \in \chi$ para as etiquetas de classe de saída $y \in \{1, \dots, C\}$, onde χ é o espaço de atributos e C é o total de classes. Assumi-se que $\chi = \mathbb{R}^d$ ou $\chi = \{0, 1\}^d$, ou seja, que o vetor de atributos é um vetor de d números reais ou d bits binários. Porém, pode-se também combinar atributos discretos e contínuos (MURPHY *et al.*, 2006). Classificação é um dos tópicos mais importantes em mineração de dados, principalmente em grandes volumes de dados (*big data*). A principal tarefa da classificação é prever as etiquetas dos dados de teste com base nos dados de treinamento (ZHANG *et al.*, 2017).

2.5.2.1 Support Vector Machine

É uma metodologia proposta por Cortes e Vapnik (1995) de aprendizado supervisionado usado para classificação, regressão e detecção de *outliers*. No SVM as probabilidades $\mathbb{P}(Y = c|\mathbf{x})$ não são estimadas; o resultado dessa técnica indica as classes estimadas de novas observações. Levando-se em conta que Y assume valores em $C = \{-1, 1\}$ (IZBICKI; SANTOS, 2020). Considerando a função linear

$$f(\mathbf{x}) := \beta_0 + \beta_1 x_1 + \dots + \beta_d x_d, \quad (2.5)$$

o classificador $g(\mathbf{x})$ dado pelo SVM é definido da seguinte forma:

$$g(\mathbf{x}) = \begin{cases} \text{Se } f(\mathbf{x}) < 0, & g(\mathbf{x}) = -1 \\ \text{Se } f(\mathbf{x}) \geq 0, & g(\mathbf{x}) = 1 \end{cases}$$

Para construir $f(\mathbf{x})$, supõe-se que as observações sejam linearmente separáveis, ou seja, existe um hiperplano que separa todas as observações do conjunto de treinamento de acordo com a classe, conforme Figura 2.6. Nesse caso, existe $f(\mathbf{x})$ linear tal que $f(\mathbf{x}_i) < 0$ se, e só se, $y_i = -1$. Assim, pode-se escrever para todo $i = 1, \dots, n$,

$$y_i(\beta_0 + \beta_1 x_{i,1} + \dots + \beta_d x_{i,d}) = y_i f(\mathbf{x}_i) > 0. \quad (2.6)$$




FIGURA 2.6 – Separação de dados por hiperplano

Quando há um grande número de hiperplanos separando perfeitamente os dados, o SVM busca por aquele com maior margem, ou seja, aquele mais distante de todos os pontos observados. Isso pode ser visto na Figura 2.7. Os pontos utilizados para definir as margens são chamados vetores de suporte (IZBICKI; SANTOS, 2020).

Havendo um hiperplano que separa bem os dados, busca-se o hiperplano com coeficientes β , tais que $\beta = \arg \max_{\beta} M$

sujeito às restrições a seguir:

1. $\sum_{i=1}^d \beta_i^2 = 1$;
2. $y_i f_{\beta}(\mathbf{x}_i) \geq M$, para todo $i = 1, \dots, n$,

A restrição 1 garante a comparação dos diferentes hiperplanos em termos de sua norma e com essa restrição é possível mostrar que $|f(\mathbf{x})| = y_i f(\mathbf{x}_i)$.




FIGURA 2.7 – Aplicação do SVM indicando os vetores de suporte e margem. Os pontos delimitando as margens são os vetores de suporte e separam os dois conjuntos de dados.

2.5.2.2 Decision Tree

A Árvore de Decisão é método não paramétrico de aprendizado supervisionado usado para classificação e regressão (QUINLAN, 1993). Uma árvore é construída por particionamento recursivos no espaço de covariáveis. O particionamento recebe o nome de nó e

o resultado recebe o nome de folha (IZBICKI; SANTOS, 2020), como apresentado na Figura 2.8. As árvores aprendem a se aproximar de uma curva senoidal com um conjunto de regras de decisão. Elas são, então, visualizadas através de gráfico, o que facilita sua interpretação. Além disso, requerem pouca preparação das informações e são capazes de lidar com dados numéricos e categóricos, porém podem apresentar instabilidade devido a pequenas variações nos dados que podem causar alterações na árvore (FRIEDMAN *et al.*, 2001; BREIMAN *et al.*, 1984).




FIGURA 2.8 – Diagrama árvore de decisão.

Uma árvore de decisão cria uma partição do espaço das covariáveis em regiões distintas e disjuntas: R_1, R_2, \dots, R_j , que representam as divisões da árvore e j é o total de divisões. A predição para resposta Y de uma observação de covariáveis x que estão em R_k é dada por (IZBICKI; SANTOS, 2020)

$$g(x) = \text{moda} \{y_i : \mathbf{x}_i \in R_k\}. \quad (2.7)$$

Além disso, o critério para buscar a melhor partição em cada processo é o índice de Gini, definido como

$$\sum_R \sum_{c \in C} \hat{P}_{R,c} (1 - \hat{P}_{R,c}), \quad (2.8)$$

em que R representa uma das regiões induzidas pela árvore e $\hat{P}_{R,c}$ é a proporção de observações categorizadas em c entre as que caem na região R . Este índice é mínimo quando todas as proporções $\hat{P}_{R,c}$ são zero ou um, indicando uma árvore “pura” com cada folha possuindo apenas observações de uma mesma classe (IZBICKI; SANTOS, 2020).

2.5.2.3 *Random Forest*

Random Forest é uma técnica de aprendizagem em conjunto (*ensemble*). É um híbrido do algoritmo de *bagging* e o método do subespaço aleatório usando árvores de decisão como a base do classificador (SAMMUT; WEBB, 2010). Em outras palavras, RF são combinações de preditores de árvores, sendo que cada árvore depende dos valores de um vetor aleatório amostrado de forma independente e com a mesma distribuição para todas as árvores na floresta (BREIMAN, 2001). Os algoritmos RF são técnicas de perturbação e combinação

baseadas em árvores de decisão aleatórias (BREIMAN, 1998). Eles são projetados especificamente para árvores. Ou seja, um conjunto diversificado de classificadores é criado pela introdução da aleatoriedade na construção do classificador. A predição do conjunto é dado pela média das predições individuais dos classificadores. No RF cada árvore é construída a partir de uma amostra retirada com substituição do conjunto de treinamento. Além disso, ao dividir cada nó durante a construção de uma árvore, a melhor divisão é encontrada em todos os recursos de entrada ou em um subconjunto aleatório. O objetivo da aleatoriedade é diminuir a variância do estimador florestal. As árvores de decisão individuais possuem alta variância e tendem a se ajustar demais. A aleatoriedade injetada nas florestas produz árvores de decisão com erros de previsão e ao tirar a média das previsões, alguns erros podem ser cancelados. Assim, as RF alcançam uma variação reduzida combinando diversas árvores, podendo haver um pequeno aumento no viés. A redução da variância é frequentemente significativa e resulta num modelo melhor. Um classificador RF consiste em um conjunto de classificadores de árvores estruturadas h , definido por $\{h(\mathbf{x}, \Theta_k, k = 1, \dots)\}$, em que $\{\Theta_k\}$ são vetores aleatórios independentes distribuídos de forma idêntica e cada árvore lança um voto unitário para cada classe mais popular na entrada x (BREIMAN, 2001). O aumento do número de árvores pode produzir melhores resultados de acurácia, e limitar o erro de generalização (BREIMAN, 2001).

2.5.2.4 Naive Bayes

Naive Bayes é um dos mais eficientes e eficazes algoritmos utilizados em ML, reconhecimento de padrões, classificação e mineração de dados (ZHANG, 2004). A Figura 2.9 apresenta um modelo. Ele tem como base o teorema de probabilidade de Bayes (YAN *et al.*, 2016; LANGLEY *et al.*, 1992), considerando \mathbf{x} um vetor de covariáveis contínuas, c a categoria de classes, Y a resposta de uma observação, se tem a seguinte equação (LEWIS, 1998) (IZBICKI; SANTOS, 2020)

$$\mathbb{P}(Y = c|\mathbf{x}) = \frac{f(\mathbf{x}|Y = c)\mathbb{P}(Y = c)}{\sum_{s \in C} f(\mathbf{x}|Y = s)\mathbb{P}(Y = s)}, \quad (2.9)$$

em que a estimativa de $\mathbb{P}(Y = c|\mathbf{x})$ pode ser obtida a partir das probabilidades marginais $\mathbb{P}(Y = s)$ e as densidades condicionais $f(\mathbf{x}|Y = s)$ para cada $s \in C$.

Utilizando-se as proporções amostrais de cada classe, o termo $\mathbb{P}(Y = s)$ pode ser estimado. Todavia, para estimar $f(\mathbf{x}|Y = s)$, é necessário assumir um modelo para as covariáveis. O NB assume que, para todo $s \in C$, $f(x|Y = s)$ pode ser fatorado da seguinte forma

$$f(\mathbf{x}|Y = s) = f((x_1, \dots, x_d)|Y = s) = \prod_{j=1}^d f(x_j|Y = s), \quad (2.10)$$

em que cada $f(x_j|Y = s)$ pode ser estimado, assumindo

$$X_j|Y = s \sim N(\mu_{j,s}, \sigma_{j,s}^2), j = 1, \dots, d, \quad (2.11)$$

ou seja, cada distribuição do vetor \mathbf{x} tem distribuição normal com parâmetros que dependem da classe e da componente. Os parâmetros podem ser estimado por máxima verossimilhança da seguinte forma

$$\hat{\mu}_{j,s} = \frac{1}{|C_s|} \sum_{k \in C_s} X_{j,k}, \quad (2.12)$$

$$\hat{\sigma}_{j,s}^2 = \frac{1}{|C_s|} \sum_{k \in C_s} (X_{j,k} - \hat{\mu}_{j,s})^2, \quad (2.13)$$

em que $C_s = \{j : Y_j = s\}$ forma o conjunto de todas as observações de treinamento da classe s . O estimador para densidade condicional $f(x|Y = c)$ é dado por

$$\hat{f}(x|Y = c) = \prod_{k=1}^d \hat{f}(x_k|Y = c) = \prod_{k=1}^d \frac{1}{\sqrt{2\pi\hat{\sigma}_{k,c}^2}} e^{-\left(\frac{x_k - \hat{\mu}_{k,c}}{2\hat{\sigma}_{k,c}^2}\right)^2}. \quad (2.14)$$

Além da distribuição normal, outras distribuições podem ser utilizadas e outros métodos de estimação, além do máxima verossimilhança podem ser considerados, como nos métodos não-paramétricos.




FIGURA 2.9 – Diagrama *Naive Bayes*.

2.5.2.5 *k Nearest Neighbor*

k-Nearest-Neighbours é um método de classificação não paramétrico que é simples e efetivo em muitos casos (GUO *et al.*, 2003). Ao longo das últimas décadas, uma grande diversidade de classificadores têm sido desenvolvidos para aplicações reais. O kNN está entre os dez principais algoritmos de mineração de dados, devido a sua simplicidade e eficiência (ZHANG *et al.*, 2017) (WU *et al.*, 2008). A ideia principal de um método kNN é prever a etiqueta de um ponto do dado de teste pela regra da maioria, ou seja, o rótulo do dado de teste é previsto com a classe principal com os seus k pontos de dados de formação

mais semelhantes no espaço de atributos (ZHANG *et al.*, 2017).

Ao aplicar o kNN é necessário escolher um valor de k adequado. A escolha apropriada de k irá afetar no resultado da classificação. Uma forma simples de escolher k é carregar o algoritmo diversas vezes com diferentes valores de k e escolher o que apresentar melhor resultado (GUO *et al.*, 2003). O kNN encontra um grupo de k objetos em um conjunto de treino que está mais próximo do objeto de teste, e baseia a associação de um rótulo na predominância de uma classe particular nesta vizinhança. Há três elementos chaves nesta abordagem: (1) o conjunto de objetos etiquetados, por exemplos, a distância ou similaridade métrica para computar a distância entre dois objetos; (2) o valor de k ; (3) o número de vizinhos próximos. Para isso, classificar um objeto não etiquetado, a distância deste objeto para o objeto etiquetado é calculada, seus k vizinhos mais próximos são identificados, a etiqueta da classe do vizinho mais próximo é usada para determinar a classe deste objeto.

Dado um conjunto de treino D e um objeto de teste $x = (\mathbf{x}', y')$, em que \mathbf{x}' são os atributos de teste, y' variável resposta do conjunto de testes. O algoritmo computa a distância (ou similaridade), entre z e todos os objetos de treino $(\mathbf{x}, y) \in D$ para determinar a lista D_z de vizinhos próximos, sendo, x os atributos do conjunto de treinamento e y a variável resposta do conjunto de treinamento. Obtida a lista de vizinhos mais próximos, o objeto de teste é classificado com base na maioria das classes dos seus vizinhos mais próximos. Um dos pontos chaves no kNN é a escolha de k . Se k for pequeno, o resultado pode ser afetado pelos pontos de ruído; se k for grande, na vizinhança podem ser incluídos muitos pontos de outras classes da seguinte forma (WU *et al.*, 2008)

$$y' = \underset{\nu}{\operatorname{argmax}} \sum_{(x_i, y_i \in D_z)} I(\nu = y_i), \quad (2.15)$$

em que ν é uma etiqueta de classe, y_i é uma etiqueta de classe para um i -ésimo vizinho próximo, e $I(\cdot)$ é um indicador de função que retorna o valor 1 se o argumento é verdadeiro e 0 se for falso.

2.5.2.6 Regressão logística

A regressão logística é um modelo linear para classificação em que a função *sigmoide* logística $\sigma(x)$ definida como

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad (2.16)$$

é a base para a regressão logística. A regressão logística acrescenta uma função exponencial no início da regressão linear para limitar a saída $y_i \in [0, 1]$, desde que $y_i \in \mathbb{R}$, como na regressão linear (JOSHI, 2020). A relação entre a entrada e a saída predita para a regressão

logística pode ser expressa da seguinte forma

$$\hat{y} = \sigma \left(\sum_{j=1}^n x_{i,j} \cdot w_j + w_0 \right). \quad (2.17)$$

Como a saída é limitada ao intervalo $[0, 1]$, ela pode ser tratada como uma medida probabilística. Além disso, devido a simetria da distribuição da função logística de saída ser entre $(-\infty + \infty)$ é mais adequada para problemas de classificação. Apesar de existir na equação uma função *sigmoide* não linear, a regressão logística não pode ser confundida como método não linear de regressão. A função sigmoide é aplicada após o mapeamento linear entre entrada e saída, isso é uma variação de regressão linear (JOSHI, 2020).

2.5.2.7 Ensemble Methods

Técnicas *ensembles* são aquelas que permitem maior generalização nas classificações (WOLPERT, 1992; KUNCHEVA, 2014). Ao contrário de abordagens comuns de ML que tentam gerar um *learner* a partir de dados de treino, métodos *ensemble* tentam construir um conjunto base de *learners* e combiná-los. *Learners base* são normalmente gerados a partir de dados de treinamento por algoritmos de ML (WU *et al.*, 2008). Os métodos *ensembles* ajudam a melhorar os resultados de ML pela combinação de diversos modelos, permitindo a geração de melhores desempenhos de predição comparadas com um único modelo (VALENTINI; MASULLI, 2002). Esses métodos são meta-algoritmos que combinam técnicas de ML em um modelo preditivo para diminuir a variância (*bagging*), *bias* (*boosting*), ou melhorar predições (*stacking*) (ZHOU, 2019). *Stacking* ou *stacked generalization* é um método *ensemble* que combina modelos de base heterogêneos, dispostos em pelo menos uma camada, e depois emprega outro modelo para resumir as previsões desses modelos (CHATZIMPARMPAS *et al.*, 2020).

2.5.2.8 Adaboost

O *adaboost* é um algoritmo de impulso adaptativo proposto por Freund e Schapire. Ele é um dos mais influentes métodos *ensemble*. O algoritmo foi desenvolvido primeiramente para classificações binárias e foi eficiente para melhorar o desempenho de árvores de decisão. A partir disso, ele foi estendido para suportar múltiplas classes (JOSHI, 2020). A ideia é atribuir um peso às amostras a serem classificadas, conforme o grau de dificuldade do acerto e recompensar o classificador com base nos pesos dos acertos, não apenas na contagem (SKIENA, 2017). Para definir os pesos dos classificadores, são ajustados os pesos de formação das amostras. Amostras de formação fácil são classificadas pela maioria dos classificadores e o algoritmo continua em T rodadas, para $t = \{0, 1, \dots, T\}$. Inicialmente,

todas as amostras de treino devem ter o mesmo peso, portanto $w_i = 1/n \forall x_1, x_2, \dots, x_n$, onde n é o total de amostras. As classificações incorretas têm o peso α_t incrementado. O peso α_t do novo classificador depende da acurácia em relação ao conjunto atual de pontos medidos pela equação

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right). \quad (2.18)$$

Os pesos são normalizados, portanto $\sum_{i=1}^n w_i = 1$. Sendo assim, deve haver um classificador com erro $\epsilon_t \leq 0.5^3$. Seja $h_t(x_i)$ a classe de (-1 ou 1) predita para x_i , e y_i a classe correta, o sinal de $h_t(x_i) \times y$ reflete se as classes concordantes (positivo) ou discordantes (negativa) (SKIENA, 2017). Os pesos são ajustados como

$$w'_{i,t+1} = w_{i,t} e^{-y_i \alpha_t h_t(x_i)}, \quad (2.19)$$

antes de renormalizar todos para que continuem a somar 1,

$$C = \sum_{i=1}^n w'_{i,t+1}, \quad (2.20)$$

e

$$w_{i,t+1} = w'_{i,t+1} / C. \quad (2.21)$$

2.5.2.9 Neural Network

A rede neural é uma tecnologia muito complexa que requer grande quantidade de dados para treinamento da rede. Uma das principais utilizações das redes neurais é no agrupamento de dados em duas ou mais classes. As redes neurais podem ser treinadas com aprendizagem supervisionada, não supervisionada e aprendizagem semi-supervisionada (KRIESEL, 2007; PASCUAL, 2015; MOTIAN *et al.*, 2017. (arXiv preprint arXiv:1711.02536)). Na aprendizagem supervisionada, cada vetor de entrada de treino é emparelhado com um vetor alvo ou saída desejada, por outro lado na aprendizagem não supervisionada, a rede auto-organiza para extrair padrões de dados sem informação de destino. A aprendizagem semi-supervisionada combina as outras duas formas de treinamento. Dentre as redes supervisionadas encontra-se a *Perceptron* (PASCUAL, 2015) a qual foi introduzido por Rosenblatt como um *framework* para solução de problemas lineares (JOSHI, 2020) e exibida na Figura 2.10. A rede neural é um modelo baseado no funcionamento dos neurônios humanos, sendo um conjunto de entradas que são utilizadas para prever uma ou mais saídas (BRAMER, 2007) como pode ser visto na Figura 2.11. Um plano linear de n -dimensões é representado por um *perceptron* de camada única com mapeamento linear. No espaço n -dimensional os vetores de entrada são representados como (x_1, x_2, \dots, x_n) ou \mathbf{x} e os coeficientes ou pesos são representados como (w_1, w_2, \dots, w_n) ou \mathbf{w} . A equação de

perceptron em n-dimensões é escrita como um vetor (JOSHI, 2020) da seguinte forma:

$$\mathbf{x} \cdot \mathbf{w} = y, \quad (2.22)$$




FIGURA 2.10 – Rede neural Perceptron.




FIGURA 2.11 – Rede neural MLP.

2.5.3 *Principal Components Analysis*

Principal Components Analysis é uma técnica para redução de dimensionalidade de um conjunto de dados onde os vetores são usados para representar os dados, sendo assim é possível fazer uma representação dos dados com poucas componentes (JAMES *et al.*, 2013). A origem do conjunto de eixos é o centroide destes pontos. A PCA inicia pela identificação da direção dos pontos no projeto, assim como explica o máximo da variância. Supondo que as dimensões \mathbf{x} e \mathbf{y} são virtualmente idênticas, espera-se que a regressão linear projetará para baixo $\mathbf{y}=\mathbf{x}$ nas duas dimensões, então elas podem ser substituídas por uma única dimensão. A PCA cria novas dimensões pela combinação linear das dimensões originais. É uma técnica que identifica as dimensões ortogonais mais importantes que explicam a maior parte da variância (SKIENA, 2017). A PCA tenta encontrar as dimensões da máxima variância dos dados tentando maximizar a separação entre as classes de dados (JOSHI, 2020).

2.6 Metodologia

Nesta pesquisa são consideradas imagens SAR de média resolução do sistema Sentinel-1, algoritmos de ML para classificação de imagens e DL para extração de atributos das imagens. Essas informações são levadas em consideração para alcançar o objetivo principal do trabalho que é avaliar e comparar o desempenho dos classificadores. Para isso, o trabalho é dividido em seis métodos que são descritos na sequência a seguir, conforme metodologia apresentada nas Figuras 2.15-2.20. O desenvolvimento deste trabalho de pesquisa é realizado utilizando recursos computacionais de hardware e software descritos na Tabela 2.3.

TABELA 2.3 – Recursos computacionais de software e hardware utilizados no desenvolvimento da pesquisa.

| Categoria | Descrição | Versão | Site |
|-----------|---------------------|------------------------|---------------------------|
| | Sistema Operacional | Windows 10 | www.microsoft.com |
| Software | ML e Data Mining | Orange Canvas 3.26.0 | orangedatamining.com |
| | | Scikit-Learn 1.0.2 | scikit-learn.org/stable |
| | | Pandas 1.4.1 | pandas.pydata.org |
| | Imagens - SAR | Rstudio 1.4.1106 | www.rstudio.com |
| | | SNAP 7 | step.esa.int/main |
| | | Copernicus | scihub.copernicus.eu/dhus |
| Hardware | Notebook | Dell Vostro 5471 | www.dell.com/pt-br |
| | Memória | RAM 8GB | |
| | Processador | Intel(R) Core(TM) i7 | |
| | CPU | CPU @ 1.80GHz 1.99 GHz | |
| | Hard disk (HD) | SATA 500 GB | |

1. **Formação do *data set*:** O *data set* é formado a partir de oito imagens SAR na polarização VH e oito na polarização VV, conforme listas apresentadas na Figura 2.12 e Figura 2.13. O três *swath* do modo IW são mais destacados na polarização VH. Os alvos presentes nessas imagens são selecionados com base na geolocalização (latitude \times longitude) informada pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) (AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS. (Brasil), 2021b), Marinha do Brasil - Diretoria de Portos e Costas (MARINHA DO BRASIL. Diretoria de Portos e Costas., 2021) e *Marine Traffic* (MARINETRAFFIC, 2021). Em seguida, através do programa SNAP (Sentinel Application Platform), os *patches* dos alvos são selecionados. As Tabelas 2.4 e 2.5 apresentam a distribuição dos *patches* por tipo de alvo em cada uma das imagens SAR. Os alvos são composto por 400 imagens com polarização VH e 400 imagens na polarização VV. Há dois tipos de alvos nas imagens, plataformas e navios. Há 200 imagens (*patches*) com plataformas e 200 *patches* com navios. A Figura 2.14 exhibe a marcação de cinco

alvos nas imagens SAR 20180430 F80C nas polarizações VH e VV. Os alvos são identificados pela latitude e longitude.

- FPSO FPNT - Cidade de Niterói; 22°29'47.688"S 39°56'14.785"W;
- FPSO FPF - Cidade Fluminense; 22°38'57.206"S 40°25'43.286"W;
- FPSO P-31 - Petrobras 31; 22°07'48.440"S 39°57'59.913"W;
- SS P-51 - Petrobras 51; 22°37'59.525"S 40°05'43.551"W;
- FIX PVM1 - Vermelho 1; 22°09'33,968"S 40°16'49,579"W.

A Figura 2.15 exibe o fluxo para aquisição das imagens, calibração, identificação e formação dos *patches* nas duas polarizações. Os *patches* são convertidos em formato *Tagged Image File Format* (TIFF). Devido a uma limitação do programa SNAP, durante o processo de conversão para TIFF, há uma perda de resolução radiométrica de 16 bits para 8 bits (FALQUETO *et al.*, 2019). Todas as imagens são preprocessadas e calibradas. O objetivo da calibração SAR é fornecer imagens nas quais os valores dos pixels possam ser relacionados ao retroespalhamento. Após o processamento dos algoritmos de calibração radiométrica, obtem-se a imagem em sigma-zero, que representa a RCS por unidade de área do terreno imageado, sendo dada em decibéis (dB). As imagens originais do tipo amplitude são transformadas em imagens do tipo sigma-zero (dB) (FALQUETO *et al.*, 2019). As Tabelas 2.4 e 2.5 exibem as distribuições dos *patches* por imagens SAR e alvos.

TABELA 2.4 – Número de alvos extraídos na polarização VH por imagens SAR e separados por tipo de plataforma e navio.

| Item | Imagem SAR | Polarização | | | | | | Navio |
|--------------|---------------|-------------|-----------|-----------|----------|----------|----------|------------|
| | | VH | | | | | | |
| | | Plataforma | | | | | | |
| | | FPSO | SS | FIX | FPU | FSO | TWLP | |
| 1 | 20180430 F80C | 14 | 13 | 11 | 1 | 3 | | 50 |
| 2 | 20180605 1FC8 | 14 | 13 | 11 | 1 | 1 | | 49 |
| 3 | 20180512 4256 | 14 | 13 | 10 | 1 | 2 | | 48 |
| 4 | 20171118 D7A4 | 3 | | 9 | | | | 29 |
| 5 | 20180524 C8E1 | 12 | 13 | 10 | | 3 | | 11 |
| 6 | 20180617 C79D | 7 | 1 | | | | | |
| 7 | 20180622 4B43 | 7 | 3 | 2 | | | 1 | |
| 8 | 20180430 2D08 | 6 | 1 | | | | | 13 |
| Total | | 77 | 57 | 53 | 3 | 9 | 1 | 200 |

2. **Extração de atributos (*features*):** os atributos de cada conjunto de imagens são extraídos através das redes neurais convolucionais (CNN, *convolutional neural network*)




FIGURA 2.12 – *Data set* de imagens SAR Sentinel-1, polarização VH, utilizadas como fonte para extração dos *patches* dos alvos.

Visual Geometry Group (VGG), VGG-16 e VGG-19 que permitem transformar pixels em vetores gerando 4096 atributos por imagem (SIMONYAN; ZISSERMAN, 2014) e estão presentes no software de *data mining* Orange Canvas (DEMSAR *et al.*, 2013). A Figura 2.16 exhibe a formação das redes convolucionais VGG-16 e VGG-19 com as camadas convolucionais, *max pooling*, *fully connected* e *softmax*. Os pixels passam a ter representação numérica. Em nossa pesquisa as CNNs são pré-treinadas com o *data set ImageNet* e os atributos são gerados a partir da camada FC7 e fornecidos aos algoritmos classificadores. O treinamento preliminar com o *data set imageNet* traz economia no esforço computacional, aumenta a capacidade de generalização e acelera a convergência (WESTPHAL; SEITZ, 2021). Deve-se levar em consideração que os dados utilizados no *ImageNet* são diferentes das imagens SAR. Apesar dessa diferença entre os dados, (DENG *et al.*, 2009) demonstra que o *ImageNet* pode melhorar o desempenho na classificação de imagens médicas (ALZUBAIDI *et al.*, 2021). A Figura 2.17 exhibe a estrutura da VGG-16 utilizada nesta pesquisa. Tem-se um *patch* de entrada e a vetorização dos atributos entregues aos classificadores é for-




FIGURA 2.13 – *Data set* de imagens SAR Sentinel-1, polarização VV, utilizadas como fonte para extração dos *patches* dos alvos.

neçada pela camada FC7. O mesmo procedimento é considerado para a VGG-19. Como são modificadas, as VGG desta pesquisa apenas geram atributos. Após a vetorização, são formados quatro *data sets*, Figura 2.18, que são a base para formação dos grupos de treinamento e teste.

- 3. Formação dos grupos de treinamento e teste:** seguindo a metodologia proposta por (FALQUETO *et al.*, 2019), a partir do conjunto de dados gerado pela extração de atributos, foram definidos 50 grupos distintos de forma aleatória e separados por redes, VGG-16 e VGG-19, e polarizações, VH e VV. Cada grupo é balanceado com 200 amostras de plataformas e 200 amostras de navios. No primeiro método, as amostras foram geradas aleatoriamente apenas no momento da classificação, não sendo salvas. A partir do método M2, as amostras foram geradas aleatoriamente e salvas para permitir a reprodutibilidade das análises com as mesmas amostras com classificadores diferentes. Em cada grupo, o total de amostras por rede e polarização é 400, sendo divididos em 80% para treinamento e 20% para testes, separados aleatoria-

TABELA 2.5 – Número de alvos extraídos na polarização VV por imagens SAR e separados por tipo de plataforma e navio.

| Item | Imagem SAR | Polarização | | | | | | Navio |
|--------------|---------------|-------------|-----------|-----------|----------|----------|----------|------------|
| | | VV | | | | | | |
| | | Plataforma | | | | | | |
| | | FPSO | SS | FIX | FPU | FSO | TWLP | |
| 1 | 20180430 F80C | 14 | 13 | 11 | 1 | 3 | | 50 |
| 2 | 20180605 1FC8 | 14 | 13 | 11 | 1 | 1 | | 49 |
| 3 | 20180512 4256 | 14 | 13 | 10 | 1 | 2 | | 48 |
| 4 | 20171118 D7A4 | 3 | | 9 | | | | 29 |
| 5 | 20180524 C8E1 | 12 | 13 | 10 | | 3 | | 11 |
| 6 | 20180617 C79D | 7 | 1 | | | | | |
| 7 | 20180622 4B43 | 7 | 3 | 2 | | | 1 | |
| 8 | 20180430 2D08 | 6 | 1 | | | | | 13 |
| Total | | 77 | 57 | 53 | 3 | 9 | 1 | 200 |

mente, conforme apresentado na Figura 2.19. Dos 80% de amostras de treinamento, que equivalem a 320 amostras, 160 amostras são de plataformas e 160 amostras são de embarcações. Dos 20% de amostras de teste, que equivalem a 80 amostras, 40 amostras são de plataformas e 40 são de embarcações, garantindo o equilíbrio entre os tipos de classes a serem classificadas. A Tabela 2.6 exibe a distribuição das amostras de treinamento e teste entre todos os métodos.

4. **Bootstrap:** após a extração de atributos com as CNN, são criados quatro *data sets* diferentes (df-16vh, df-16vv, df-19vh, df-19vv) que são os resultados das combinações das duas CNN, VGG-16/VGG-19, e das polarizações VH/VV. Para garantir a reprodutibilidade e que os classificadores sejam avaliados sob as mesmas condições, utiliza-se a técnica *bootstrap*. O *bootstrap* é uma técnica não paramétrica de reamostragem aleatória com reposição, a partir de um conjunto de dados principal. Com essa técnica é possível estimar a distribuição empírica de estatísticas. Foram utilizados 50 *bootstrap* para cada um dos *data sets* principais. A técnica *bootstrap* é aplicada da seguinte forma:

- Utilizam-se 50 *bootstrap* para cada um dos *data sets* originais (df-16vh, df-16vv, df-19vh, df-19vv). Com isso, são gerados 50 novos *data set*;
- Para formação de cada *bootstrap* são coletadas amostras aleatórias com reposição, a partir dos dados originais;
- Cada *data set* é formado por 320 amostras de treinamento e 80 amostras de testes;




FIGURA 2.14 – Localização dos *patches* de plataformas nas imagens SAR 20180430 F80C com polarização VH e VV.

5. **Escolha de classificadores:** Os algoritmos a seguir são utilizados nos métodos de classificação: LR, SVM, RF, k NN, NB, DT, NET e ADBST. Como critério de avaliação utilizou-se a métrica acurácia (Acc, *Accuracy*) a qual é definida como a proporção de amostras corretamente classificadas perante o número total de amostras em um teste.

6. Métodos de classificação.

Sao utilizados seis métodos de classificação descritos com detalhes a seguir.

- **(M1) - Reprodução dos dados:** este método reproduz os resultados obtidos por (FALQUETO *et al.*, 2019), onde utilizam-se os classificadores LR, SVM, RF, k NN, DT, NB com parâmetros na configuração *default*;
- **(M2) - Teste de sensibilidade:** neste método, ampliou-se o número de algoritmos utilizados no método M1 com a adição do NET e do ADBST. Os parâmetros dos algoritmos foram alterados de forma empírica buscando melhorar os resultados de (FALQUETO *et al.*, 2019). A Tabela 2.8 apresenta a relação de parâmetros e seus respectivos valores para ajuste visando identificar os limites dos algoritmos. As médias dos melhores resultados são obtidas com os valores de parâmetros da Tabela 2.9. O classificador NB não está na relação porque

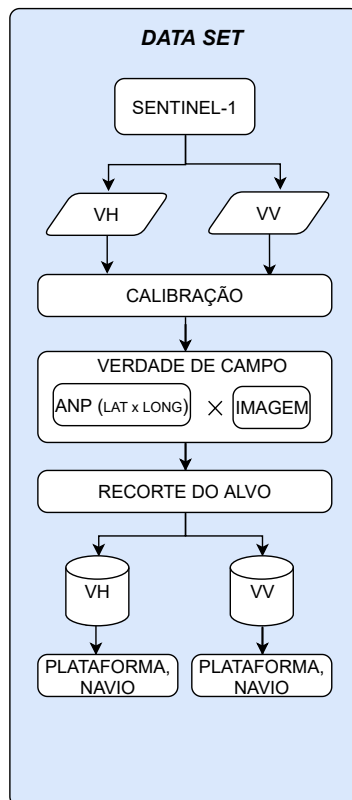


FIGURA 2.15 – *Flowchart* do *data set* de imagens Sentinel-1 usado neste trabalho.

não possui parâmetro para ajuste;

- **(M3) - PCA:** neste método, utilizou-se a técnica PCA para redução da dimensionalidade dos atributos. Após isso, realizou-se a classificação do *data set* com novos atributos. Foram mantidos os parâmetros listados na Tabela 2.7;
- **(M4) - Concatenação VH + VV:** neste método, ampliou-se o *data set* de treinamento com a concatenação de todas as amostras dos *data sets* VH e VV. O *data set* de testes não sofreu alteração. Em seguida, são executados os classificadores;
- **(M5) - Concatenação de 1/2 (VH + VV):** neste método, ampliou-se o *data set* de treinamento com a concatenação de metade das amostras dos *data set* VH e VV. O conjunto de testes permaneceu com as mesmas amostras.
- **(M6) - Stacking:** neste método, utiliza-se a técnica *stacked generalization* para combinação de vários classificadores com objetivo de obter melhores resultados de classificação (WOLPERT, 1992; TING; WITTEN, 1997; TING; WITTEN, 1999).

7. **Classificação:** é a última etapa do processo, consistindo na execução dos classificadores com base nas amostras de treinamento e teste. Encerrando a classificação, são apresentados os resultados e distribuídos nos cinco indicadores de desempenho




FIGURA 2.16 – (a) Estrutura de formação da VGG-16 com suas 13 camadas convolucionais; (b) Estrutura de formação da VGG-19 com suas 16 camadas convolucionais.

apresentados anteriormente.

- Análises estatísticas:** Por fim, utiliza-se testes estatísticos de Shapiro-Wilk (SHAPIRO; WILK, 1965; MILICEVI *et al.*, 2019) para verificação da normalidade dos dados e do teste não paramétrico Kruskal-Wallis (KRUSKAL; WALLIS, 1952; GARCÍA *et al.*, 2010) e teste de comparações múltiplas Dunn (DINNO, 2015) para análise do nível de significância dos resultados de classificação para multiplas amostras. Considerou-se nível de significância de 5%.

Os parâmetros de configuração dos classificadores estão relacionados na Tabela 2.7. A seguir descreve-se cada um dos classificadores e seus respectivos parâmetros.

- k NN - (1) número de vizinhos: determina a quantidade de vizinhos a serem considerados na classificação do alvo; (2) distância: define a métrica para cálculo da

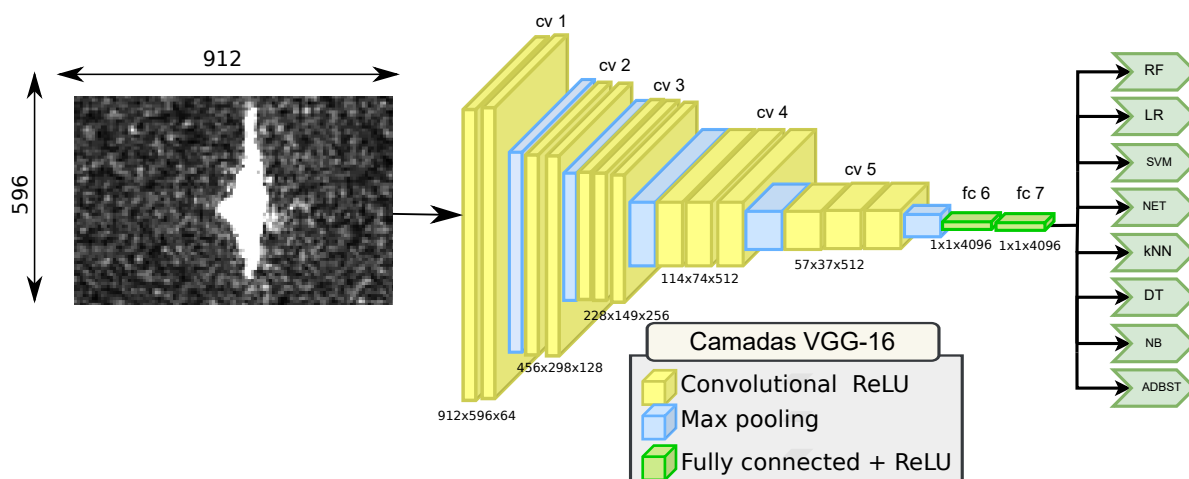


FIGURA 2.17 – Aplicação da VGG-16 modificada utilizada neste trabalho. Um *patch* de alvo é fornecido à camada convolucional 1. A camada FC7 fornece aos classificadores RF os atributos vetorizados.

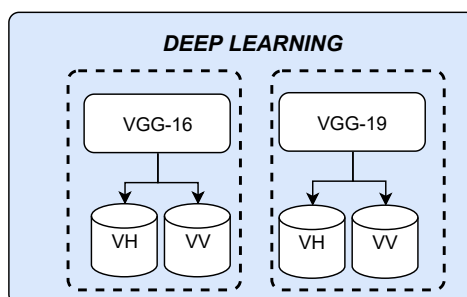


FIGURA 2.18 – Extração de atributos por redes CNN VGG-16 e VGG-19.

distância entre o vizinho e o alvo. Dentre as métricas, tem-se: Euclidiana (linha reta entre dois pontos; Manhattan (soma da diferença absoluta entre os atributos); (3) peso: uniforme (todos os pontos na vizinhança são ponderados igualmente); distância: os vizinhos mais próximos de um ponto de consulta têm uma influência maior que os vizinhos mais distantes;

2. DT - (1) tipo de árvore: constrói uma árvore binária; (2) número mínimo de instâncias por folhas: evita que o algoritmo construa uma divisão com menos que o número especificado de exemplos de treinamento em qualquer uma das ramificações; (3) mínimo de instâncias para divisão de um nó: evita que haja divisão com número de nós menor de instâncias; (4) limite de profundidade da árvore: limita a profundidade de acordo com o número especificado;
3. RF - (1) número de árvores: especifica a quantidade de árvores que farão parte da floresta; (2) mínimo de instâncias para divisão de um nó: seleciona o menor subconjunto que pode ser dividido;
4. SVM - (1) custo: é o indicador de penalidade para classificações incorretas; (2) ϵ

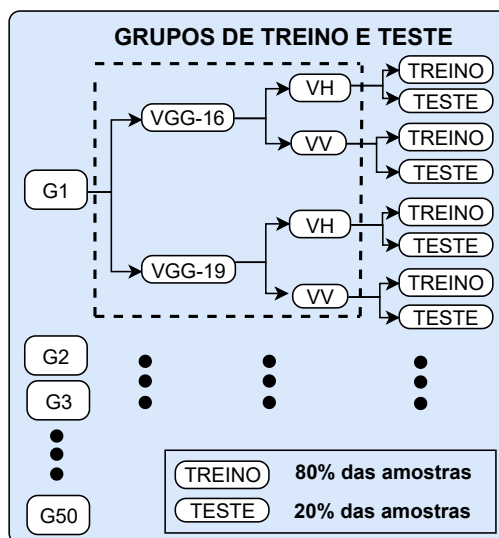


FIGURA 2.19 – Processo de formação dos grupos de treinamento e teste.

- tolerância numérica: distância dos valores verdadeiros dentro dos quais nenhuma penalidade está associada; (3) *kernel*: é uma função que transforma o espaço de atributos em um novo espaço de atributos para ajustar o hiperplano de margem máxima, permitindo ao modelo criar *kernels* linear, polinomial, RBF e sigmoid; (4) tolerância numérica: limite permitido do valor esperado; (5) limite de iterações: número máximo de iterações.

5. LR - (1) método de regularização: altera a resposta do resultado para ser mais simples e pode ser dividido em L1 (Lasso) e L2 (*ridge regression*); (2) custo: define a força do custo;
6. NET - (1) número de neurônios na camada oculta: define a quantidade de neurônios que irão formar a camada oculta;
7. ADBST - (1) número de estimadores: define a quantidade de estimadores (árvores de decisão) que serão usados na classificação.

A Figura 2.20 apresenta o diagrama com todos os blocos que compõem a metodologia da pesquisa citados anteriormente, constituindo-se de: *data set*, *deep learning*, grupos de teste e treinamento, métodos de classificação, classificadores, resultados e análise estatística. A Figura 2.21 exhibe o fluxo ilustrativo resumido.

2.7 Conclusão

Este capítulo apresentou as características da missão Sentinel-1 que é a fonte das imagens SAR polarimétricas utilizadas nesta pesquisa. Também apresentou a Bacia de

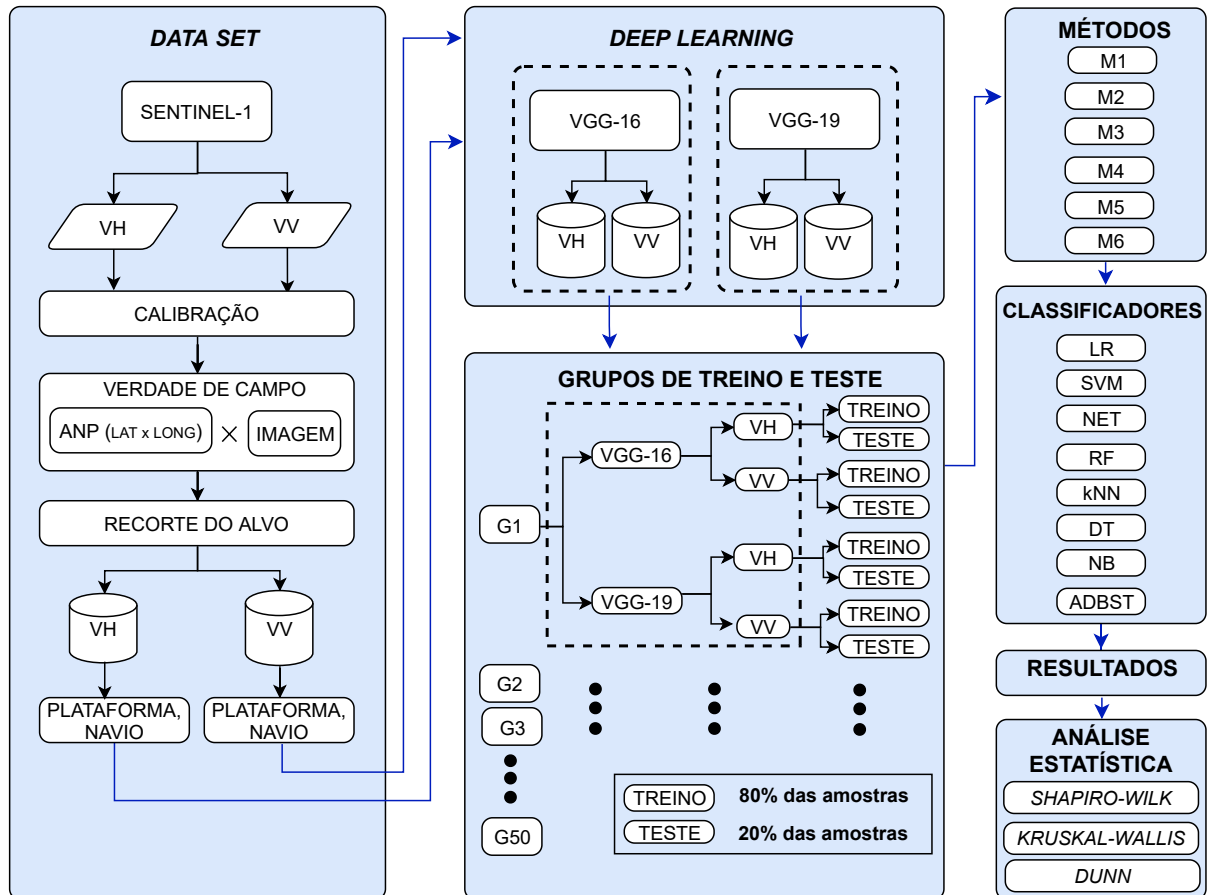


FIGURA 2.20 – Metodologia. Os *patches* gerados no *data set* são vetorizados pelo bloco *deep learning*. Logo após, são gerados os 50 grupos de treinamento e teste. Cada grupo é classificado utilizando os seis métodos e os oito classificadores. Os resultados são avaliados pela acurácia e validados com os testes estatísticos.

Campos, área de interesse do estudo, que se destaca na produção marítima nacional de petróleo e gás natural. Os alvos de interesse são formados por navios e plataformas petrolíferas. Para classificação foram apresentadas as técnicas de *machine learning* compostas pelos algoritmos LR, SVM, RF, NET, *k*NN, DT, NB e ADBST que foram divididos em seis métodos de análise. A extração de atributos das imagens ocorre através de técnicas *deep learning* com as CNN VGG-16 e VGG-19. Por fim, apresenta-se a metodologia para avaliação dos classificadores que envolve o material composto pelas imagens SAR e pelas técnicas de ML e DL. O Capítulo 3 apresenta os resultados da metodologia discutida anteriormente. Também apresenta-se as discussões e análises dos resultados alcançados.

TABELA 2.6 – Distribuição das amostras de treinamento e teste.

| Amostras | | | | | | |
|----------|-----|-------|--------------------|-----|---------------------|-------|
| CNN | Pol | Total | Treinamento | | | Teste |
| | | | M1, M2, M3, and M6 | M4 | M5 | |
| VGG-16 | VH | 400 | 320 | 640 | 160 (VH) + 160 (VV) | 80 |
| | VV | 400 | 320 | | | 80 |
| VGG-19 | VH | 400 | 320 | 640 | 160 (VH) + 160 (VV) | 80 |
| | VV | 400 | 320 | | | 80 |

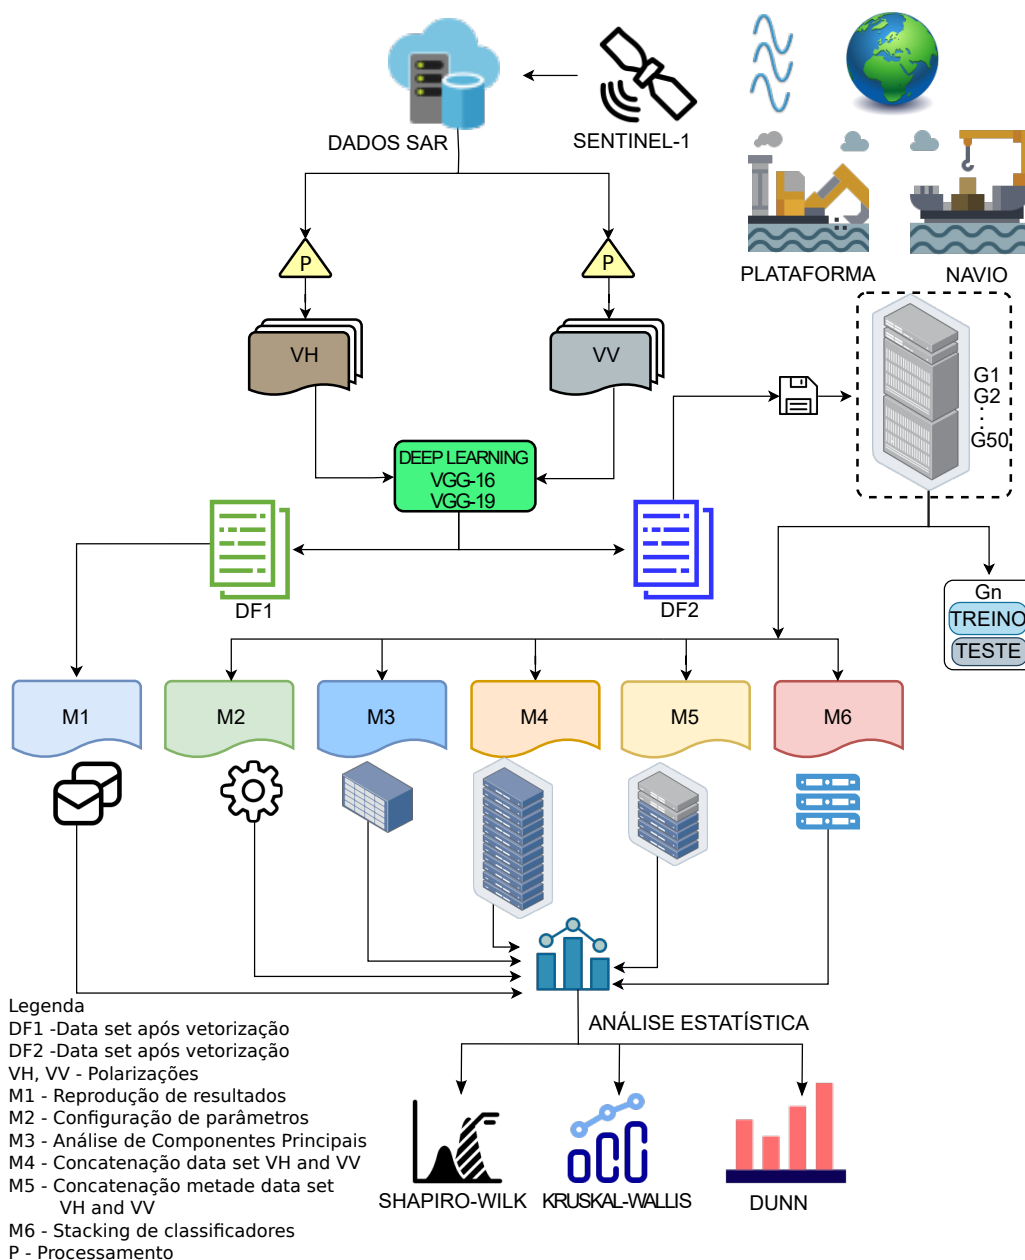


FIGURA 2.21 – Fluxograma resumido da metodologia considerando os dados SAR, *deep learning*, os seis métodos de análise aplicados, os grupos de treinamento e testes estatísticos.

TABELA 2.7 – Relação de parâmetros por classificadores.

| Classificador | Parâmetro | Valor |
|----------------------|--|------------------|
| <i>k</i> NN | Número de vizinhos | 3 |
| | Distância | Euclidiana |
| | Peso | Uniforme |
| DT | Tipo de árvore | Binária |
| | Mínimo de instâncias por folha | 2 |
| | Mínimo de instâncias para divisão de um nó | 5 |
| | Limite de profundidade da árvore | 100 níveis de nó |
| | Critério de parada baseado na maioria | 95% |
| RF | Número de árvores | 10 |
| | Mínimo de instâncias para divisão de um nó | 5 |
| SVM | Custo | 1 |
| | Regression Loss Epsilon | 0,1 |
| | Kernel | RBF |
| | Tolerância numérica | 0,001 |
| | Número de interações | 100 |
| NB | Sem parâmetros | - |
| LR | Método de regularização | Ridge (L2) |
| | Força | 1 |

TABELA 2.8 – Parâmetros ajustados.

| Classificador | Parâmetro | Valor |
|----------------------|--------------------------------|-----------------------|
| RF | Número de árvores | 10,50,100,200,300,400 |
| | | 500,600,700,800,900 |
| | | 1000,1100,1200,1300 |
| k NN | Número de vizinhos | 3,5,7,10 |
| | Distância | Euclidean, Manhattan |
| ADBST | Nº de estimadores | 10,50,100 |
| LR | Força | 0.6,1,10,50,100,200 |
| NET | Número de neurônios | 10,50,100,200 |
| SVM | Custo | 1,2,3,4,5 |
| | Kernel | RBF, SIGM |
| | Número de iterações | 100,200 |
| DT | Mínimo de instâncias por folha | 2,5,7,10,20 |
| NB | Sem parâmetros | |

TABELA 2.9 – Parâmetros ajustados no método M2.

| | | Parâmetro | | | | | |
|------------|------------|----------------------|-----|------|------------|----|-----|
| | | Classificador | | | | | |
| CNN | Pol | k NN | LR | RF | SVM | DT | NET |
| VGG-16 | VH | 7-Manhattan | 1 | 50 | 4-SIGM-200 | 7 | 10 |
| | VV | 3-Manhattan | 1 | 200 | 3-SIGM-200 | 5 | 50 |
| VGG-19 | VH | 5-Manhattan | 1 | 1200 | 1-SIGM-100 | 2 | 50 |
| | VV | 5-Euclidean | 0.6 | 100 | 2-SIGM-200 | 5 | 100 |

3 Análise numérica

Este capítulo apresenta os resultados alcançados na avaliação das técnicas de ML citadas na Seção 2.6. Para isso, segue-se a metodologia descrita na Seção 2.6 que é uma adaptação da proposta por (FALQUETO *et al.*, 2019) em que as classificações foram divididas em seis métodos, M1-M6. Cada método é composto pelos classificadores relacionados na Seção 2.6. O método M_{Ref} refere-se as médias de Acc obtidas por (FALQUETO *et al.*, 2019), sendo fator comparativo para avaliar o ganho dos classificadores nos métodos subsequentes. Nas análises consideram-se as métricas de desempenho citadas na Seção 2.5.1, AUC , Acc , $F1\ Score$, $Precision$ e $Recall$. Devido à similaridade entre os valores de algumas métricas, este capítulo apresenta os resultados apenas considerando a Acc . Os resultados com as demais métricas são apresentados no Apêndice. Ao final do capítulo, são exibidas as análises estatísticas.

Os resultados apresentados neste capítulo são possíveis a partir da extração de atributos (vetorização) das imagens SAR com canais de polarização VH e VV realizadas através das CNN VGG-16 e VGG-19. Com base nos atributos (*features*) fornecidos pelas CNN, são gerados 50 grupos de treinamento e teste para classificação supervisionado. As CNN permitem extrair 4096 *features* (SIMONYAN; ZISSERMAN, 2014) de cada imagem com informações representativas e com capacidade de gerar classificações com acurácia chegando até 85,5%. A seguir são apresentadas e analisadas as médias de Acc e ganhos de 50 classificações por métodos e classificadores. Considerando os dois classificadores com maiores níveis de acurácia, a Tabela 3.1 destaca todos os resultados. Observa-se a predominância de LR, NET, SVM, RF e kNN distribuídos da seguinte forma: 32,5%, 32,5%, 17,5%, 15,5% e 2,5%, respectivamente. Em M1 observa-se similaridade com M_{Ref} . As maiores Acc são para VGG-16VH com LR 85,2% e VGG-19VH com SVM 81,6%. A Figura 3.1 complementa através de boxplot as análises dos resultados da Tabela 3.1 para VGG-16VH. Para as análises com VGG-16VV, VGG-19VH e VGG-19VV as figuras complementares estão apresentadas no Apêndice B.

O desempenho dos classificadores é comparado com os resultados de (FALQUETO *et al.*, 2019) utilizando a equação

$$Ganho(\psi) = \frac{Acc(\psi) - Acc(M_{Ref})}{Acc(M_{Ref})} * 100, \quad (3.1)$$

TABELA 3.1 – Resumo com os dois melhores índices de acurácia por métodos de classificação. O símbolo “–” indica que a classificação não está entre os dois melhores resultados.

| | Classificador | Acurácia | | | | | | |
|-----------------|---------------|-----------|-------|-------|-------|-------|-------|-------|
| | | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| VGG-16VH | LR | 0,864 | 0,852 | 0,855 | 0,824 | – | 0,846 | – |
| | RF | – | – | – | 0,820 | 0,799 | – | – |
| | SVM | 0,804 | 0,806 | 0,838 | – | – | – | – |
| | NET | – | – | 0,838 | – | 0,840 | 0,830 | – |
| | Stack | – | – | – | – | – | – | 0,844 |
| VGG-16VV | k NN | – | – | – | – | 0,748 | – | – |
| | LR | 0,781 | 0,782 | 0,783 | – | – | 0,783 | – |
| | RF | – | – | – | 0,747 | – | – | – |
| | SVM | 0,723 | 0,714 | – | – | – | – | – |
| | NET | – | – | 0,784 | 0,728 | 0,776 | 0,757 | – |
| | Stack | – | – | – | – | – | – | 0,763 |
| VGG-19VH | LR | 0,841 | 0,851 | 0,842 | – | – | 0,845 | – |
| | RF | – | – | – | 0,824 | 0,810 | – | – |
| | SVM | 0,824 | 0,816 | 0,849 | – | – | – | – |
| | NET | – | – | – | 0,828 | 0,844 | 0,833 | – |
| | Stack | – | – | – | – | – | – | 0,841 |
| VGG-19VV | LR | 0,774 | 0,766 | 0,768 | – | – | 0,733 | – |
| | RF | – | – | – | 0,757 | – | – | – |
| | SVM | 0,737 | 0,731 | 0,754 | – | 0,766 | – | – |
| | NET | – | – | – | 0,760 | 0,777 | 0,761 | – |
| | Stack | – | – | – | – | – | – | 0,761 |

em que ψ é a média da acurácia em cada um dos métodos de classificação M1-M6; M_{Ref} é a acurácia de referência dos resultados obtidos por (FALQUETO *et al.*, 2019). Os resultados de classificação com ganho superior a (FALQUETO *et al.*, 2019) são exibidos na Tabela 3.2.

A Tabela 3.3 mostra um resumo da média de acurácia de todos os métodos com VGG-16/19 e polarizações VH/VV. De forma geral, percebe-se predominância dos LR, SVM, RF e NET. Analisando os métodos individualmente tem-se:

- no método M1, similaridade com os resultados de (FALQUETO *et al.*, 2019), sendo essa referência para as análises estatísticas;
- no método M2, as maiores Acc são LR, SVM, NET e os maiores ganhos são RF e SVM;
- no método M3, as maiores Acc são LR, RF, NET e os maiores ganhos NB e RF;
- no método M4, as maiores Acc são RF, NET, SVM e ganhos k NN, DT e SVM;
- no método M5, as maiores Acc são LR, NET, RF, SVM e ganhos DT, NB e SVM;
- no método M6, as classificações combinadas apresentam ganho em relação as classificações individuais.




FIGURA 3.1 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-16VH.

As Tabelas 3.4-3.7 apresentam as médias de acurácia e ganhos para todos os métodos por tipo de VGG e polarização. Com base nas tabelas supracitadas, a seguir são apresentadas as Acc e ganhos dos melhores resultados separados por CNN (VGG-16 e VGG-19) e polarização (VH e VV). Comparando os resultados obtidos nesta pesquisa com os resultados de (FALQUETO *et al.*, 2019), observa-se ganho em CNN VGG-16 polarização VV: k NN 7,7% (M4), RF 6,1% (M3); polarização VH: SVM 4,2% (M2), NB 3,4% (M3). CNN VGG-19 polarização VV: NB 9,6% (M3), k NN 7% (M4); polarização VH: NB 4,1% (M3), SVM 3% (M2). Nos métodos M4 e M5 destaca-se o classificador NET com os valores de Acc a seguir. VGG-16 polarização VH: 84% (M4) e 83% (M5); VGG-19 polarização VH: 84,4% (M4), 83,3% (M5); VGG-16 polarização VV: 77,6% (M4), 75,7% (M5); VGG-19 polarização VV: 77,7% (M4), 76,1% (M5).

Com a técnica *stacking* o resultado final é superior aos resultados individuais, exceto para LR nos métodos M1, M2 e M5. Considerando VGG-16 polarização VH nos métodos M3 e M4, o melhor resultado de Acc com 84,4% é obtido com a técnica *stacking*. Considerando VGG-16 polarização VV, o resultado final de 76,3% é superior aos resultados individuais em todos os métodos, exceto para LR nos métodos M1, M2 e M5. No método M3 a técnica *stacking* apresenta maior nível de Acc com 76,3% que é superior a 74,7% do RF. No método M4 apenas a NET foi superior com 77,6%. Considerando VGG-19 polarização VH, o resultado de 84,1% é inferior a LR 85,1% (M1), LR 84,2% (M2), SVM 84,9% (M2), NET 84,4% (M4), LR 84,5% (M5). Comparando com os resultados obtidos no método M3, o *stacking* foi melhor. Considerando VGG-19 polarização VV, a Acc de 76,1% é inferior a LR 76,6% (M1), LR 76,8% (M2), SVM 76,6% (M4), NET 77,7% (M4),

TABELA 3.2 – Resumo melhores ganhos por métodos de classificação. O símbolo “–” indica que os ganhos são negativos.

| | Classificador | Ganho | | | | | | |
|-----------------|---------------|-----------|------|------|------|------|------|-------|
| | | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| VGG-16VH | k NN | – | 0,7% | 2,6% | – | – | – | – |
| | NB | – | – | – | 3,4% | – | – | 20,9% |
| | RF | – | – | 2,0% | 2,3% | – | – | – |
| | SVM | – | 0,2% | 4,2% | – | – | – | – |
| | k NN | – | 0,9% | – | – | 7,7% | 0,9% | – |
| | DT | – | – | – | – | – | – | 12,5% |
| VGG-16VV | LR | – | 0,1% | – | – | – | – | – |
| | NB | – | – | – | 2,7% | – | – | 15,6% |
| | RF | – | – | 5,0% | 6,1% | 3,4% | – | – |
| | SVM | – | – | 5,1% | – | – | – | – |
| | DT | – | – | – | – | – | 1,3% | 15,8% |
| VGG-19VH | LR | – | 1,1% | – | – | – | 0,4% | – |
| | NB | – | – | – | 4,1% | – | – | 20,0% |
| | RF | – | – | 2,2% | 1,0% | – | – | – |
| | SVM | – | – | 3,0% | – | – | – | – |
| | DT | – | – | – | – | – | – | 10,3% |
| VGG-19VV | k NN | – | – | – | – | 7,0% | – | – |
| | NB | – | 1,6% | – | 9,6% | – | 2,1% | 18,4% |
| | RF | – | – | 4,5% | 5,2% | – | – | – |
| | SVM | – | – | 2,3% | – | – | – | – |
| | DT | – | – | – | – | 5,3% | 3,3% | 13,6% |

LR 77,3% (M5). Comparando com os resultados de M3, o *stacking* foi o que apresentou maior nível de acurácia. Comparando os resultados da técnica *stacking* com (FALQUETO *et al.*, 2019), os maiores ganhos ocorrem com NB e DT, conforme destacado adiante. CNN VGG-16 polarização VH: NB 20,9%, DT 12,5%; polarização VV: NB 15,6%; DT 15,8%. CNN VGG-19 polarização VH: NB 20,3%, DT 10,3%; polarização VV: NB 18,4%, DT 13,6%.

Ainda, considerando os dois classificadores com maiores níveis de Acc em cada método de classificação, os resultados foram analisados pelos testes estatísticos Shapiro-Wilk, Kruskal-Wallis e Dunn que são testes indicados pela literatura e muito aplicados em processamento de sinais e ML (MURATA *et al.*, 2019; EMAMI *et al.*, 2019; SUTTON *et al.*, 2016; PAIVA *et al.*, 2019; TAGHAVI *et al.*, 2021) para avaliação da normalidade e teste do nível de significância. O teste Shapiro-Wilk identificou que há 70%, 10%, 30% e 30% de VGG-16VH, VGG-16VV, VGG-19VH e VGG-19VV, respectivamente de resultados que não podem ser modelados por distribuição normal. Diante disso, optou-se pelo teste não paramétrico Kruskal-Wallis que identificou haver diferença significativa entre as amostras testadas. O teste *post hoc* Dunn identificou quais grupos possuem diferença entre si. Como nível de significância utilizou-se 0,05 por ser um nível adequado para rejeitar a

hipótese nula (FISHER, 1992). A Tabela 3.8 apresenta os resultados da avaliação do nível de significância entre os resultados de classificação. Para isso, utiliza-se os testes Kruskal-Wallis e Dunn com seus respectivos p -valores e métodos de classificação. Como destaque estão os resultados entre as comparações das reproduções de (FALQUETO *et al.*, 2019) (M1) e os métodos analisados os quais o SVM apresenta maior ganho com 4,17%, 3,94% e 3,03% em termos de Acc em VGG-16VH (M2), VGG-19VV (M4), VGG-19VH(M2), respectivamente em comparação com (FALQUETO *et al.*, 2019) As análises de desempenho e testes estatísticos destacam que os métodos de classificação apresentam performance competitiva em comparação com (FALQUETO *et al.*, 2019), que em nosso conhecimento, é o único estudo na literatura sobre a detecção de plataformas e navios na bacia de Campos através de imagens SAR do Sentinel-1.

3.1 Análise com otimizações

Esta seção apresenta os resultados de análises realizadas com a biblioteca Scikit-learn (PEDREGOSA *et al.*, 2011), sendo resumido no diagrama da Figura 3.2. A seguir são descritos cada um dos blocos do diagrama.

1. *data set*: o *data set* vetorizado das imagens SAR que é gerando no Orange (DEMSAR *et al.*, 2013) é importado para o Python;
2. Pandas: após a importação o *data set* é salvo com a biblioteca Pandas;
3. Otimização: são utilizadas duas formas de otimização: (i) redução de dimensionalidade com a técnica PCA; (ii) identificação das melhores combinações de parâmetros com a função *Grid Search*;
4. Classificação: a classificação utiliza as seguintes funções da biblioteca Scikit-learn:
 - LR - LogisticRegression;
 - DT - DecisionTreeClassifier;
 - RF - RandomForestClassifier;
 - kNN - KNeighborsClassifier;
 - SVM - svm.SVC;
 - ADBST - AdaBoostClassifier;
 - NET - MLPClassifier;
 - NB - GaussianNB;
5. AUC Acc: como resultados são avaliadas as métricas AUC e Acc.

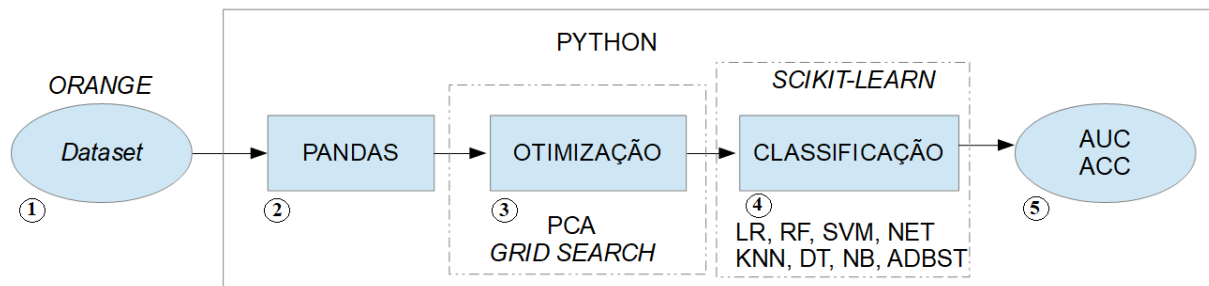


FIGURA 3.2 – Diagrama de análise com a biblioteca Scikit-learn.

Para isso, são consideradas quatro categorias: (1) *default* - utiliza-se os parâmetros com opção *default* e com a dimensionalidade total de atributos; (2) otimizado - utiliza-se a função *Grid Search* para identificar o melhor ajuste do classificador com dimensionalidade total de atributos; (3) PCA - utiliza-se a redução de dimensionalidade de atributos e parâmetros *default*; (4) PCA otimizado - utiliza-se a função *Grid Search* para identificar o melhor ajuste do classificador. A Figura 3.3 exibe a variância explicada acumulada em relação a quantidade de componentes principais dos dados extraídos com VGG-16VH. Isso significa quanta variação em um conjunto de dados pode ser atribuída a cada um dos componentes principais da PCA, ou seja, é a variabilidade em um conjunto de dados que pode ser atribuída a cada componente principal individual. Ela informa quanto da variância total é explicada por cada componente (KUMAR, 2022). Percebe-se que 40 componentes tem uma variância explicada acumulada de 80%. Aumentando para 100 componentes, chega-se a 94,54%. Com 150 componentes, a variância explicada acumulada é de 97%. Já com 200 componentes, tem-se 98% de explicação. As curvas ROC da Figura 3.4 indicam os melhores resultados de classificação do LR em relação as CNN VGG-16 e VGG-19 e as polarizações VH e VV. As curvas ROC dos classificadores SVM, NET e RF estão listadas no Apêndice C.

3.2 Conclusão

Este capítulo apresentou os resultados das classificações nos seis métodos analisadas (M1-M6) e os discutiu com base nos ganhos de acurácia obtidos em relação a literatura de referência (FALQUETO *et al.*, 2019). Utilizando a ferramenta de *data mining* Orange, os resultados alcançados apresentaram Acc acima de 80%, chegando a 85,5% e ganho de até 9,61%. Dentre os aqueles com diferença significativa em comparação aos valores reproduzidos de (FALQUETO *et al.*, 2019) (M1), destaca-se o SVM com ganho de 4,17%, 3,94% e 3,03% em termos de Acc em VGG-16VH (M2), VGG-19VV (M4), VGG-19VH(M2), respectivamente. Também realizou-se uma análise de otimização utilizando PCA e a função *Grid Search* em conjunto com a biblioteca Scikit-learn. Como resultados foram geradas




FIGURA 3.3 – Variância cumulativa explicada das componentes principais da VGG-16VH. Sendo o valor máximo de variância cumulativa explicada: (a) 80%; (b) 94,54%; (c) 97%; (d) 98%.

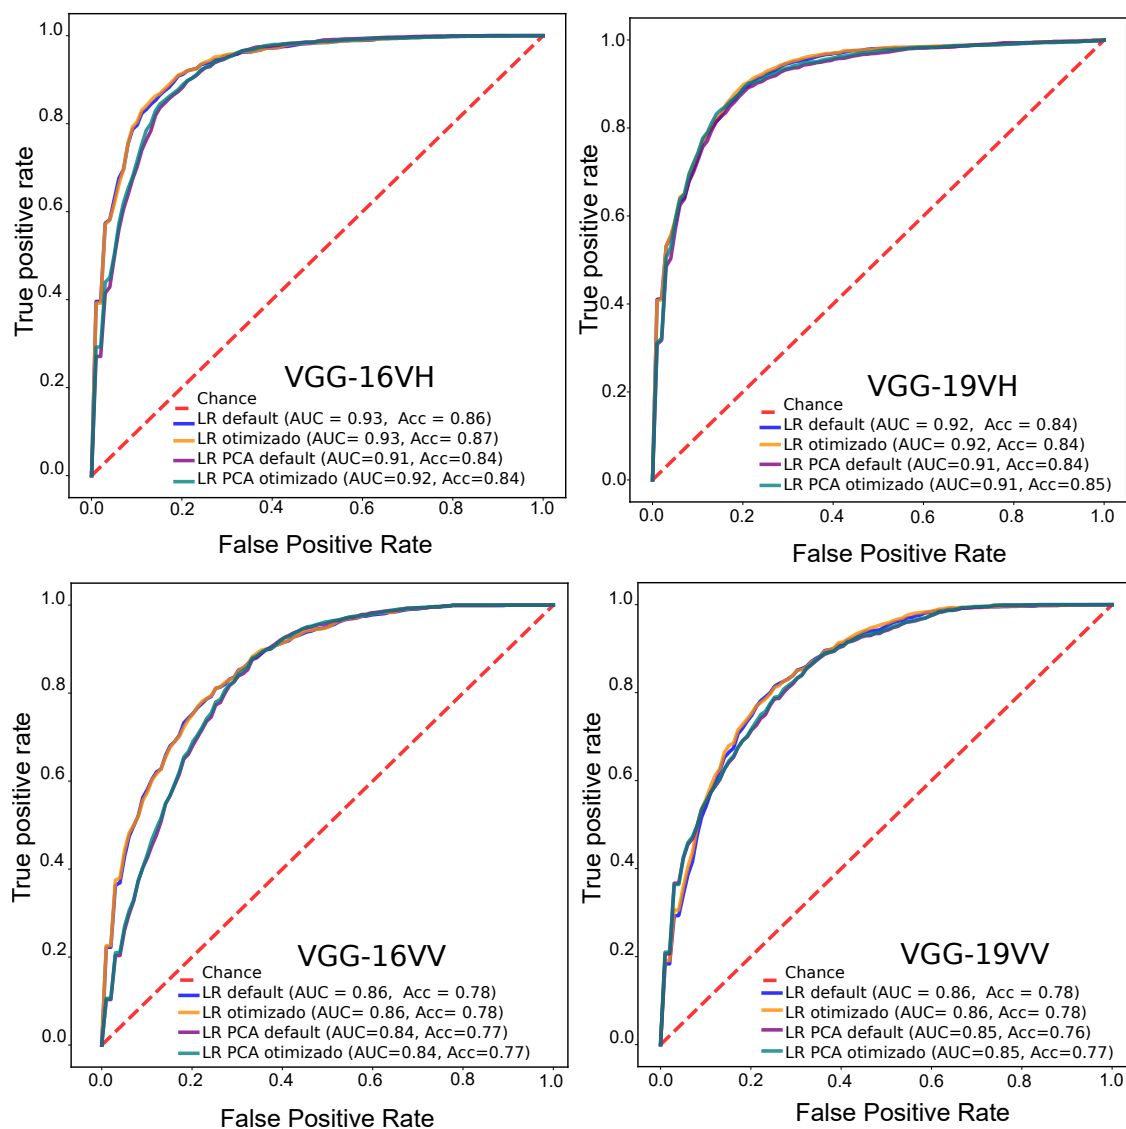


FIGURA 3.4 – Curva ROC dos resultados de classificação do LR em relação as CNN VGG-16/19 e polarizações VH/VV.

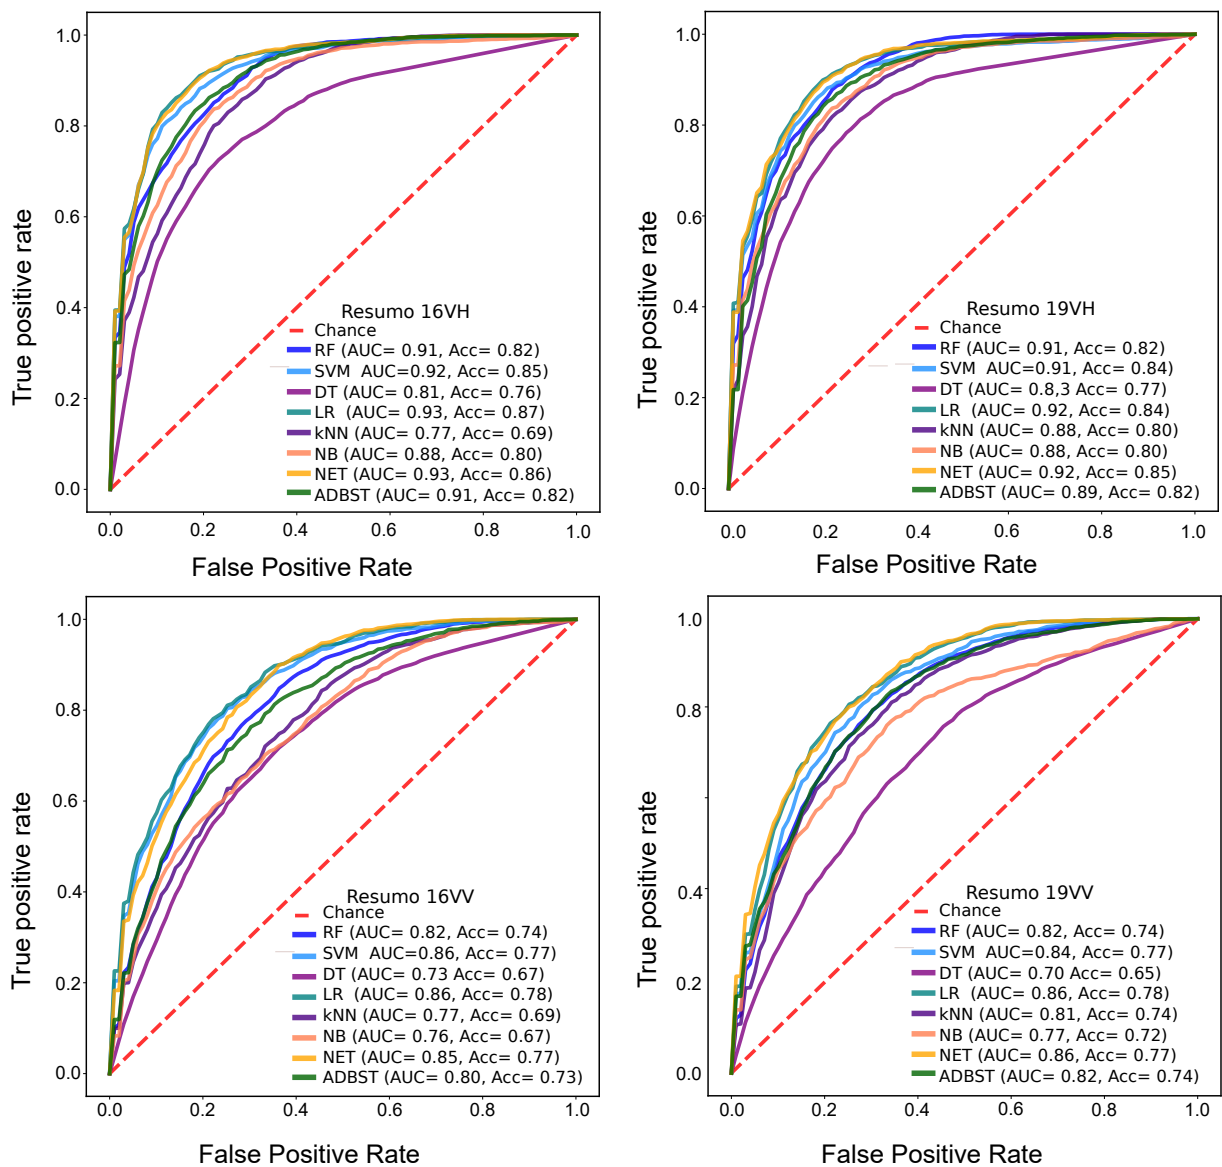


FIGURA 3.5 – Curva ROC dos melhores resultados de classificação considerando as CNN VGG-16/19 e as polarizações VH/VV.

as curvas ROC e fica evidenciado que o LR obtem a maior AUC e acurácia com 0,93 e 86,5%, respectivamente, para a VGG-16VH.

TABELA 3.4 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG - 16 e polarização VH e ganho de rendimento em relação a M_{Ref} . O símbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final no método **M6** e (iii) “*” indica ganho não calculado por ser o método de referência.

| Acurácia VGG-16VH | | | | | | | |
|-------------------|-----------|-------|-------|-------|--------|-------|-------|
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | 0,772 | 0,778 | 0,792 | 0,751 | 0,768 | 0,772 | |
| LR | 0,864 | 0,852 | 0,855 | 0,824 | 0,627 | 0,846 | x |
| NB | 0,698 | 0,711 | 0,696 | 0,722 | 0,691 | 0,687 | |
| RF | 0,802 | 0,792 | 0,818 | 0,820 | 0,799 | 0,780 | x |
| SVM | 0,804 | 0,806 | 0,838 | 0,817 | 0,785 | 0,792 | x |
| DT | 0,750 | 0,744 | 0,738 | 0,742 | 0,757 | 0,724 | x |
| ADBST | - | - | 0,732 | 0,726 | 0,739 | 0,726 | |
| NET | - | - | 0,838 | 0,817 | 0,840 | 0,830 | |
| <i>Stack</i> | - | - | - | - | - | - | 0,844 |
| Ganho VGG-16VH | | | | | | | |
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | * | 0,7% | 2,6% | -2,7% | -0,6% | 0,0% | 9,3% |
| LR | * | -1,4% | -1,1% | -4,6% | -27,5% | -2,1% | -2,3% |
| NB | * | 1,8% | -0,4% | 3,4% | -1,1% | -1,6% | 20,9% |
| RF | * | -1,2% | 2,0% | 2,3% | -0,4% | -2,9% | 5,2% |
| SVM | * | 0,2% | 4,2% | 1,6% | -2,4% | -1,5% | 4,9% |
| DT | * | -0,8% | -1,6% | -1,1% | 0,9% | -3,6% | 12,5% |

TABELA 3.5 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG-16, polarização VV e ganho de rendimento em relação a M_{Ref} . O símbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final no método **M6** e (iii) “*” indica ganho não calculado por ser o método de referência.

| Acurácia VGG-16VV | | | | | | | |
|-------------------|-----------|-------|-------|-------|--------|-------|-------|
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | 0,694 | 0,701 | 0,708 | 0,655 | 0,748 | 0,700 | |
| LR | 0,781 | 0,782 | 0,783 | 0,722 | 0,608 | 0,783 | x |
| NB | 0,660 | 0,645 | 0,657 | 0,678 | 0,656 | 0,658 | |
| RF | 0,704 | 0,695 | 0,740 | 0,747 | 0,728 | 0,703 | x |
| SVM | 0,723 | 0,714 | 0,760 | 0,718 | 0,729 | 0,722 | x |
| DT | 0,659 | 0,642 | 0,654 | 0,615 | 0,676 | 0,668 | x |
| ADBST | - | - | 0,650 | 0,645 | 0,688 | 0,667 | |
| NET | - | - | 0,784 | 0,728 | 0,776 | 0,757 | |
| <i>Stack</i> | - | - | - | - | - | - | 0,763 |
| Ganho VGG-16VV | | | | | | | |
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | * | 0,9% | 2,0% | -5,6% | 7,7% | 0,9% | 9,9% |
| LR | * | 0,1% | 0,2% | -7,6% | -22,2% | 0,2% | -2,3% |
| NB | * | -2,3% | -0,5% | 2,7% | -0,6% | -0,3% | 15,6% |
| RF | * | -1,3% | 5,0% | 6,1% | 3,4% | -0,2% | 8,4% |
| SVM | * | -1,2% | 5,1% | -0,7% | 0,8% | -0,2% | 5,5% |
| DT | * | -2,5% | -0,8% | -6,6% | 2,5% | 1,3% | 15,8% |

TABELA 3.6 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG-19, polarização VH e ganho de rendimento em relação a M_{Ref} . O símbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final no método **M6** e (iii) “*” indica ganho não calculado por ser o método de referência.

| Acurácia VGG-19VH | | | | | | | |
|-------------------|-----------|-------|-------|-------|--------|-------|-------|
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | 0,801 | 0,801 | 0,802 | 0,793 | 0,793 | 0,788 | |
| LR | 0,841 | 0,851 | 0,842 | 0,815 | 0,641 | 0,845 | x |
| NB | 0,707 | 0,699 | 0,704 | 0,736 | 0,707 | 0,698 | |
| RF | 0,815 | 0,806 | 0,833 | 0,824 | 0,810 | 0,804 | x |
| SVM | 0,824 | 0,816 | 0,849 | 0,821 | 0,789 | 0,799 | x |
| DT | 0,776 | 0,762 | 0,765 | 0,723 | 0,775 | 0,758 | x |
| ADBST | - | - | 0,768 | 0,708 | 0,770 | 0,752 | |
| NET | - | - | 0,836 | 0,828 | 0,844 | 0,833 | |
| <i>Stack</i> | - | - | - | - | - | - | 0,841 |
| Ganho VGG-19VH | | | | | | | |
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | * | 0,0% | 0,2% | -1,0% | -1,0% | -1,7% | 5,0% |
| LR | * | 1,1% | 0,1% | -3,1% | -23,8% | 0,4% | -1,2% |
| NB | * | -1,2% | -0,5% | 4,1% | 0,0% | -1,3% | 20,3% |
| RF | * | -1,2% | 2,2% | 1,0% | -0,6% | -1,3% | 4,3% |
| SVM | * | -1,0% | 3,0% | -0,3% | -4,3% | -3,1% | 3,0% |
| DT | * | -1,8% | -1,4% | -6,8% | -0,1% | -2,3% | 10,3% |

TABELA 3.7 – Média de acurácia dos resultados dos métodos de classificação empregados para imagens SAR com CNN VGG-19, polarização VV e ganho de rendimento em relação a M_{Ref} . O símbolo (i) “-” indica classificação não utilizada, (ii) “x” indica que os classificadores são combinados para o resultado final do método **M6** e (iii) “*” indica ganho não calculado por ser o método de referência.

| Acurácia VGG-19VV | | | | | | | |
|-------------------|-----------|-------|-------|-------|--------|-------|-------|
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | 0,713 | 0,713 | 0,724 | 0,690 | 0,763 | 0,710 | |
| LR | 0,774 | 0,766 | 0,768 | 0,748 | 0,624 | 0,773 | x |
| NB | 0,643 | 0,653 | 0,652 | 0,705 | 0,658 | 0,657 | |
| RF | 0,719 | 0,717 | 0,751 | 0,757 | 0,742 | 0,727 | x |
| SVM | 0,737 | 0,731 | 0,754 | 0,732 | 0,766 | 0,746 | x |
| DT | 0,670 | 0,667 | 0,663 | 0,641 | 0,706 | 0,692 | x |
| ADBST | - | - | 0,640 | 0,645 | 0,698 | 0,680 | |
| NET | - | - | 0,761 | 0,760 | 0,777 | 0,761 | |
| <i>Stack</i> | - | - | - | - | - | - | 0,761 |
| Ganho VGG-19VV | | | | | | | |
| Classificador | M_{Ref} | M1 | M2 | M3 | M4 | M5 | M6 |
| kNN | * | 0,0% | 1,5% | -3,3% | 7,0% | -0,5% | 6,7% |
| LR | * | -1,0% | -0,8% | -3,3% | -19,4% | -0,2% | -1,7% |
| NB | * | 1,6% | 1,3% | 9,6% | 2,4% | 2,1% | 18,4% |
| RF | * | -0,3% | 4,5% | 5,2% | 3,2% | 1,0% | 5,8% |
| SVM | * | -0,8% | 2,3% | -0,7% | 3,9% | 1,2% | 3,3% |
| DT | * | -0,4% | -1,1% | -4,4% | 5,3% | 3,3% | 13,6% |

TABELA 3.8 – Testes Kruskal-Wallis e Dunn comparando os resultados dos classificadores que apresentaram diferença significativa. Em destaque, as comparações em relação aos resultados reproduzidos de (FALQUETO *et al.*, 2019) (**M1**).

| CNN VGG-16VH | | | | | CNN VGG-19VH | | | | |
|--------------------|---------|--------|--------------|----------------|--------------------|---------|--------|---------|----------------|
| Valor- $p < 0,001$ | | | | | Valor- $p < 0,001$ | | | | |
| Método | Classif | Método | Classif | Valor- p | Método | Classif | Método | Classif | Valor- p |
| 1 | LR | 1 | SVM | <0,001 | 1 | LR | 1 | SVM | <0,001 |
| 1 | SVM | 2 | LR | < 0,001 | 1 | SVM | 2 | SVM | 0,003 |
| 1 | SVM | 2 | SVM | 0,037 | 1 | LR | 3 | RF | < 0,001 |
| 1 | LR | 3 | LR | 0,031 | 2 | LR | 3 | RF | 0,027 |
| 2 | LR | 3 | LR | 0,015 | 2 | SVM | 3 | RF | <0,001 |
| 1 | LR | 3 | RF | < 0,001 | 3 | RF | 4 | NET | 0,030 |
| 2 | LR | 3 | RF | <0,001 | 1 | LR | 4 | RF | < 0,001 |
| 1 | SVM | 4 | NET | 0,013 | 2 | LR | 4 | RF | 0,006 |
| 3 | RF | 4 | NET | 0,029 | 2 | SVM | 4 | RF | <0,001 |
| 1 | LR | 4 | RF | < 0,001 | 4 | NET | 4 | RF | 0,007 |
| 2 | LR | 4 | RF | <0,001 | 1 | SVM | 5 | LR | 0,026 |
| 2 | SVM | 4 | RF | <0,001 | 3 | RF | 5 | LR | 0,002 |
| 4 | NET | 4 | RF | <0,001 | 4 | RF | 5 | LR | <0,001 |
| 1 | SVM | 5 | LR | < 0,001 | | | | | |
| 3 | RF | 5 | LR | <0,001 | | | | | |
| 4 | RF | 5 | LR | <0,001 | | | | | |
| 2 | LR | 5 | NET | 0,026 | | | | | |
| 4 | RF | 5 | NET | 0,031 | | | | | |
| 1 | SVM | 6 | <i>Stack</i> | 0,001 | | | | | |
| 3 | RF | 6 | <i>Stack</i> | 0,003 | | | | | |
| 4 | RF | 6 | <i>Stack</i> | <0,001 | | | | | |
| CNN VGG-16VV | | | | | CNN VGG-19VV | | | | |
| Valor- $p < 0,001$ | | | | | Valor- $p < 0,001$ | | | | |
| Método | Classif | Método | Classif | Valor- p | Método | Classif | Método | Classif | Valor- p |
| 1 | LR | 1 | SVM | <0,001 | 1 | SVM | 2 | LR | 0,012 |
| 1 | SVM | 2 | LR | < 0,001 | 1 | SVM | 4 | NET | < 0,001 |
| 1 | SVM | 2 | NET | < 0,001 | 1 | SVM | 5 | LR | 0,011 |
| 1 | LR | 3 | NET | < 0,001 | | | | | |
| 2 | LR | 3 | NET | <0,001 | | | | | |
| 1 | LR | 3 | RF | < 0,001 | | | | | |
| 2 | LR | 3 | RF | <0,001 | | | | | |
| 1 | LR | 4 | kNN | 0,026 | | | | | |
| 1 | SVM | 4 | kNN | 0,039 | | | | | |
| 2 | LR | 4 | kNN | 0,013 | | | | | |
| 1 | SVM | 4 | NET | < 0,001 | | | | | |
| 3 | NET | 4 | NET | <0,001 | | | | | |
| 3 | RF | 4 | NET | 0,005 | | | | | |
| 1 | SVM | 5 | LR | < 0,001 | | | | | |
| 3 | NET | 5 | LR | <0,001 | | | | | |
| 3 | RF | 5 | LR | <0,001 | | | | | |
| 4 | kNN | 5 | LR | 0,027 | | | | | |
| 1 | SVM | 5 | NET | 0,001 | | | | | |
| 1 | SVM | 6 | <i>Stack</i> | < 0,001 | | | | | |
| 3 | NET | 6 | <i>Stack</i> | 0,002 | | | | | |

TABELA 3.9 – *Ranking* de acurácia e ganho dos classificadores quando comparados com M_{Ref} .

| Maiores acurácias | | | | | | Maiores ganhos | | | | | |
|-------------------|-----|-----|---------|-------|-------|----------------|-----|-----|---------|-------|-------|
| M | VGG | Pol | Classif | Acc | Ganho | M | VGG | Pol | Classif | Acc | Ganho |
| 2 | 16 | VH | LR | 0,855 | -1,1% | 3 | 19 | VV | NB | 0,705 | 9,6% |
| 1 | 16 | VH | LR | 0,852 | -1,4% | 4 | 16 | VV | kNN | 0,748 | 7,7% |
| 1 | 19 | VH | LR | 0,851 | 1,1% | 4 | 19 | VV | kNN | 0,763 | 7,0% |
| 2 | 19 | VH | SVM | 0,849 | 3,0% | 3 | 16 | VV | RF | 0,747 | 6,1% |
| 5 | 16 | VH | LR | 0,846 | -2,1% | 4 | 19 | VV | DT | 0,706 | 5,3% |
| 5 | 19 | VH | LR | 0,845 | 0,4% | 3 | 19 | VV | RF | 0,757 | 5,2% |
| 2 | 19 | VH | LR | 0,842 | 0,1% | 2 | 16 | VV | SVM | 0,760 | 5,1% |
| 2 | 16 | VH | SVM | 0,838 | 4,2% | 2 | 16 | VV | RF | 0,740 | 5,0% |
| 2 | 19 | VH | RF | 0,833 | 2,2% | 2 | 19 | VV | RF | 0,751 | 4,5% |
| 3 | 16 | VH | LR | 0,824 | -4,6% | 2 | 16 | VH | SVM | 0,838 | 4,2% |

TABELA 3.10 – *Ranking* de acurácia considerando os 20 melhores resultados de Acc.

| Método | VGG | Pol | Classificador | Acc |
|--------|-----|-----|---------------|-------|
| 2 | 16 | VH | LR | 0,855 |
| 1 | 16 | VH | LR | 0,852 |
| 1 | 19 | VH | LR | 0,851 |
| 2 | 19 | VH | SVM | 0,849 |
| 5 | 16 | VH | LR | 0,846 |
| 5 | 19 | VH | LR | 0,845 |
| 4 | 19 | VH | NET | 0,844 |
| 6 | 16 | VH | <i>Stack</i> | 0,844 |
| 2 | 19 | VH | LR | 0,842 |
| 6 | 19 | VH | <i>Stack</i> | 0,841 |
| 4 | 16 | VH | NET | 0,840 |
| 2 | 16 | VH | SVM | 0,838 |
| 5 | 19 | VH | NET | 0,833 |
| 5 | 16 | VH | NET | 0,830 |
| 3 | 19 | VH | NET | 0,828 |
| 3 | 16 | VH | LR | 0,824 |
| 3 | 19 | VH | RF | 0,824 |
| 3 | 16 | VH | RF | 0,820 |
| 1 | 19 | VH | SVM | 0,816 |
| 4 | 19 | VH | RF | 0,810 |

4 Conclusão e trabalhos futuros

Esta pesquisa avalia técnicas de ML e DL na classificação de imagens SAR de navios e plataformas petrolíferas. Ela é dividida em seis métodos (M1-M6) considerando CNN (VGG-16 e VGG-19), polarização (VH e VV) e algoritmos classificadores (LR, SVM, RF, NET, kNN, NB, DT, ADBST). Como métrica de avaliação, considera-se a média da acurácia em 50 classificações. Inicialmente as análises e resultados são obtidos, conforme apresenta-se a seguir. O maior nível de acurácia é obtido pelo LR com 85,5%. Ele se destaca como melhor classificador em todas os métodos, exceto no método M4. Em seguida, têm-se o SVM, NET e RF com 84,9%, 84,4% e 81,5%, respectivamente. As variações de parâmetros proporcionam aumento na acurácia. A técnica PCA aumenta a performance do NB e RF. Nos métodos M4 e M5, a combinação dos *data set* permite aumentar a variabilidade das amostras de treinamento, proporcionando maior capacidade de generalização. O uso de técnicas *ensemble adaboost* e *stacking* permitem aumentar a quantidade de métodos de classificação. A técnica *stacking* apresenta melhores resultados que as classificações individuais. Os índices de acurácia superiores a 80% concentram-se no canal de polarização VH e são distribuídos de forma equivalente entre as CNN VGG-16 e VGG-19. As variações de parâmetros proporcionam maiores ganhos de acurácia nas classificações com polarização VV. Posteriormente, utiliza-se a biblioteca Scikit Learning a qual através da otimização de parâmetros proporciona o maior resultado de acurácia com 86,5% para o LR. A pesquisa contribui para ampliação das técnicas de vigilância da Amazônia Azul. As variações de parâmetros e combinações de técnicas permitem obter resultados competitivos em relação aos resultados de (FALQUETO *et al.*, 2019).

Contribuições da dissertação:

- **Artigo publicado:** da Silva, F. G.; Palm, B. G.; Machado, R., “Classificação de Alvos em Imagens SAR com técnicas de Machine Learning”, In: Simpósio de Aplicações Operacionais em Áreas de Defesa SIGE 2021, São José dos Campos, 2021. p. 1-4.
- **Artigo publicado:** da Silva, F.G.; Ramos, L.P.; Palm, B.G.; Machado, R. Assessment of Machine Learning Techniques for Oil Rig Classification in C-Band SAR Images. *Remote Sens.* 2022, 14, 2966. <https://doi.org/10.3390/rs14132966> (SILVA *et al.*, 2022).

- **Artigo aceito:** da Silva, F. G.; Ramos, L. P.; Palm, B. G.; Alves, D. I.; Pettersson, M. I.; Machado, R., “Hybrid Feature Extraction Based on PCA and CNN for Oil Rig Classification in C-Band SAR Imager”, In: SPIE Security + Defence (ESI22D), 2022.

Como trabalhos futuros, elenca-se algumas ideias a seguir:

- Ampliar os tipos de CNN para extração de atributos. Algumas dessas são: SqueezeNet, Inception v3, Painters e DeepLoc;
- Utilizar dados brutos das imagens no lugar de imagens no formato TIFF que geram perdas de informações;
- Avaliar outros formatos de polarização (HH, HV);
- Ampliar o *data set* e avaliar as classificações com número maior de amostras de treinamento e teste;
- Utilizar atributos com decomposição polarimétrica em substituição aos coeficientes de retroespalhamento;
- Utilizar os coeficientes beta e gamma na calibração radiométrica;
- Avaliar o uso da RPCA para extração de atributos.

Referências

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS. (Brasil). **Boletim Mensal da Produção de Petróleo e Gás Natural**. 2021. Disponível em: <<https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/boletins-anp/bmp-2021/2021-07-boletim.pdf>>. Acesso em: 30 jul. 2021.

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS. (Brasil). **Lista de plataformas em operação**. 2021. Disponível em: <<https://www.gov.br/anp/pt-br/centrais-de-conteudo/dados-abertos/lista-de-plataformas-em-operacao>>. Acesso em: 30 abr. 2022.

ALZUBAIDI, L. *et al.* Review of deep learning: Concepts, cnn architectures, challenges, applications, future directions. **Journal of big Data**, Springer, v. 8, n. 1, p. 1–74, 2021.

ARMELENTI, G. *et al.* Deposition, diagenesis and reservoir potential of non-carbonate sedimentary rocks from the rift section of campos basin, brazil. **Petroleum Geoscience**, European Association of Geoscientists & Engineers, v. 22, n. 3, p. 223–239, 2016.

BAEK, W.-K.; JUNG, H.-S. Performance comparison of oil spill and ship classification from x-band dual- and single-polarized sar image using support vector machine, random forest, and deep neural network. **Remote Sensing**, v. 13, n. 16, 2021. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/13/16/3203>>. Acesso em: 25 jun. 2022.

BRAMER, M. **Principles of data mining**. Berlin: Springer, 2007.

BRASIL. Decreto legislativo no 373, de 25 de setembro de 2013 (aprova a política nacional de defesa, a estratégia nacional de defesa e o livro branco de defesa nacional). **Diário Oficial da União**, secão 1, Brasília, DF, n. 1, p. 1, 2013.

BREIMAN, L. Rejoinder: Arcing classifiers. **The Annals of Statistics**, JSTOR, v. 26, n. 3, p. 841–849, 1998.

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

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and regression trees**. New York: Routledge, 1984.

BRUSCH, S. *et al.* Ship surveillance with terrasars-x. **IEEE transactions on geoscience and remote sensing**, IEEE, v. 49, n. 3, p. 1092–1103, 2010.

- CANTORNA, D. *et al.* Oil spill segmentation in sar images using convolutional neural networks. a comparative analysis with clustering and logistic regression algorithms. **Applied Soft Computing**, Elsevier, v. 84, p. 105716, 2019.
- CASTRO, J. D. B. *et al.* A comparative analysis of deep learning techniques for sub-tropical crop types recognition from multitemporal optical/sar image sequences. In: SIBGRAPI CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES, 30., 2017. NITEROI. **Proceedings**. Niteroi: IC-UFF; IEEE, 2017. p. 382–389.
- CHATZIMPARMPAS, A. *et al.* Stackgenvis: Alignment of data, algorithms, and models for stacking ensemble learning using performance metrics. **IEEE Transactions on Visualization and Computer Graphics**, IEEE, v. 27, n. 2, p. 1547–1557, 2020.
- CHEN, S. *et al.* Target classification using the deep convolutional networks for sar images. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 54, n. 8, p. 4806–4817, 2016.
- CRISP, D. **The state-of-the-art in ship detection in Synthetic Aperture Radar imagery**. Edinburgh: DSTO Information Sciences Laboratory, 2004.
- DEMSAR, J. *et al.* Orange: data mining toolbox in python. **the Journal of machine Learning research**, JMLR. org, v. 14, n. 1, p. 2349–2353, 2013. Disponível em: <<http://jmlr.org/papers/v14/demsar13a.html>>. Acesso em: 20 dez. 2021.
- DENG, J. *et al.* Imagenet: A large-scale hierarchical image database. In: **2009 IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2009. p. 248–255.
- DING, J. *et al.* Convolutional neural network with data augmentation for sar target recognition. **IEEE Geoscience and remote sensing letters**, IEEE, v. 13, n. 3, p. 364–368, 2016.
- DINNO, A. Nonparametric pairwise multiple comparisons in independent groups using dunn’s test. **The Stata Journal**, v. 15, n. 1, p. 292–300, 2015.
- EL-DARYMLI, K. *et al.* Target detection in synthetic aperture radar imagery: A state-of-the-art survey. **Journal of Applied Remote Sensing**, v. 7, n. 1, p. 071598, 2013.
- EMAMI, A. *et al.* Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images. **NeuroImage: Clinical**, v. 22, p. 101684, 2019.
- ERSAHIN, K.; CUMMING, I. G.; WARD, R. K. Segmentation and Classification of Polarimetric SAR Data Using Spectral Graph Partitioning. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 48, n. 1, p. 164–174, 2010.
- European Space Agency. **Copernicus Open Access Hub**. Paris: ESA, 2021. Disponível em: <<https://scihub.copernicus.eu/dhus/>>. Acesso em: 25 jun. 2022.
- European Space Agency. **Sentinel**. Paris: ESA, 2022. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-1>>. Acesso em: 30 jun. 2022.
- FALQUETO, L. E. *et al.* Oil rig recognition using convolutional neural network on Sentinel-1 SAR images. **IEEE Geoscience and Remote Sensing Letters**, IEEE, v. 16, n. 8, p. 1329–1333, 2019.

- FALQUETO, L. E. *et al.* **Reconhecimento de alvos artificiais em ambientes complexos por meio de imagens SAR polarimétricas obtidas por plataformas orbitais**. Dissertação (Mestrado) — Instituto Tecnológico de Aeronáutica, 2019.
- FISHER, R. A. Statistical methods for research workers. In: **Breakthroughs in Statistics**. [S.l.]: Springer, 1992. p. 66–70.
- FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. *et al.* **The elements of statistical learning**. New York: Springer, 2001.
- GAO, F. *et al.* A new algorithm for sar image target recognition based on an improved deep convolutional neural network. **Cognitive Computation**, v. 11, n. 6, p. 809–824, 2019.
- GARCÍA, S. *et al.* Advanced nonparametric tests for multiple comparisons in the design of experiments in computational intelligence and data mining: Experimental analysis of power. **Information Sciences**, v. 180, n. 10, p. 2044–2064, 2010. ISSN 0020-0255. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025509005404>>. Acesso em: 20 dez. 2021.
- GEUDTNER, D. *et al.* Copernicus and ESA SAR Missions. In: IEEE RADAR CONFERENCE (RADARCONF21), 2021. ATLANTA. **Proceedings**. [S.l.]: Piscataway: IEEE, 2021. p. 1–6.
- GUO, G. *et al.* KNN model-based approach in classification. In: OTM CONFEDERATED INTERNATIONAL CONFERENCES “ON THE MOVE TO MEANINGFUL INTERNET SYSTEMS”, 2003, CATANIA. **Proceedings**. [S.l.]: New York: Springer, 2003. p. 986–996.
- HIROSE, A. **Complex-valued neural networks: theories and applications**. Singapore: World Scientific, 2003. ISBN 981-238-464-2.
- HUANG, S.-q. *et al.* A novel method for speckle noise reduction and ship target detection in SAR images. **Pattern Recognition**, v. 42, n. 7, p. 1533–1542, 2009.
- HUANG, Z.; PAN, Z.; LEI, B. Transfer learning with deep convolutional neural network for sar target classification with limited labeled data. **Remote Sensing**, v. 9, n. 9, p. 907, 2017.
- IGUAL, L.; SEGUÍ, S. Introduction to data science. In: _____. **Introduction to Data Science: A Python Approach to Concepts, Techniques and Applications**. Cham: Springer International Publishing, 2017. p. 1–4. ISBN 978-3-319-50017-1. Disponível em: <https://doi.org/10.1007/978-3-319-50017-1_1>. Acesso em: 20 dez. 2021.
- IZBICKI, R.; SANTOS, T. M. dos. **Aprendizado de máquina: uma abordagem estatística**. São Carlos: Rafael Izbicki, 2020.
- JAMES, G. *et al.* **An introduction to statistical learning**. Berlin: Springer, 2013.
- JIANG, Y.; LI, W.; LIU, L. R-CenterNet+: Anchor-Free Detector for Ship Detection in SAR Images. **Sensors**, v. 21, n. 17, p. 5693, 2021.

- JOSHI, A. V. **Machine Learning and Artificial Intelligence**. Berlin: Springer, 2020.
- KRAMER, O. **Machine learning for evolution strategies**. [S.l.]: Springer, 2016.
- KRIESEL, D. **A brief introduction on neural networks**. [s.n.], 2007. Disponível em: <<http://www.dkriesel.com>>. Acesso em: 27 jun. 2022.
- KRUSKAL, W. H.; WALLIS, W. A. Use of ranks in one-criterion variance analysis. **Journal of the American Statistical Association**, v. 47, n. 260, p. 583–621, 1952.
- KUBAT, M. **An Introduction to Machine Learning**. New York: Springer, 2017.
- KUCK, T. N. *et al.* A comparative assessment of machine-learning techniques for forest degradation caused by selective logging in an amazon region using multitemporal x-band sar images. **Remote Sensing**, v. 13, n. 17, 2021. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/13/17/3341>>. Acesso em: 27 jun. 2022.
- KUHN, M. *et al.* **Applied predictive modeling**. Berlin: Springer, 2013.
- KUMAR, A. **PCA Explained Variance Concepts with Python**. 2022. Disponível em: <<https://vitalflux.com/pca-explained-variance-concept-python-example/>>. Acesso em: 31 jul. 2022.
- KUMAR, D.; ZHANG, X. Ship Detection Based on Faster R-CNN in SAR Imagery by Anchor Box Optimization. In: INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION AND INFORMATION SCIENCES, 2019, CHENGDU. **Proceedings**. Piscataway: IEEE, 2019.
- KUNCHEVA, L. I. **Combining pattern classifiers: methods and algorithms**. Hoboken: John Wiley & Sons, 2014.
- KUSSUL, N. *et al.* Deep learning classification of land cover and crop types using remote sensing data. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 5, p. 778–782, 2017.
- LANGLEY, P.; IBA, W.; THOMPSON, K. *et al.* An analysis of bayesian classifiers. **Proceedings of the Tenth National Conference on Artificial Intelligence**, v. 90, p. 223–228, 1992.
- LAPINI, A. *et al.* Comparison of machine learning methods applied to SAR images for forest classification in Mediterranean areas. **Remote Sensing**, v. 12, n. 3, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/3/369>>. Acesso em: 27 jun. 2022.
- LEWIS, D. D. Naive (bayes) at forty: The independence assumption in information retrieval. In: EUROPEAN CONFERENCE ON MACHINE LEARNING, 1998, CHEMNITZ. **Proceedings**. Berlin: Springer, 1998. p. 4–15.
- LIANG, X. *et al.* Pol-sar based oil spillage classification with various scenarios of prior knowledge. **IEEE Access**, v. 7, p. 66895–66909, 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8718654>>. Acesso em: 20 jun. 2022.
- LIU, H.; LI, S. Decision fusion of sparse representation and support vector machine for sar image target recognition. **Neurocomputing**, Elsevier, v. 113, p. 97–104, 2013.

- LIU, Y. *et al.* Ship detection and classification on optical remote sensing images using deep learning. **ITM Web of Conferences**, v. 12, p. 05012, 2017.
- LIVINGSTONE, C.; DRAGOSEVIC, M.; CHU, S. **Ship detection and measurement of ship motion by multi-aperture Synthetic Aperture Radar**. Ottawa: Defence Research and Development Canada, 2014. (DRDC–RDDC–2014–R17).
- LOS, H. *et al.* Performance evaluation of quad-pol data compare to dual-pol SAR data for river ice classification. **European Journal of Remote Sensing**, v. 52, n. sup1, p. 79–95, 2019.
- MARINETRAFFIC. **MarineTraffic - Global Ship Tracking Intelligence**. 2021. Disponível em: <<https://www.marinetraffic.com>>. Acesso em: 30 abr. 2022.
- MARINHA DO BRASIL. Comissão Interministerial para os Recursos do Mar. **Amazonia Azul**. Brasília, DF: SECIRM, 2022. Disponível em: <<https://www.marinha.mil.br/secirm/amazoniaazul>>. Acesso em: 30 jun. 2022.
- MARINHA DO BRASIL. Diretoria de Portos e Costas. **Helideques**. Rio de Janeiro: Marinha, 2021. Disponível em: <<https://www.marinha.mil.br/dpc/helideques>>. Acesso em: 10 jun. 2022.
- MENDONÇA, P. M. M. de; SPADINI, A. R.; MILANI, E. J. Exploração na Petrobras: 50 anos de sucesso. **Boletim de geociências da petrobras**, Rio de Janeiro, v. 12, n. 1, p. 9–58, 2003.
- MILICEVI, M. *et al.* Ensemble transfer learning framework for vessel size estimation from 2d images. In: ROJAS, I.; JOYA, G.; CATALA, A. (Ed.). **Advances in Computational Intelligence**. Cham: Springer International Publishing, 2019. p. 258–269. ISBN 978-3-030-20518-8.
- MORAIS, J. M. d. **Petróleo em águas profundas: uma história tecnológica da Petrobras na exploração e produção offshore**. Brasília, DF: Instituto de Pesquisa Econômica Aplicada (Ipea), 2013.
- MOREIRA, A. *et al.* A tutorial on synthetic aperture radar. **IEEE Geoscience and remote sensing magazine**, IEEE, v. 1, n. 1, p. 6–43, 2013.
- MORGAN, D. A. Deep convolutional neural networks for atr from sar imagery. In: ALGORITHMS FOR SYNTHETIC APERTURE RADAR IMAGERY 22, 2015,BALTIMORE. **Proceedings**. Baltimore, SPIE, 2015. v. 9475, p. 94750F.
- MOTIIAN, S. *et al.* **Few-shot adversarial domain adaptation**. Trabalho apresentado no 30 Annual Conference on Neural Information Processing Systems, Long Beach: [s.n.], 2017. (arXiv preprint arXiv:1711.02536).
- MURATA, T. *et al.* Salivary metabolomics with alternative decision tree-based machine learning methods for breast cancer discrimination. **Breast Cancer Research and Treatment**, v. 177, n. 3, p. 591–601, 2019.
- MURPHY, K. P. *et al.* Naive bayes classifiers. **University of British Columbia**, v. 18, n. 60, p. 1–8, 2006.

- NATH, S. S. *et al.* A survey of image classification methods and techniques. In: CONFERENCE ON CONTROL, INSTRUMENTATION, COMMUNICATION AND COMPUTATIONAL TECHNOLOGIES, 2014, KANYAKUMARI DISTRICT. **Proceedings**. [S.l.]: Piscataway: IEEE, 2014. p. 554–557.
- NDIKUMANA, E. *et al.* Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France. **Remote Sensing**, v. 10, n. 8, p. 1217, 2018.
- NGUYEN, G. *et al.* Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. **Artificial Intelligence Review**, Springer, v. 52, n. 1, p. 77–124, 2019.
- PAIVA, F. D. *et al.* Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. **Expert Systems with Applications**, v. 115, p. 635–655, 2019.
- PAN, Z. *et al.* Airplane recognition in TerraSAR-X images via scatter cluster extraction and reweighted sparse representation. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 1, p. 112–116, 2016.
- PASCUAL, D. G. **Artificial intelligence tools: decision support systems in condition monitoring and diagnosis**. Boca Raton: Crc Press, 2015.
- PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.
- POTIN, P. *et al.* Copernicus sentinel-1 constellation mission operations status. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, Yokohama. **Proceedings**. [S.l.]: Piscataway: IEEE, 2019. p. 5385–5388.
- QUINLAN, J. R. **Programs for machine learning**. San Mateo: Morgan Kaufmann, 1993.
- RANE, A.; SANGILI, V. Implementation of improved ship-iceberg classifier using deep learning. **Journal of Intelligent Systems**, v. 29, n. 1, p. 1514–1522, 2020.
- Random forests. In: SAMMUT, C.; WEBB, G. I. (Ed.). **Encyclopedia of Machine Learning**. Boston, MA: Springer, 2010. p. 828–828. ISBN 978-0-387-30164-8. Disponível em: <https://doi.org/10.1007/978-0-387-30164-8_695>. Acesso em: 30 mai. 2022.
- SCHUBERT, A. *et al.* Sentinel-1a product geolocation accuracy: Commissioning phase results. **Remote sensing**, v. 7, n. 7, p. 9431–9449, 2015.
- SCHUMACHER, R.; SCHILLER, J. Non-cooperative target identification of battlefield targets-classification results based on SAR images. In: IEEE INTERNATIONAL RADAR CONFERENCE, 2005, Arlington. **Proceedings**. Piscataway: IEEE, 2005. p. 167–172.
- SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3/4, p. 591–611, 1965.

- SHARIFZADEH, F.; AKBARIZADEH, G.; KAVIAN, Y. S. Ship classification in SAR images using a new hybrid CNN–MLP classifier. **Journal of the Indian Society of Remote Sensing**, v. 47, n. 4, p. 551–562, 2019.
- SILVA, F. G. da *et al.* Assessment of Machine Learning Techniques for Oil Rig Classification in C-Band SAR Images. **Remote Sensing**, v. 14, n. 13, 2022. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/14/13/2966>>. Acesso em: 27 jun. 2022.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.
- SKIENA, S. S. **The data science design manual**. Berlin: Springer, 2017.
- SNOEIJ, P. *et al.* The sentinel-1 radar mission: Status and performance. In: INTERNATIONAL RADAR CONFERENCE SURVEILLANCE FOR A SAFER WORLD BORDEAUX, 2009. **Proceedings**. Piscataway, 2009. p. 1–6.
- SOARES, M. de O. *et al.* **Brazilian Marine Animal Forests: A New World to Discover in the Southwestern Atlantic**. Cham: Springer, 2017. 73–110 p. ISBN 978-3-319-21012-4. Disponível em: <https://doi.org/10.1007/978-3-319-21012-4_51>. Acesso em: 20 mai. 2022.
- SOLBERG, A. H. S. Remote sensing of ocean oil-spill pollution. **Proceedings of the IEEE**, v. 100, n. 10, p. 2931–2945, 2012.
- SUTTON, E. J. *et al.* Breast cancer molecular subtype classifier that incorporates MRI features. **Journal of Magnetic Resonance Imaging**, v. 44, n. 1, p. 122–129, 2016.
- TAGHAVI, M. *et al.* Machine learning-based analysis of ct radiomics model for prediction of colorectal metachronous liver metastases. **Abdominal Radiology**, v. 46, n. 1, p. 249–256, 2021.
- TING, K. M.; WITTEN, I. H. **Stacked Generalization: when does it work?** Department of Computer Science, University of Waik, 1997. Disponível em: <<https://hdl.handle.net/10289/1066>>. Acesso em: 30 jun. 2022.
- TING, K. M.; WITTEN, I. H. Issues in stacked generalization. **Journal of artificial intelligence research**, v. 10, p. 271–289, 1999.
- TORRES, R. *et al.* Gmes sentinel-1 mission. **Remote Sensing of Environment**, v. 120, p. 9–24, 2012.
- USOWICZ, B. Backscattering. In: _____. **Encyclopedia of Agrophysics**. Dordrecht: Springer Netherlands, 2011. p. 59–60. ISBN 978-90-481-3585-1. Disponível em: <https://doi.org/10.1007/978-90-481-3585-1_16>. Acesso em: 30 ago. 2021.
- VALENTINI, G.; MASULLI, F. Ensembles of learning machines. In: ITALIAN WORKSHOP ON NEURAL NETS, 13, 2002, Vietri sul Mare. **Proceedings**. New York: ACM, 2002. p. 3–20. (Lecture Notes in Computer Science, 2486).
- WAGNER, S. A. SAR ATR by a combination of convolutional neural network and support vector machines. **IEEE transactions on Aerospace and Electronic Systems**, v. 52, n. 6, p. 2861–2872, 2016.

- WANG, C. *et al.* When Deep Learning Meets Multi-Task Learning in SAR ATR: Simultaneous Target Recognition and Segmentation. **Remote Sensing**, v. 12, n. 23, p. 3863, 2020.
- WANG, Y. *et al.* Combing single shot multibox detector with transfer learning for ship detection using chinese gaofen-3 images. In: PROGRESS IN ELECTROMAGNETICS RESEARCH SYMPOSIUM-FALL (PIERS-FALL), 2017, SINGAPURA. **Proceedings**. Piscataway: IEEE, 2017. p. 712–716.
- WANG, Y.; WANG, C.; ZHANG, H. Combining a single shot multibox detector with transfer learning for ship detection using sentinel-1 SAR images. **Remote sensing letters**, v. 9, n. 8, p. 780–788, 2018.
- WESTPHAL, E.; SEITZ, H. A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. **Additive Manufacturing**, v. 41, p. 101965, 2021.
- WOLPERT, D. H. Stacked generalization. **Neural networks**, v. 5, n. 2, p. 241–259, 1992.
- WU, X. *et al.* Top 10 algorithms in data mining. **Knowledge and information systems**, v. 14, n. 1, p. 1–37, 2008.
- YAMAGUCHI, Y. **Polarimetric SAR Imaging: Theory and Applications**. Boca Raton: CRC Press, 2020.
- YAN, X. *et al.* A double weighted naive bayes for multi-label classification. In: **Computational Intelligence and Intelligent Systems**. Singapore: Springer Singapore, 2016. p. 382–389. ISBN 978-981-10-0356-1.
- YU, X.; LI, Y.; JIAO, L. SAR automatic target recognition based on classifiers fusion. In: INTERNATIONAL WORKSHOP ON MULTI-PLATFORM/MULTI-SENSOR REMOTE SENSING AND MAPPING, 2011, Xiamen. **Proceedings**. Piscataway, 2011. p. 1–5.
- ZHANG, H. The optimality of naive bayes. In: INTERNATIONAL FLORIDA ARTIFICIAL INTELLIGENCE RESEARCH SOCIETY CONFERENCE, 2004, MIAMI BEACH. **Proceedings**. New York: AIAA, 2004.
- ZHANG, S.; LI, X.; ZONG, M.; ZHU, X.; CHENG, D. Learning k for knn classification. **ACM Transactions on Intelligent Systems and Technology**, v. 8, n. 3, p. 1–19, 2017.
- ZHAO, Q. *et al.* Synthetic aperture radar automatic target recognition with three strategies of learning and representation. **Optical Engineering-Bellingham-International Society for Optical Engineering**, v. 39, n. 5, p. 1230–1244, 2000.
- ZHOU, Z.-H. **Ensemble methods: foundations and algorithms**. [S.l.]: Chapman and Hall/CRC, 2019.

Apêndice A - Tabelas com detalhamento das classificações

Neste apêndice são apresentados nas Tabelas A.1, A.2, A.3, A.4, A.5, A.6 o resumo geral com as métricas AUC, Acc, F1 Score, *Precision* e *Recall* geradas em todas os métodos de classificação.

TABELA A.1 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M1.

| Método | CNN-Pol | Métrica | Classificador | | | | | |
|--------|----------|------------------|---------------|-------|-------|-------|-------|-------|
| | | | kNN | LR | NB | RF | SVM | TREE |
| M1 | VGG-16VH | AUC | 0,837 | 0,928 | 0,738 | 0,876 | 0,897 | 0,719 |
| | | Acc | 0,778 | 0,852 | 0,711 | 0,792 | 0,806 | 0,744 |
| | | F1 | 0,776 | 0,851 | 0,707 | 0,791 | 0,803 | 0,743 |
| | | <i>Precision</i> | 0,782 | 0,855 | 0,721 | 0,795 | 0,826 | 0,747 |
| | | <i>Recall</i> | 0,778 | 0,852 | 0,711 | 0,792 | 0,806 | 0,744 |
| | VGG-16VV | AUC | 0,746 | 0,873 | 0,663 | 0,767 | 0,802 | 0,633 |
| | | Acc | 0,701 | 0,782 | 0,645 | 0,695 | 0,714 | 0,642 |
| | | F1 | 0,700 | 0,781 | 0,638 | 0,694 | 0,712 | 0,641 |
| | | <i>Precision</i> | 0,703 | 0,785 | 0,657 | 0,697 | 0,722 | 0,645 |
| | | <i>Recall</i> | 0,701 | 0,782 | 0,645 | 0,695 | 0,714 | 0,642 |
| | VGG-19VH | AUC | 0,842 | 0,923 | 0,737 | 0,886 | 0,911 | 0,723 |
| | | Acc | 0,801 | 0,851 | 0,699 | 0,806 | 0,816 | 0,762 |
| | | F1 | 0,800 | 0,850 | 0,695 | 0,805 | 0,814 | 0,761 |
| | | <i>Precision</i> | 0,803 | 0,852 | 0,708 | 0,809 | 0,825 | 0,766 |
| | | <i>Recall</i> | 0,801 | 0,851 | 0,699 | 0,806 | 0,816 | 0,762 |
| | VGG-19VV | AUC | 0,761 | 0,850 | 0,679 | 0,793 | 0,809 | 0,652 |
| | | Acc | 0,713 | 0,766 | 0,653 | 0,717 | 0,731 | 0,667 |
| | | F1 | 0,711 | 0,765 | 0,647 | 0,716 | 0,730 | 0,666 |
| | | <i>Precision</i> | 0,718 | 0,769 | 0,666 | 0,720 | 0,734 | 0,670 |
| | | <i>Recall</i> | 0,713 | 0,766 | 0,653 | 0,717 | 0,731 | 0,667 |

TABELA A.2 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M2.

| Método | CNN-Pol | Metric | Classificador | | | | | | | |
|--------|----------|------------------|---------------|-------|-------|-------|-------|-------|-------|-------|
| | | | ADBST | kNN | LR | NB | NET | RF | SVM | TREE |
| M2 | VGG-16VH | AUC | 0,732 | 0,865 | 0,927 | 0,724 | 0,905 | 0,905 | 0,910 | 0,754 |
| | | Acc | 0,732 | 0,792 | 0,855 | 0,696 | 0,838 | 0,818 | 0,838 | 0,738 |
| | | F1 | 0,731 | 0,791 | 0,854 | 0,691 | 0,836 | 0,818 | 0,837 | 0,737 |
| | | <i>Precision</i> | 0,734 | 0,798 | 0,858 | 0,707 | 0,841 | 0,822 | 0,844 | 0,742 |
| | | <i>Recall</i> | 0,732 | 0,792 | 0,855 | 0,696 | 0,838 | 0,818 | 0,838 | 0,738 |
| | VGG-16VV | AUC | 0,650 | 0,752 | 0,868 | 0,674 | 0,851 | 0,825 | 0,835 | 0,654 |
| | | Acc | 0,650 | 0,708 | 0,783 | 0,657 | 0,784 | 0,740 | 0,760 | 0,654 |
| | | F1 | 0,649 | 0,707 | 0,782 | 0,650 | 0,783 | 0,738 | 0,759 | 0,652 |
| | | <i>Precision</i> | 0,652 | 0,710 | 0,786 | 0,669 | 0,788 | 0,744 | 0,765 | 0,656 |
| | | <i>Recall</i> | 0,650 | 0,708 | 0,783 | 0,657 | 0,784 | 0,740 | 0,760 | 0,654 |
| | VGG-19VH | AUC | 0,768 | 0,861 | 0,917 | 0,741 | 0,903 | 0,907 | 0,911 | 0,732 |
| | | Acc | 0,768 | 0,802 | 0,842 | 0,704 | 0,836 | 0,833 | 0,849 | 0,765 |
| | | F1 | 0,767 | 0,802 | 0,841 | 0,699 | 0,835 | 0,833 | 0,848 | 0,764 |
| | | <i>Precision</i> | 0,770 | 0,805 | 0,844 | 0,714 | 0,838 | 0,837 | 0,854 | 0,768 |
| | | <i>Recall</i> | 0,768 | 0,802 | 0,842 | 0,704 | 0,836 | 0,833 | 0,849 | 0,765 |
| | VGG-19VV | AUC | 0,640 | 0,772 | 0,839 | 0,683 | 0,817 | 0,830 | 0,830 | 0,669 |
| | | Acc | 0,640 | 0,728 | 0,765 | 0,652 | 0,761 | 0,751 | 0,754 | 0,663 |
| | | F1 | 0,637 | 0,724 | 0,765 | 0,644 | 0,758 | 0,750 | 0,753 | 0,661 |
| | | <i>Precision</i> | 0,642 | 0,737 | 0,767 | 0,664 | 0,761 | 0,753 | 0,756 | 0,665 |
| | | <i>Recall</i> | 0,640 | 0,728 | 0,765 | 0,652 | 0,761 | 0,751 | 0,754 | 0,663 |

TABELA A.3 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M3.

| Método | CNN-Pol | Métrica | Classificador | | | | | | | |
|--------|----------|------------------|---------------|-------|-------|-------|-------|-------|-------|-------|
| | | | ADBST | kNN | LR | NB | NET | RF | SVM | TREE |
| M3 | VGG-16VH | AUC | 0,726 | 0,804 | 0,890 | 0,796 | 0,890 | 0,899 | 0,901 | 0,735 |
| | | Acc | 0,726 | 0,751 | 0,824 | 0,727 | 0,817 | 0,820 | 0,817 | 0,742 |
| | | F1 | 0,724 | 0,750 | 0,822 | 0,722 | 0,815 | 0,820 | 0,811 | 0,740 |
| | | <i>Precision</i> | 0,730 | 0,757 | 0,826 | 0,734 | 0,820 | 0,824 | 0,823 | 0,745 |
| | | <i>Recall</i> | 0,726 | 0,751 | 0,824 | 0,727 | 0,817 | 0,820 | 0,817 | 0,742 |
| | VGG-16VV | AUC | 0,645 | 0,697 | 0,809 | 0,747 | 0,813 | 0,818 | 0,822 | 0,606 |
| | | Acc | 0,645 | 0,655 | 0,722 | 0,678 | 0,728 | 0,747 | 0,718 | 0,615 |
| | | F1 | 0,642 | 0,654 | 0,721 | 0,676 | 0,727 | 0,744 | 0,705 | 0,613 |
| | | <i>Precision</i> | 0,649 | 0,658 | 0,725 | 0,682 | 0,731 | 0,757 | 0,760 | 0,618 |
| | | <i>Recall</i> | 0,645 | 0,655 | 0,722 | 0,678 | 0,728 | 0,747 | 0,718 | 0,615 |
| | VGG-19VH | AUC | 0,708 | 0,842 | 0,869 | 0,811 | 0,891 | 0,900 | 0,908 | 0,699 |
| | | Acc | 0,708 | 0,793 | 0,815 | 0,736 | 0,828 | 0,824 | 0,821 | 0,723 |
| | | F1 | 0,707 | 0,793 | 0,814 | 0,734 | 0,828 | 0,823 | 0,821 | 0,722 |
| | | <i>Precision</i> | 0,712 | 0,795 | 0,817 | 0,741 | 0,831 | 0,826 | 0,827 | 0,728 |
| | | <i>Recall</i> | 0,708 | 0,793 | 0,815 | 0,736 | 0,828 | 0,824 | 0,821 | 0,723 |
| | VGG-19VV | AUC | 0,645 | 0,733 | 0,814 | 0,767 | 0,836 | 0,830 | 0,846 | 0,629 |
| | | Acc | 0,645 | 0,690 | 0,748 | 0,705 | 0,760 | 0,757 | 0,732 | 0,641 |
| | | F1 | 0,642 | 0,688 | 0,748 | 0,701 | 0,760 | 0,756 | 0,719 | 0,639 |
| | | <i>Precision</i> | 0,649 | 0,694 | 0,750 | 0,714 | 0,762 | 0,759 | 0,773 | 0,644 |
| | | <i>Recall</i> | 0,645 | 0,690 | 0,748 | 0,705 | 0,760 | 0,757 | 0,732 | 0,641 |

TABELA A.4 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M4.

| Método | CNN-Pol | Métrica | Classificador | | | | | | | |
|--------|----------|------------------|---------------|-------|-------|-------|-------|-------|-------|-------|
| | | | ADBST | kNN | LR | NB | NET | RF | SVM | TREE |
| M4 | VGG-16VH | AUC | 0,739 | 0,829 | 0,747 | 0,718 | 0,913 | 0,880 | 0,878 | 0,724 |
| | | Acc | 0,739 | 0,768 | 0,627 | 0,691 | 0,840 | 0,799 | 0,785 | 0,757 |
| | | F1 | 0,738 | 0,767 | 0,578 | 0,686 | 0,839 | 0,798 | 0,784 | 0,756 |
| | | <i>Precision</i> | 0,741 | 0,773 | 0,573 | 0,703 | 0,843 | 0,802 | 0,789 | 0,761 |
| | | <i>Recall</i> | 0,739 | 0,768 | 0,627 | 0,691 | 0,840 | 0,799 | 0,785 | 0,757 |
| | VGG-16VV | AUC | 0,688 | 0,805 | 0,717 | 0,672 | 0,856 | 0,808 | 0,816 | 0,643 |
| | | Acc | 0,688 | 0,748 | 0,608 | 0,656 | 0,776 | 0,728 | 0,729 | 0,676 |
| | | F1 | 0,687 | 0,747 | 0,560 | 0,650 | 0,775 | 0,727 | 0,725 | 0,675 |
| | | <i>Precision</i> | 0,689 | 0,750 | 0,549 | 0,667 | 0,778 | 0,731 | 0,739 | 0,677 |
| | | <i>Recall</i> | 0,688 | 0,748 | 0,608 | 0,656 | 0,776 | 0,728 | 0,729 | 0,676 |
| | VGG-19VH | AUC | 0,770 | 0,855 | 0,785 | 0,736 | 0,924 | 0,893 | 0,884 | 0,733 |
| | | Acc | 0,770 | 0,793 | 0,641 | 0,707 | 0,844 | 0,810 | 0,789 | 0,775 |
| | | F1 | 0,769 | 0,793 | 0,600 | 0,703 | 0,844 | 0,810 | 0,787 | 0,774 |
| | | <i>Precision</i> | 0,774 | 0,796 | 0,595 | 0,719 | 0,847 | 0,813 | 0,797 | 0,778 |
| | | <i>Recall</i> | 0,770 | 0,793 | 0,641 | 0,707 | 0,844 | 0,810 | 0,789 | 0,775 |
| | VGG-19VV | AUC | 0,698 | 0,827 | 0,738 | 0,688 | 0,865 | 0,819 | 0,833 | 0,668 |
| | | Acc | 0,698 | 0,763 | 0,624 | 0,658 | 0,777 | 0,742 | 0,766 | 0,706 |
| | | F1 | 0,697 | 0,763 | 0,582 | 0,653 | 0,777 | 0,741 | 0,764 | 0,705 |
| | | <i>Precision</i> | 0,700 | 0,765 | 0,577 | 0,667 | 0,779 | 0,744 | 0,776 | 0,708 |
| | | <i>Recall</i> | 0,698 | 0,763 | 0,624 | 0,658 | 0,777 | 0,742 | 0,766 | 0,706 |

TABELA A.5 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M5.

| Método | CNN-Pol | Métrica | Classificador | | | | | | | |
|--------|----------|------------------|---------------|-------|-------|-------|-------|-------|-------|-------|
| | | | ADBST | kNN | LR | NB | NET | RF | SVM | TREE |
| M5 | VGG-16VH | AUC | 0,726 | 0,822 | 0,919 | 0,722 | 0,908 | 0,863 | 0,888 | 0,699 |
| | | Acc | 0,726 | 0,772 | 0,846 | 0,687 | 0,830 | 0,780 | 0,792 | 0,724 |
| | | F1 | 0,724 | 0,771 | 0,846 | 0,682 | 0,830 | 0,779 | 0,791 | 0,723 |
| | | <i>Precision</i> | 0,729 | 0,778 | 0,851 | 0,700 | 0,836 | 0,783 | 0,800 | 0,727 |
| | | <i>Recall</i> | 0,726 | 0,772 | 0,846 | 0,687 | 0,830 | 0,780 | 0,792 | 0,724 |
| | VGG-16VV | AUC | 0,667 | 0,754 | 0,862 | 0,679 | 0,829 | 0,778 | 0,810 | 0,647 |
| | | Acc | 0,667 | 0,700 | 0,783 | 0,658 | 0,757 | 0,703 | 0,722 | 0,668 |
| | | F1 | 0,666 | 0,699 | 0,782 | 0,652 | 0,756 | 0,701 | 0,720 | 0,666 |
| | | <i>Precision</i> | 0,670 | 0,702 | 0,785 | 0,668 | 0,759 | 0,705 | 0,728 | 0,671 |
| | | <i>Recall</i> | 0,667 | 0,700 | 0,783 | 0,658 | 0,757 | 0,703 | 0,722 | 0,668 |
| | VGG-19VH | AUC | 0,752 | 0,840 | 0,924 | 0,735 | 0,891 | 0,875 | 0,894 | 0,724 |
| | | Acc | 0,752 | 0,788 | 0,845 | 0,698 | 0,833 | 0,804 | 0,799 | 0,758 |
| | | F1 | 0,751 | 0,787 | 0,844 | 0,693 | 0,832 | 0,804 | 0,797 | 0,757 |
| | | <i>Precision</i> | 0,755 | 0,792 | 0,848 | 0,709 | 0,836 | 0,807 | 0,805 | 0,761 |
| | | <i>Recall</i> | 0,752 | 0,788 | 0,845 | 0,698 | 0,833 | 0,804 | 0,799 | 0,758 |
| | VGG-19VV | AUC | 0,680 | 0,756 | 0,850 | 0,688 | 0,834 | 0,804 | 0,830 | 0,668 |
| | | Acc | 0,680 | 0,710 | 0,773 | 0,657 | 0,761 | 0,727 | 0,746 | 0,692 |
| | | F1 | 0,678 | 0,708 | 0,772 | 0,651 | 0,760 | 0,725 | 0,745 | 0,691 |
| | | <i>Precision</i> | 0,683 | 0,713 | 0,776 | 0,666 | 0,764 | 0,730 | 0,749 | 0,694 |
| | | <i>Recall</i> | 0,680 | 0,710 | 0,773 | 0,657 | 0,761 | 0,727 | 0,746 | 0,692 |

TABELA A.6 – Resumo geral das médias de todas as métricas empregadas por técnicas de classificação no método M6.

| Método | CNN-Pol | AUC | CA | F1 | Precision | Recall |
|--------|----------|-------|-------|-------|-----------|--------|
| M6 | VGG-16VH | 0,917 | 0,844 | 0,842 | 0,856 | 0,844 |
| | VGG-16VV | 0,844 | 0,763 | 0,756 | 0,779 | 0,763 |
| | VGG-19VH | 0,913 | 0,841 | 0,840 | 0,846 | 0,841 |
| | VGG-19VV | 0,841 | 0,761 | 0,757 | 0,772 | 0,761 |

TABELA A.7 – Teste de normalidade Shapiro-Wilk.

| CNN | Pol | Método | Classificador | Valor- <i>p</i> | | | |
|--------|-----|--------|---------------|-----------------|-------|-----|-------|
| VGG-16 | VH | 1 | SVM | 0,719 | | | |
| | | 2 | SVM | 0,095 | | | |
| | | 5 | LR | 0,332 | | | |
| | VV | | 1 | LR | 0,804 | | |
| | | | 1 | SVM | 0,114 | | |
| | | | 2 | LR | 0,623 | | |
| | | | 2 | NET | 0,073 | | |
| | | | 3 | NET | 0,058 | | |
| | | | 3 | RF | 0,156 | | |
| | | | 4 | kNN | 0,692 | | |
| | | | 5 | LR | 0,097 | | |
| | | | 5 | NET | 0,356 | | |
| | | | VGG-19 | VH | 1 | LR | 0,082 |
| | | | | | 1 | SVM | 0,123 |
| | | | | | 2 | SVM | 0,394 |
| 3 | NET | 0,161 | | | | | |
| 4 | RF | 0,112 | | | | | |
| VV | | 5 | | LR | 0,516 | | |
| | | 5 | | NET | 0,124 | | |
| | | 1 | | LR | 0,628 | | |
| | | 1 | | SVM | 0,185 | | |
| | | 3 | | NET | 0,304 | | |
| | | 3 | | RF | 0,941 | | |
| | | 4 | | NET | 0,388 | | |
| | | 5 | | LR | 0,918 | | |
| | | 5 | | NET | 0,068 | | |

TABELA A.8 – Resultados por métricas e parâmetros do classificador SVM.

| | | Classificador SVM | | | | | | |
|----------|------------------|-------------------|---------|---------|---------|---------|---------|---------|
| | | Parâmetros | | | | | | |
| CNN-Pol | Métrica | 1-100-R | 1-100-S | 2-200-R | 2-200-S | 3-200-S | 4-200-S | 5-200-S |
| VGG-16VH | AUC | 0,893 | 0,907 | 0,906 | 0,910 | 0,911 | 0,910 | 0,905 |
| | Acc | 0,798 | 0,825 | 0,813 | 0,833 | 0,836 | 0,838 | 0,836 |
| | F1 | 0,794 | 0,823 | 0,811 | 0,832 | 0,835 | 0,837 | 0,835 |
| | <i>Precision</i> | 0,817 | 0,836 | 0,826 | 0,841 | 0,844 | 0,844 | 0,843 |
| | <i>Recall</i> | 0,798 | 0,825 | 0,813 | 0,833 | 0,836 | 0,838 | 0,836 |
| VGG-16VV | AUC | 0,810 | 0,824 | 0,838 | 0,836 | 0,835 | 0,830 | 0,822 |
| | Acc | 0,721 | 0,733 | 0,746 | 0,754 | 0,760 | 0,757 | 0,749 |
| | F1 | 0,718 | 0,728 | 0,745 | 0,752 | 0,759 | 0,755 | 0,748 |
| | <i>Precision</i> | 0,732 | 0,751 | 0,750 | 0,763 | 0,765 | 0,761 | 0,752 |
| | <i>Recall</i> | 0,721 | 0,733 | 0,746 | 0,754 | 0,760 | 0,757 | 0,749 |
| VGG-19VH | AUC | 0,902 | 0,911 | 0,904 | 0,903 | 0,894 | 0,886 | 0,879 |
| | Acc | 0,806 | 0,849 | 0,815 | 0,835 | 0,825 | 0,819 | 0,818 |
| | F1 | 0,804 | 0,848 | 0,813 | 0,835 | 0,824 | 0,819 | 0,817 |
| | <i>Precision</i> | 0,814 | 0,854 | 0,824 | 0,839 | 0,828 | 0,822 | 0,821 |
| | <i>Recall</i> | 0,806 | 0,849 | 0,815 | 0,835 | 0,825 | 0,819 | 0,818 |
| VGG-19VV | AUC | 0,811 | 0,829 | 0,829 | 0,830 | 0,819 | 0,812 | 0,808 |
| | Acc | 0,727 | 0,743 | 0,752 | 0,754 | 0,750 | 0,749 | 0,747 |
| | F1 | 0,723 | 0,741 | 0,748 | 0,753 | 0,749 | 0,747 | 0,745 |
| | <i>Precision</i> | 0,725 | 0,750 | 0,750 | 0,756 | 0,752 | 0,750 | 0,748 |
| | <i>Recall</i> | 0,727 | 0,743 | 0,752 | 0,754 | 0,750 | 0,749 | 0,747 |

TABELA A.9 – Resultados por métricas e parâmetros do classificador LR.

| | | Classificador LR | | | | | |
|----------|------------------|------------------|-------|-------|-------|-------|-------|
| CNN-Pol | Métricas | Parâmetros | | | | | |
| | | 0.6 | 1 | 10 | 50 | 100 | 200 |
| VGG-16VH | AUC | 0,927 | 0,927 | 0,927 | 0,926 | 0,926 | 0,925 |
| | Acc | 0,854 | 0,855 | 0,852 | 0,853 | 0,851 | 0,852 |
| | F1 | 0,854 | 0,854 | 0,852 | 0,852 | 0,851 | 0,851 |
| | <i>Precision</i> | 0,858 | 0,858 | 0,855 | 0,856 | 0,854 | 0,855 |
| | <i>Recall</i> | 0,854 | 0,855 | 0,852 | 0,853 | 0,851 | 0,852 |
| VGG-16VV | AUC | 0,869 | 0,868 | 0,866 | 0,865 | 0,864 | 0,864 |
| | Acc | 0,781 | 0,783 | 0,782 | 0,782 | 0,780 | 0,781 |
| | F1 | 0,781 | 0,782 | 0,782 | 0,781 | 0,779 | 0,781 |
| | <i>Precision</i> | 0,784 | 0,786 | 0,785 | 0,784 | 0,782 | 0,784 |
| | <i>Recall</i> | 0,781 | 0,783 | 0,782 | 0,782 | 0,780 | 0,781 |
| VGG-19VH | AUC | 0,917 | 0,917 | 0,913 | 0,911 | 0,911 | 0,910 |
| | Acc | 0,842 | 0,842 | 0,841 | 0,840 | 0,840 | 0,839 |
| | F1 | 0,841 | 0,841 | 0,840 | 0,840 | 0,840 | 0,839 |
| | <i>Precision</i> | 0,844 | 0,844 | 0,843 | 0,842 | 0,842 | 0,841 |
| | <i>Recall</i> | 0,842 | 0,842 | 0,841 | 0,840 | 0,840 | 0,839 |
| VGG-19VV | AUC | 0,845 | 0,844 | 0,841 | 0,840 | 0,839 | 0,839 |
| | Acc | 0,768 | 0,767 | 0,764 | 0,764 | 0,765 | 0,764 |
| | F1 | 0,767 | 0,766 | 0,763 | 0,764 | 0,765 | 0,764 |
| | <i>Precision</i> | 0,770 | 0,768 | 0,765 | 0,766 | 0,767 | 0,766 |
| | <i>Recall</i> | 0,768 | 0,767 | 0,764 | 0,764 | 0,765 | 0,764 |

TABELA A.10 – Resultados por métricas e parâmetros do classificador RF.

| | | Classificador RF | | | | | | | |
|----------------|------------------|-------------------------|-----------|------------|------------|------------|------------|------------|------------|
| CNN-Pol | Métricas | Parâmetros | | | | | | | |
| | | 10 | 50 | 100 | 200 | 300 | 400 | 500 | 600 |
| VGG-16VH | AUC | 0,877 | 0,905 | 0,908 | 0,908 | 0,909 | 0,908 | 0,908 | 0,908 |
| | Acc | 0,792 | 0,818 | 0,812 | 0,811 | 0,809 | 0,810 | 0,810 | 0,811 |
| | F1 | 0,791 | 0,818 | 0,811 | 0,810 | 0,808 | 0,809 | 0,809 | 0,810 |
| | <i>Precision</i> | 0,794 | 0,822 | 0,816 | 0,815 | 0,813 | 0,814 | 0,814 | 0,815 |
| | <i>Recall</i> | 0,792 | 0,818 | 0,812 | 0,811 | 0,809 | 0,810 | 0,810 | 0,811 |
| VGG-16VV | AUC | 0,778 | 0,816 | 0,822 | 0,825 | 0,826 | 0,825 | 0,825 | 0,826 |
| | Acc | 0,704 | 0,733 | 0,739 | 0,740 | 0,737 | 0,737 | 0,735 | 0,738 |
| | F1 | 0,703 | 0,732 | 0,737 | 0,738 | 0,736 | 0,736 | 0,734 | 0,736 |
| | <i>Precision</i> | 0,707 | 0,738 | 0,744 | 0,744 | 0,741 | 0,741 | 0,740 | 0,743 |
| | <i>Recall</i> | 0,704 | 0,733 | 0,739 | 0,740 | 0,737 | 0,737 | 0,735 | 0,738 |
| VGG-19VH | AUC | 0,872 | 0,897 | 0,903 | 0,905 | 0,905 | 0,906 | 0,907 | 0,906 |
| | Acc | 0,789 | 0,823 | 0,828 | 0,831 | 0,830 | 0,830 | 0,832 | 0,832 |
| | F1 | 0,788 | 0,820 | 0,827 | 0,830 | 0,829 | 0,828 | 0,830 | 0,831 |
| | <i>Precision</i> | 0,792 | 0,826 | 0,832 | 0,835 | 0,834 | 0,833 | 0,837 | 0,836 |
| | <i>Recall</i> | 0,789 | 0,823 | 0,828 | 0,831 | 0,830 | 0,830 | 0,832 | 0,832 |
| VGG-19VV | AUC | 0,790 | 0,824 | 0,830 | 0,832 | 0,833 | 0,834 | 0,835 | 0,835 |
| | Acc | 0,721 | 0,742 | 0,751 | 0,746 | 0,748 | 0,750 | 0,748 | 0,750 |
| | F1 | 0,718 | 0,741 | 0,750 | 0,745 | 0,747 | 0,749 | 0,748 | 0,749 |
| | <i>Precision</i> | 0,723 | 0,744 | 0,753 | 0,747 | 0,750 | 0,752 | 0,750 | 0,752 |
| | <i>Recall</i> | 0,721 | 0,742 | 0,751 | 0,746 | 0,748 | 0,750 | 0,748 | 0,750 |

TABELA A.11 – Resultados por métricas e parâmetros do classificador RF.

| | | Classificador RF | | | | | | |
|----------------|------------------|-------------------------|------------|------------|-------------|-------------|-------------|-------------|
| | | Parâmetros | | | | | | |
| CNN-Pol | Métricas | 700 | 800 | 900 | 1000 | 1100 | 1200 | 1300 |
| VGG-16VH | AUC | 0,909 | 0,909 | 0,909 | 0,909 | 0,909 | 0,908 | 0,908 |
| | Acc | 0,811 | 0,811 | 0,813 | 0,813 | 0,812 | 0,813 | 0,812 |
| | F1 | 0,811 | 0,811 | 0,812 | 0,812 | 0,811 | 0,812 | 0,811 |
| | <i>Precision</i> | 0,816 | 0,816 | 0,817 | 0,817 | 0,816 | 0,817 | 0,816 |
| | <i>Recall</i> | 0,811 | 0,811 | 0,813 | 0,813 | 0,812 | 0,813 | 0,812 |
| VGG-16VV | AUC | 0,826 | 0,826 | 0,827 | 0,826 | 0,827 | 0,826 | 0,827 |
| | Acc | 0,738 | 0,737 | 0,736 | 0,738 | 0,738 | 0,738 | 0,736 |
| | F1 | 0,736 | 0,735 | 0,735 | 0,736 | 0,737 | 0,736 | 0,735 |
| | <i>Precision</i> | 0,743 | 0,741 | 0,741 | 0,742 | 0,743 | 0,742 | 0,741 |
| | <i>Recall</i> | 0,738 | 0,737 | 0,736 | 0,738 | 0,738 | 0,738 | 0,736 |
| VGG-19VH | AUC | 0,907 | 0,906 | 0,906 | 0,907 | 0,906 | 0,907 | 0,907 |
| | Acc | 0,832 | 0,832 | 0,832 | 0,833 | 0,832 | 0,833 | 0,833 |
| | F1 | 0,831 | 0,832 | 0,831 | 0,832 | 0,832 | 0,833 | 0,832 |
| | <i>Precision</i> | 0,836 | 0,836 | 0,836 | 0,836 | 0,836 | 0,837 | 0,836 |
| | <i>Recall</i> | 0,832 | 0,832 | 0,832 | 0,833 | 0,832 | 0,833 | 0,833 |
| VGG-19VV | AUC | 0,835 | 0,836 | 0,836 | 0,836 | 0,836 | 0,837 | 0,836 |
| | Acc | 0,750 | 0,748 | 0,749 | 0,750 | 0,751 | 0,750 | 0,751 |
| | F1 | 0,749 | 0,747 | 0,748 | 0,749 | 0,750 | 0,749 | 0,750 |
| | <i>Precision</i> | 0,751 | 0,750 | 0,751 | 0,751 | 0,752 | 0,752 | 0,753 |
| | <i>Recall</i> | 0,750 | 0,748 | 0,749 | 0,750 | 0,751 | 0,750 | 0,751 |

TABELA A.12 – Resultados por métricas e parâmetros do classificador kNN.

| | | Classificador kNN | | | | | | | |
|----------|------------------|-------------------|--------|-------|-------|-------|-------|-------|-------|
| CNN-Pol | Métricas | Parâmetros | | | | | | | |
| | | 10-EUC | 10-MAN | 3-EUC | 3-MAN | 5-EUC | 5-MAN | 7-EUC | 7-MAN |
| VGG-16VH | AUC | 0,868 | 0,868 | 0,829 | 0,831 | 0,855 | 0,860 | 0,860 | 0,865 |
| | Acc | 0,785 | 0,785 | 0,776 | 0,776 | 0,782 | 0,789 | 0,784 | 0,792 |
| | F1 | 0,785 | 0,784 | 0,775 | 0,774 | 0,780 | 0,788 | 0,782 | 0,791 |
| | <i>Precision</i> | 0,789 | 0,788 | 0,782 | 0,781 | 0,789 | 0,796 | 0,790 | 0,798 |
| | <i>Recall</i> | 0,785 | 0,785 | 0,776 | 0,776 | 0,782 | 0,789 | 0,784 | 0,792 |
| VGG-16VV | AUC | 0,758 | 0,761 | 0,746 | 0,752 | 0,757 | 0,757 | 0,759 | 0,764 |
| | Acc | 0,682 | 0,692 | 0,700 | 0,708 | 0,693 | 0,690 | 0,695 | 0,699 |
| | F1 | 0,681 | 0,691 | 0,700 | 0,707 | 0,691 | 0,689 | 0,693 | 0,697 |
| | <i>Precision</i> | 0,684 | 0,694 | 0,702 | 0,710 | 0,696 | 0,692 | 0,698 | 0,703 |
| | <i>Recall</i> | 0,682 | 0,692 | 0,700 | 0,708 | 0,693 | 0,690 | 0,695 | 0,699 |
| VGG-19VH | AUC | 0,873 | 0,872 | 0,844 | 0,839 | 0,858 | 0,861 | 0,871 | 0,873 |
| | Acc | 0,793 | 0,788 | 0,799 | 0,797 | 0,795 | 0,802 | 0,794 | 0,799 |
| | F1 | 0,792 | 0,788 | 0,799 | 0,797 | 0,794 | 0,802 | 0,793 | 0,798 |
| | <i>Precision</i> | 0,795 | 0,791 | 0,802 | 0,800 | 0,799 | 0,805 | 0,799 | 0,803 |
| | <i>Recall</i> | 0,793 | 0,788 | 0,799 | 0,797 | 0,795 | 0,802 | 0,794 | 0,799 |
| VGG-19VV | AUC | 0,784 | 0,783 | 0,750 | 0,759 | 0,772 | 0,773 | 0,774 | 0,777 |
| | Acc | 0,710 | 0,706 | 0,712 | 0,724 | 0,728 | 0,720 | 0,712 | 0,712 |
| | F1 | 0,706 | 0,704 | 0,708 | 0,721 | 0,724 | 0,717 | 0,707 | 0,709 |
| | <i>Precision</i> | 0,717 | 0,709 | 0,718 | 0,731 | 0,737 | 0,726 | 0,722 | 0,718 |
| | <i>Recall</i> | 0,710 | 0,706 | 0,712 | 0,724 | 0,728 | 0,720 | 0,712 | 0,712 |

TABELA A.13 – Resultados por métricas e parâmetros do classificador DT.

| | | Classificador DT | | | | |
|----------|------------------|------------------|-------|-------|-------|-------|
| CNN-Pol | Métricas | Parâmetros | | | | |
| | | 2 | 5 | 7 | 10 | 20 |
| VGG-16VH | AUC | 0,709 | 0,737 | 0,754 | 0,777 | 0,801 |
| | Acc | 0,736 | 0,737 | 0,738 | 0,733 | 0,731 |
| | F1 | 0,735 | 0,736 | 0,737 | 0,732 | 0,728 |
| | <i>Precision</i> | 0,738 | 0,740 | 0,742 | 0,737 | 0,738 |
| | <i>Recall</i> | 0,736 | 0,737 | 0,738 | 0,733 | 0,731 |
| VGG-16VV | AUC | 0,629 | 0,654 | 0,665 | 0,674 | 0,705 |
| | Acc | 0,653 | 0,654 | 0,649 | 0,644 | 0,652 |
| | F1 | 0,651 | 0,652 | 0,647 | 0,642 | 0,650 |
| | <i>Precision</i> | 0,655 | 0,656 | 0,652 | 0,647 | 0,657 |
| | <i>Recall</i> | 0,653 | 0,654 | 0,649 | 0,644 | 0,652 |
| VGG-19VH | AUC | 0,732 | 0,755 | 0,767 | 0,790 | 0,823 |
| | Acc | 0,765 | 0,761 | 0,758 | 0,752 | 0,762 |
| | F1 | 0,764 | 0,761 | 0,757 | 0,751 | 0,761 |
| | <i>Precision</i> | 0,768 | 0,764 | 0,761 | 0,755 | 0,767 |
| | <i>Recall</i> | 0,765 | 0,761 | 0,758 | 0,752 | 0,762 |
| VGG-19VV | AUC | 0,646 | 0,669 | 0,682 | 0,699 | 0,724 |
| | Acc | 0,662 | 0,663 | 0,663 | 0,661 | 0,661 |
| | F1 | 0,660 | 0,661 | 0,661 | 0,658 | 0,658 |
| | <i>Precision</i> | 0,664 | 0,665 | 0,665 | 0,665 | 0,662 |
| | <i>Recall</i> | 0,662 | 0,663 | 0,663 | 0,661 | 0,661 |

TABELA A.14 – Resultados por métricas e parâmetros do classificador NET.

| | | Classificador NET | | | |
|----------------|------------------|--------------------------|-----------|------------|------------|
| CNN-Pol | Métricas | Parâmetros | | | |
| | | 10 | 50 | 100 | 200 |
| VGG-16VH | AUC | 0,905 | 0,906 | 0,903 | 0,903 |
| | Acc | 0,837 | 0,835 | 0,838 | 0,838 |
| | F1 | 0,836 | 0,834 | 0,837 | 0,837 |
| | <i>Precision</i> | 0,841 | 0,839 | 0,842 | 0,842 |
| | <i>Recall</i> | 0,837 | 0,835 | 0,838 | 0,838 |
| VGG-16VV | AUC | 0,854 | 0,851 | 0,856 | 0,856 |
| | Acc | 0,775 | 0,784 | 0,781 | 0,781 |
| | F1 | 0,774 | 0,783 | 0,780 | 0,780 |
| | <i>Precision</i> | 0,782 | 0,788 | 0,786 | 0,786 |
| | <i>Recall</i> | 0,775 | 0,784 | 0,781 | 0,781 |
| VGG-19VH | AUC | 0,885 | 0,903 | 0,899 | 0,899 |
| | Acc | 0,823 | 0,836 | 0,830 | 0,830 |
| | F1 | 0,822 | 0,835 | 0,830 | 0,830 |
| | <i>Precision</i> | 0,825 | 0,838 | 0,832 | 0,832 |
| | <i>Recall</i> | 0,823 | 0,836 | 0,830 | 0,830 |
| VGG-19VV | AUC | 0,817 | 0,821 | 0,823 | 0,823 |
| | Acc | 0,761 | 0,752 | 0,757 | 0,757 |
| | F1 | 0,758 | 0,748 | 0,754 | 0,754 |
| | <i>Precision</i> | 0,761 | 0,758 | 0,758 | 0,758 |
| | <i>Recall</i> | 0,761 | 0,752 | 0,757 | 0,757 |

TABELA A.15 – Resultados por métricas e parâmetros do classificador ADBST.

| | | Classificador ADBST | | |
|----------|------------------|---------------------|-------|-------|
| CNN-Pol | Métricas | Parâmetros | | |
| | | 10 | 50 | 100 |
| VGG-16VH | AUC | 0,732 | 0,732 | 0,732 |
| | Acc | 0,732 | 0,732 | 0,732 |
| | F1 | 0,731 | 0,731 | 0,731 |
| | <i>Precision</i> | 0,734 | 0,734 | 0,734 |
| | <i>Recall</i> | 0,732 | 0,732 | 0,732 |
| VGG-16VV | AUC | 0,650 | 0,650 | 0,650 |
| | Acc | 0,650 | 0,650 | 0,650 |
| | F1 | 0,649 | 0,649 | 0,649 |
| | <i>Precision</i> | 0,652 | 0,652 | 0,652 |
| | <i>Recall</i> | 0,650 | 0,650 | 0,650 |
| VGG-19VH | AUC | 0,768 | 0,768 | 0,768 |
| | Acc | 0,768 | 0,768 | 0,768 |
| | F1 | 0,767 | 0,767 | 0,767 |
| | <i>Precision</i> | 0,770 | 0,770 | 0,770 |
| | <i>Recall</i> | 0,768 | 0,768 | 0,768 |
| VGG-19VV | AUC | 0,640 | 0,640 | 0,640 |
| | Acc | 0,640 | 0,640 | 0,640 |
| | F1 | 0,637 | 0,637 | 0,637 |
| | <i>Precision</i> | 0,642 | 0,642 | 0,642 |
| | <i>Recall</i> | 0,640 | 0,640 | 0,640 |

TABELA A.16 – Parâmetros otimizados com a biblioteca Scikit-learn.

| | Função | | | |
|----------------|------------------------|-------------------|--------------------|---------------|
| Legenda | Parâmetros | | | |
| | LogisticRegression | | | |
| | C | penalty | tol | solver |
| LR-default | 1 | l2 | 0.01 | lbfgs |
| LR-1 | 0.2 | l2 | 0.01 | Newton-cg |
| LR-2 | 0.2 | l2 | 0.01 | saga |
| LR-4 | 0.2 | l2 | 0.01 | liblinear |
| | DecisionTreeClassifier | | | |
| | criterion | min-samples-split | Min-samples-leaf | splitter |
| DT-default | gini | 2 | 10 | random |
| DT-2 | entropy | 10 | 5 | random |
| DT-3 | gini | 10 | 1 | best |
| DT-4 | entropy | 2 | 1 | best |
| DT-5 | gini | 5 | 5 | random |
| DT-6 | entropy | 10 | 5 | random |
| DT-7 | gini | 2 | 10 | best |
| | RandomForestClassifier | | | |
| | n-estimators | random-state | max-features | |
| RF-Default | 10 | 0 | auto | |
| RF-30 | 30 | 0 | auto | |
| RF-50 | 50 | 0 | auto | |
| RF-100 | 100 | 0 | auto | |
| | KNeighborsClassifier | | | |
| | N-neighbors | p | weights | |
| kNN-1 | 3 | 2 | uniform | |
| kNN-2 | 10 | 1 | distance | |
| KNN-3 | 3 | 2 | uniform | |
| kNN-4 | 3 | 1 | uniform | |
| | svm.SVC | | | |
| | C | kernel | gamma | probability |
| SVM-1 | 1 | rbf | scale | True |
| SVM-2 | 1 | linear | scale | True |
| SVM-3 | 1 | sigmoid | scale | True |
| | AdaBoostClassifier | | | |
| | n-estimators | algorithm | | |
| ADBST-1 | 150 | SAMME.R | | |
| ADBST-2 | 50 | SAMME | | |
| ADBST-3 | 100 | SAMME | | |
| ADBST-4 | 50 | SAMME.R | | |
| | MLPClassifier | | | |
| | activation | solver | hidden-layer sizes | learning-rate |
| NET-1 | relu | lbfgs | 10 | constant |
| NET-2 | identify | sgd | 10 | adaptive |
| NET-3 | logistic | lbfgs | 50 | adaptive |
| NET-4 | relu | sigmoid | 10 | constant |
| NET-5 | identify | sigmoid | 10 | adaptive |
| NET-6 | identify | adam | 10 | constant |

Apêndice B - Gráficos dos melhores classificadores

Como complemento aos resultados apresentados nas Tabelas do Apêndice A, este apêndice apresenta os gráficos boxplot dos resultados da média de acurácia dos melhores classificadores. Neles é possível observar o limite superior, limite inferior, média e mediana de cada classificador.




FIGURA B.1 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-16VV

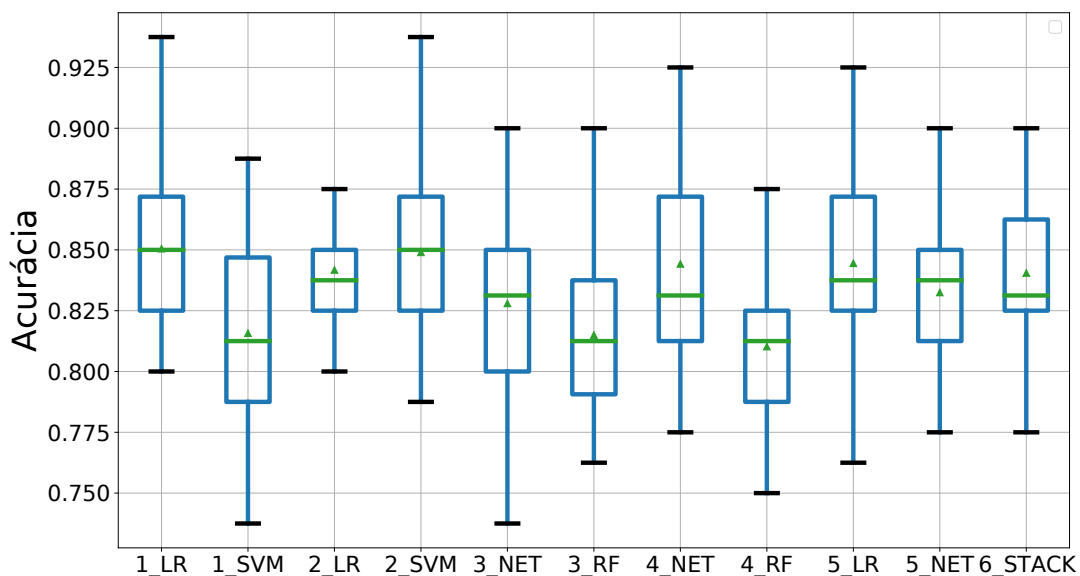


FIGURA B.2 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-19VH




FIGURA B.3 – Boxplot de comparação entre os dois melhores classificadores em cada método - VGG-19VV

Apêndice C - Gráficos de Análises de otimizações

A quantidade de componentes principais permite explicar os atributos de um *data set*. Quanto maior o número de componentes, maior será a representatividade, como visto nas Figuras a seguir.



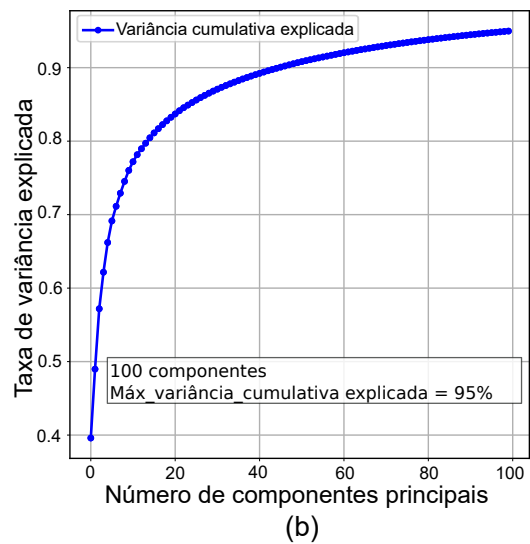
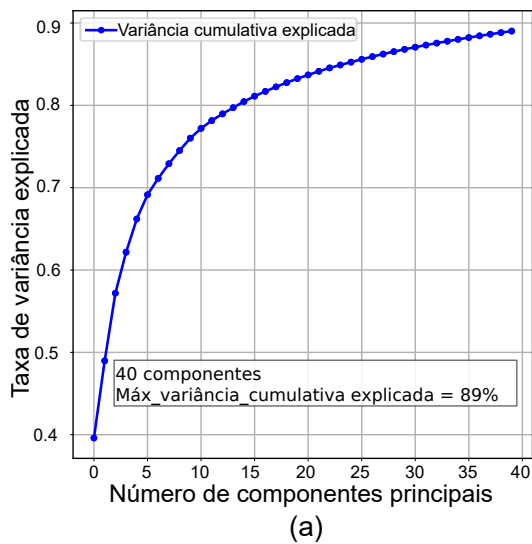





FIGURA C.1 – Variância cumulativa explicada das componentes principais da VGG-16VV. Sendo o valor máximo de variância cumulativa explicada: (a) 89%; (b) 95%; (c) 97%; (d) 98%.



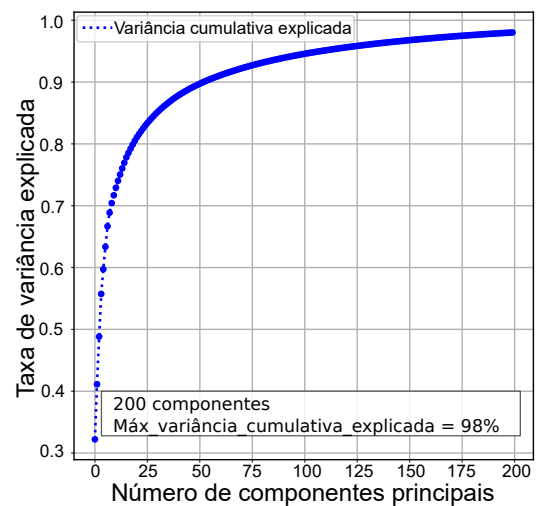
(a)



(b)



(c)



(d)

FIGURA C.2 – Variância cumulativa explicada das componentes principais da VGG-19VH. Sendo o valor máximo de variância cumulativa explicada: (a) 87,7%; (b) 94,5%; (c) 96,7%; (d) 98%.




FIGURA C.3 – Variância cumulativa explicada das componentes principais da VGG-19VV. Sendo o valor máximo de variância cumulativa explicada: (a) 88,6%; (b) 94,9%; (c) 97%; (d) 98,2%.

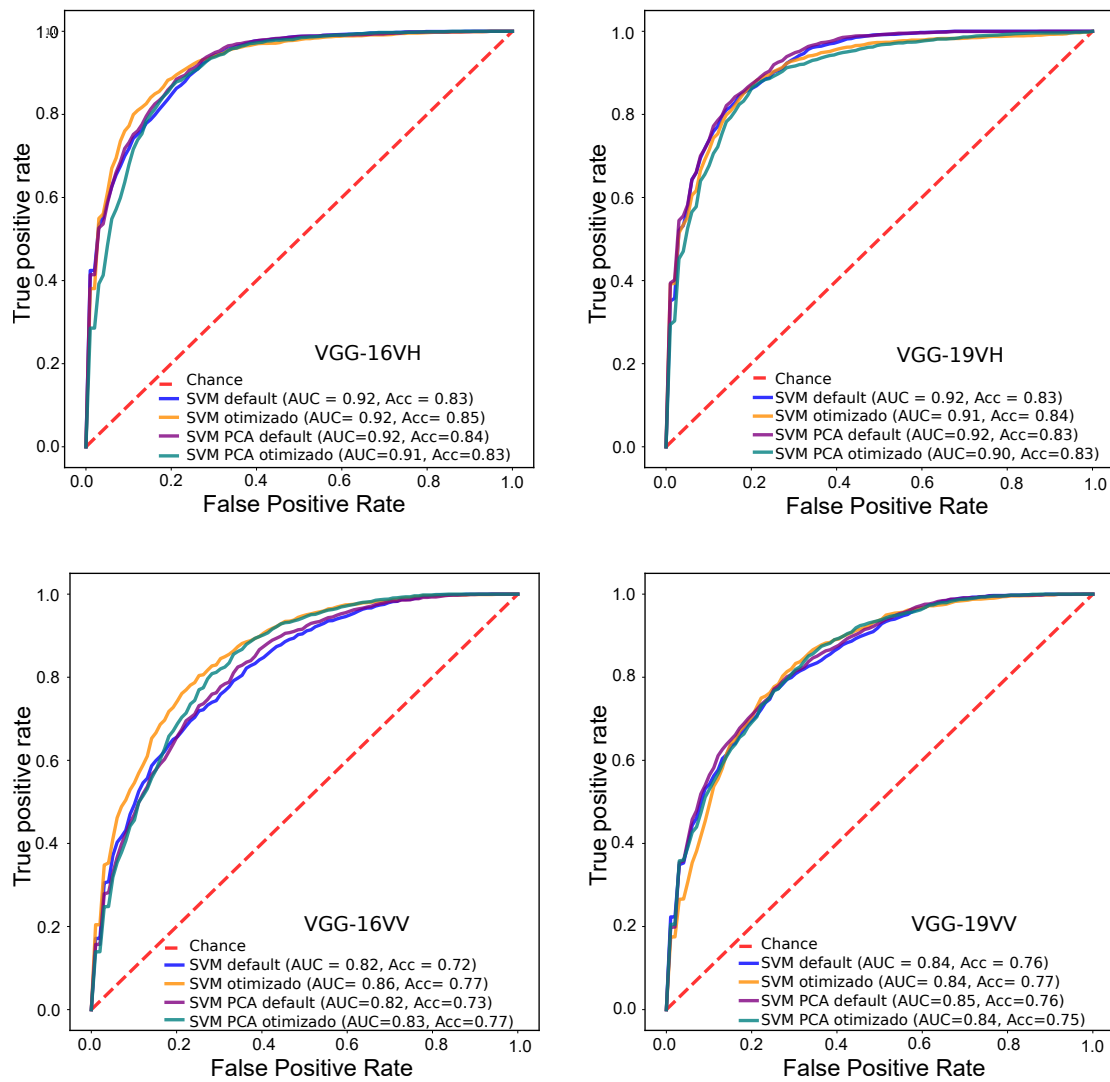


FIGURA C.4 – Curva ROC dos resultados de classificação do SVM considerando as CNN VGG-16/VGG-19 e polarizações VH/VV.

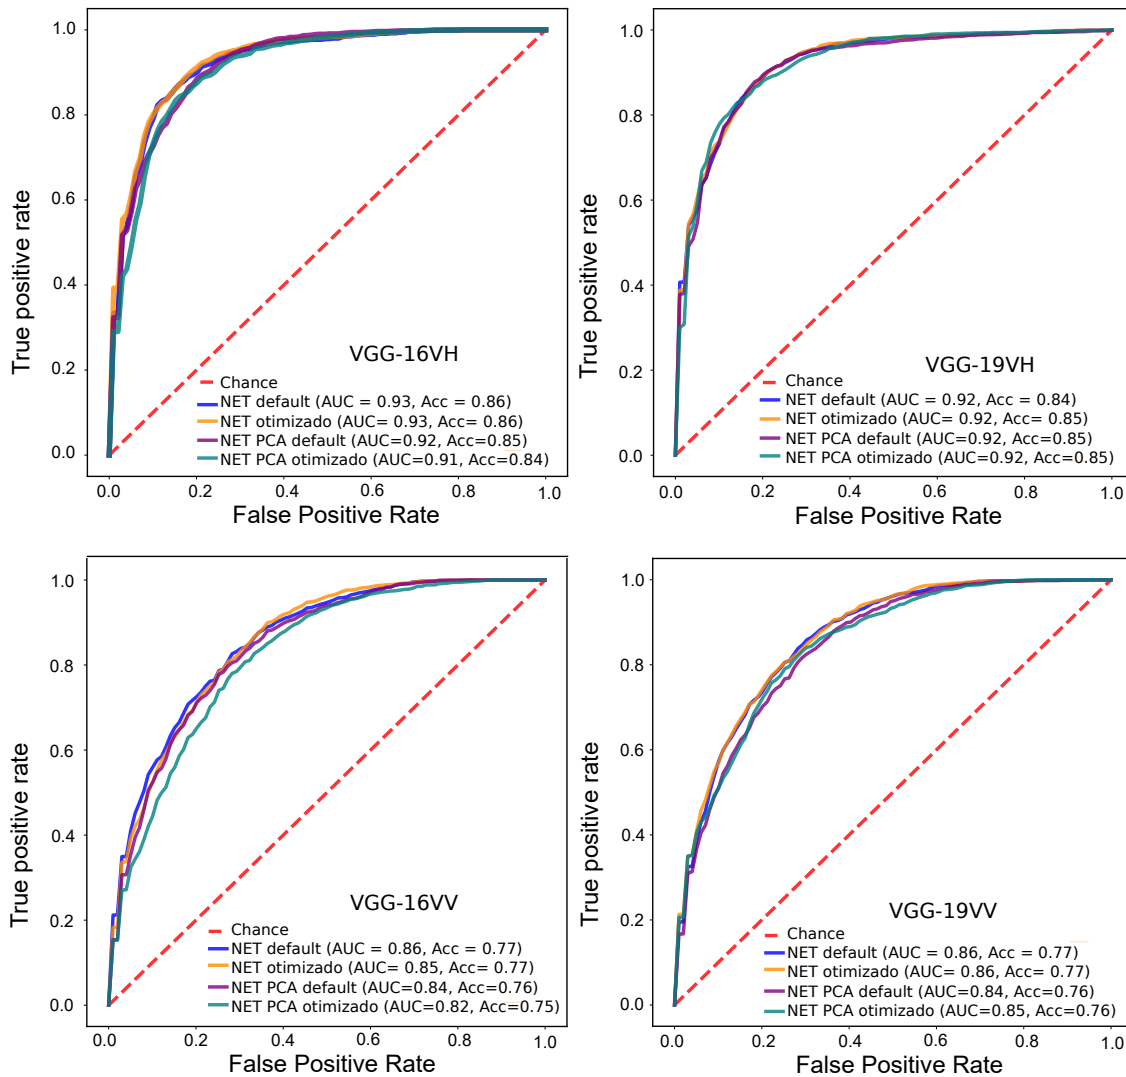


FIGURA C.5 – Curva ROC dos resultados de classificação do NET considerando as CNN VGG-16/VGG-19 e polarizações VH/VV.

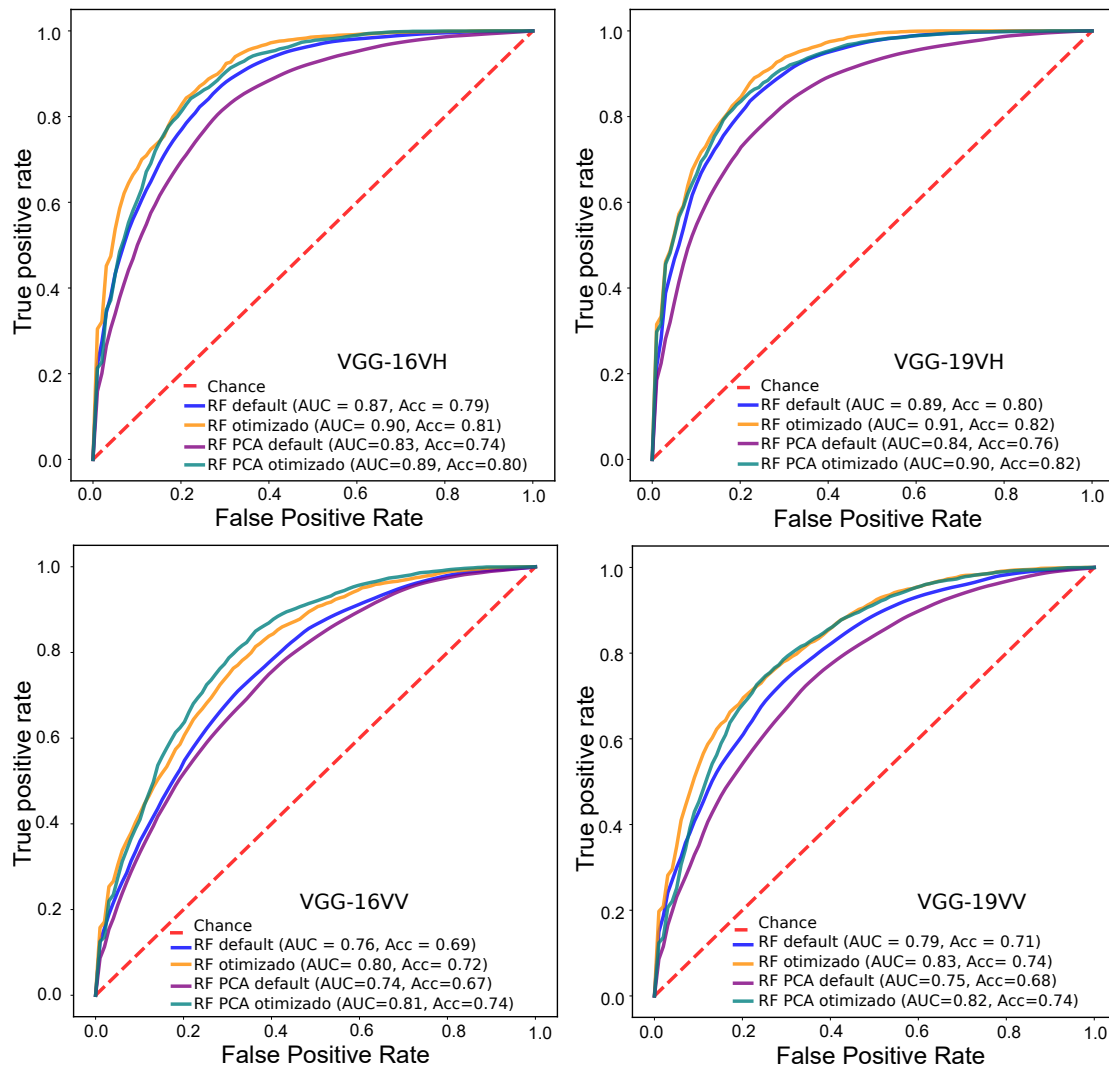


FIGURA C.6 – Curva ROC dos resultados de classificação do RF considerando as CNN VGG-16/VGG-19 e polarizações VH/VV.

FOLHA DE REGISTRO DO DOCUMENTO

| | | | |
|--|--------------------------------|---|-------------------------|
| 1. CLASSIFICAÇÃO/TIPO DM | 2. DATA 26 de julho de 2022 | 3. DOCUMENTO Nº DCTA/ITA/DM-062/2022 | 4. Nº DE PÁGINAS 106 |
| 5. TÍTULO E SUBTÍTULO: Avaliação de Técnicas de <i>Machine Learning</i> na Classificação de Alvos Marítimos em Imagens SAR na Banda C | | | |
| 6. AUTOR(ES): Fabiano Gabriel da Silva | | | |
| 7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica – ITA | | | |
| 8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: SAR; <i>Machine Learning</i> ; <i>Deep Learning</i> | | | |
| 9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Processamento de imagens; Radar de abertura sintética; Aprendizagem(inteligência artificial); Rastreamento (posição); Engenharia eletrônica. | | | |
| 10. APRESENTAÇÃO: <input checked="" type="checkbox"/> Nacional <input type="checkbox"/> Internacional ITA, São José dos Campos. Curso de Mestrado. Programa de Pós-Graduação em Engenharia Eletrônica e Computação. Área de Telecomunicações. Orientador: Prof. Dr. Renato Machado. Coorientadora: Prof ^a . Dr ^a . Bruna Gregory Palm. Defesa em 08/07/2022. Publicada em 2022. | | | |
| 11. RESUMO: Esta pesquisa faz uma avaliação da classificação de alvos em ambiente marítimo através de imagens de radar de abertura sintética - <i>synthetic aperture radar</i> (SAR), técnicas de <i>machine learning</i> (ML) e <i>deep learning</i> (DL). Os alvos de interesse são plataformas e navios localizados na baía de Campos/RJ. Para identificação dos alvos, utiliza-se um banco de imagens SAR polarimétricas vertical-horizontal (VH) e vertical-vertical (VV) obtidas de sensores orbitais do sistema Sentinel-1. Duas redes neurais convolucionais - <i>convolutional neural network</i> (CNN), <i>visual geometry group</i> (VGG), VGG-16 e VGG-19 são utilizadas para vetorização e extração de atributos. A classificação das imagens é dividida em seis formas distintas, considerando as seguintes técnicas de ML: <i>logistic regression</i> (LR), <i>support vector machine</i> (SVM), <i>random forest</i> (RF), <i>k nearest neighbor</i> (kNN), <i>naive Bayes</i> (NB), <i>decision tree</i> (DT), <i>adaboost</i> (ADBOST) e <i>neural network</i> (NET). As amostras são geradas através da técnica <i>bootstrap</i> . Utiliza-se treinamento supervisionado, com 80% das amostras para treino e 20% das amostras para teste. A metodologia considera seis métodos de classificação. Para cada método são realizadas 50 classificações. Todos os classificadores foram avaliados em relação a CNN (VGG-16 e VGG-19) e a polarização (VH e VV). Os maiores níveis de acurácia são obtidos pelo LR com 85,5% e 86,5%. A técnica <i>principal components analysis</i> (PCA) aumenta a performance dos classificadores NB e RF. A combinação dos <i>data sets</i> permite aumentar a variabilidade das amostras de treinamento, proporcionando maior capacidade de generalização. A técnica <i>stacking</i> apresenta melhores resultados que as classificações individuais. Os índices de acurácia superiores a 80% concentram-se no canal de polarização VH e são distribuídos de forma equivalente entre as CNN VGG-16 e VGG-19. Por fim, os resultados foram comparados pelos testes estatísticos Kruskal-Wallis e Dunn que comprovam haver diferença significativa entre os métodos de classificação, ou seja, as otimizações (configurações de parâmetros e combinações de técnicas) proporcionam resultados competitivos com a literatura. Diante disso, a pesquisa contribui para ampliação dos métodos de vigilância da Amazônia Azul através de técnicas de inteligência artificial consideradas estado da arte. | | | |
| 12. GRAU DE SIGILO: <input checked="" type="checkbox"/> OSTENSIVO <input type="checkbox"/> RESERVADO <input type="checkbox"/> SECRETO | | | |