

Monik Silva Sousa

**Detecção e Classificação de Perturbações no  
Meio Aquático via Aprendizado Profundo e  
Rede Neural Artificial Integrada à Métodos  
Estatísticos**

São Luís - MA

Fevereiro de 2023

Monik Silva Sousa

**Detecção e Classificação de Perturbações no Meio Aquático via  
Aprendizado Profundo e Rede Neural Artificial Integrada à  
Métodos Estatísticos**

Dissertação apresentada ao Programa de Pós Graduação em Engenharia Elétrica da UFMA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica. Área de concentração: Engenharia Elétrica.

Universidade Federal do Maranhão  
Centro de Ciências Exatas e Tecnologia  
Programa de Pós Graduação em Engenharia Elétrica

Orientador: Prof(a). Dr. João Viana da Fonseca Neto

São Luís - MA

Fevereiro de 2023

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).  
Diretoria Integrada de Bibliotecas/UFMA

Silva Sousa, Monik.

Detecção e Classificação de Perturbações no Meio Aquático via Aprendizado Profundo e Rede Neural Artificial Integrada à Métodos Estatísticos / Monik Silva Sousa. - 2023.

93 p.

Orientador(a): João Viana da Fonseca Neto.

Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica/ccet, Universidade Federal do Maranhão, São Luís, 2023.

1. Análise Discriminante Linear. 2. Deep Learning. 3. Detecção de Manchas de Óleo. 4. Machine Learning. 5. Rede Neural Artificial. I. Viana da Fonseca Neto, João. II. Título.

Monik Silva Sousa

**Detecção e Classificação de Perturbações no Meio Aquático via  
Aprendizado Profundo e Rede Neural Artificial Integrada à  
Métodos Estatísticos**

Dissertação apresentada ao Programa de Pós  
Graduação em Engenharia Elétrica da UFMA  
como parte dos requisitos necessários para a  
obtenção do grau de Mestre em Engenharia  
Elétrica. Área de concentração: Engenharia  
Elétrica.

Trabalho submetido . São Luís - MA, 10 de fevereiro de 2023

---

**Prof. Dr. João Viana da Fonseca Neto**  
(Orientador)

---

**Prof. Allan Kardec Duailibe Barros Filho**  
(Examinador Interno)

---

**Prof. Raimundo Carlos Silvério Freire**  
(Examinador Externo)

*Este trabalho é dedicado a Deus e a minha família.*

# Agradecimentos

Agradeço ao meu professor e orientador João Viana pela orientação e dedicação aplicadas neste trabalho. Meu agradecimento sincero pelo acompanhamento, pela compreensão, auxílio e tempo despendido durante todo o mestrado, sempre me motivando em todos os momentos em que precisei e que me mostrou os caminhos a serem seguidos.

Aos professores Alcione e Aristofanes pela contribuição nesta pesquisa, toda minha admiração!

Aos Professores Wendell e Lyzette, coordenador e pesquisadora visitante do Programa de Recursos Humanos da ANP, respectivamente.

Aos meus pais, Epitácio Candeira Sousa e Maria de Jesus Silva Costa Sousa e a minha irmã Sárvia Silva Sousa pelo incentivo, apoio e compreensão ao longo destes dois anos, toda minha gratidão!

A minha segunda mãe, Ivanilde Silva Veras, que cuidou de mim e contribuiu para que eu realizasse esse sonho.

Aos meus primos e amigos pela parceria, incentivo e apoio, pelos momentos de diversão.

Ao meu namorado, Cláudio, pela paciência e companheirismo, por nunca me deixar desistir e por ser um dos maiores incentivadores.

Aos meus companheiros do Laboratório de Controle de Processos, Evandro, Denis, Bruno, Yan, Victor e Allan pela ajuda, por todos os ensinamentos que compartilhamos e momentos de descontração.

A todos os professores e colaboradores do Programa de Pós-Graduação em Engenharia de Eletricidade e a Universidade Federal do Maranhão, que de alguma forma contribuíram para o desenvolvimento deste trabalho e ao Programa de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis pelo suporte financeiro.

Ao Laboratório de Sensoriamento Remoto por Radar Aplicado à Indústria do Petróleo (LabSAR) que concedeu-nos o banco de imagens de satélite que foram utilizadas neste trabalho.

A todos que não foram citados, mas que direta ou indiretamente fizeram parte desse trabalho.

*“É muito melhor lançar-se em busca de conquistas grandiosas, mesmo expondo-se ao fracasso, do que alinhar-se com os pobres de espírito, que nem gozam muito nem sofrem muito, porque vivem numa penumbra cinzenta, onde não conhecem nem vitória, nem derrota.”*  
*(Theodore Roosevelt)*



# Resumo

Devido ao crescimento da exploração e do transporte do petróleo aumenta-se também os riscos de acidentes no meio aquático, tornando-se necessário o desenvolvimento de métodos e sistemas que contribuem para redução dos danos causados pelas atividades industriais ao meio ambiente. Nesta dissertação é apresentada uma metodologia para detecção e classificação de perturbações no meio aquático. No intuito de contribuir com uma solução para a questão ambiental e promover o avanço científico e tecnológico pela aplicação de métodos de inteligência artificial e estatística. Especificamente, para detectar manchas de óleo na superfície do oceano. A metodologia desenvolvida baseia-se nas abordagens de aprendizado profundo, rede neural artificial e métodos estatísticos. A partir destas abordagens foram desenvolvidos dois algoritmos para o módulo do crítico (realiza toda a análise exploratória dos dados) de um sistema de tomada de decisão. O primeiro modelo é uma rede neural artificial do tipo *perceptron* que é integrada a métodos estatísticos, no caso, o algoritmo da análise do discriminante linear (LDA) que define uma função discriminante para estimar a classe das imagens, a rede neural do tipo *perceptron* de múltipla camadas (MLP) para detectar/classificar a informação, denominado modelo LDA-MLP. O segundo modelo é uma rede neural que utiliza *deep learning*, arquitetura Unet e é denominado modelo AP-Unet. Para avaliar o desempenho dos classificadores de detecção de manchas de petróleo no oceano, foram utilizadas informações oriundas de um Radar de Abertura Sintética (*Synthetic Aperture Radar* – SAR) processadas pelos classificadores LDA-MLP e AP-Unet. A base de dados utilizada possui 1112 imagens, sendo 880 imagens que apresentam manchas de óleo na superfície do oceano, esse banco de dados é dividido em conjunto de treinamento com 1002 imagens, conjunto de testes com 110 imagens. De posse dos resultados obtidos e realizada a sua análise, conclui-se que os métodos de detecção de mancha de óleo na superfície do oceano propostos conseguem detectar as manchas de óleo com uma boa precisão, comparando os dois métodos observa-se que os dois modelos apresentaram uma precisão muito próxima.

**Palavras-chave:** Análise Discriminante Linear; Detecção de Manchas de Óleo; Machine Learning; Rede Neural Artificial; Deep Learning.

# Abstract

Due to the growth of oil exploration and transportation, the risk of accidents in the aquatic environment also increases, making it necessary to develop methods and systems that created to reduce the damage caused by industrial activities to the environment. In this dissertation a methodology for detection and classification of disturbances in the aquatic environment is presented. In order to contribute to a solution to the environmental issue and promote scientific and technological advancement through the application of artificial intelligence and statistical methods. Specifically, to detect oil slicks on the surface of the ocean. The developed methodology is based on deep learning approaches, artificial neural network and statistical methods. Based on these approaches, two algorithms were combined for the critic module (performs all exploratory data analysis) of a decision-making system. The first model is a perceptron-type artificial neural network that is integrated with statistical methods, in this case the linear discriminant analysis (LDA) algorithm that defines a discriminant function to estimate the class of images, and the perceptron-type neural network of multiple layers (MLP) to detect/classify the information, called LDA-MLP model. The second model is just a neural network that uses deep learning, Unet architecture and is called AP-Unet model. To evaluate the performance of ocean oil slick classifieds, information from a Synthetic Aperture Radar (SAR) processed by LDA-MLP and AP-Unet classifieds was used. The database used has 1112 images, 880 of which show oil slicks on the ocean surface, this database is divided into a training set with 1002 images, and a test set with 110 images. With the results obtained and their analysis carried out, it is concluded that the methods of detecting oil slicks on the surface of the ocean, standards, are able to detect oil slicks with good precision, comparing the two methods observing that the two models showed very close accuracy.

**Keywords:** Linear Discriminant Analysis, Oil Stain Detection, Machine Learning, Artificial Neural Network, Deep Learning.

# Lista de Figuras

Figura 1 - Geometria de iluminação do sistema SAR.....	28
Figura 2 - Diagrama de blocos de um sistema neural.....	38
Figura 3 - Rede perceptron de múltiplas camadas.....	42
Figura 4 – Arquitetura da rede Unet.....	45
Figura 5 - Descrição do sistema de detecção de mancha de óleo na superfície do oceano. ....	50
Figura 6 - Diagrama de blocos do sistema de detecção de mancha de óleo na superfície do oceano.....	51
Figura 7 - Esquema do algoritmo LDA-MLP de detecção de manchas de óleo na superfície do oceano.....	53
Figura 8 - Esquema do algoritmo AP-Unet de detecção de manchas de óleo na superfície do oceano.....	54
Figura 9 - Imagem do banco de dados SAR.....	61
Figura 10 -Máscara do banco de dados SAR.....	61
Figura 11 - Histograma de imagens da superfície do oceano SEM manchas de óleo.....	63
Figura 12 - Histograma de imagens da superfície do oceano COM manchas de óleo.....	64
Figura 13 - Gráfico boxplot dos dois grupos.....	65
Figura 14- Diagrama de blocos do algoritmo LDA-MLP proposto para a classificação.....	66
Figura 15 - Diagrama de blocos da Análise Discriminante Linear – LDA.....	67
Figura 16 - Diagrama de blocos da etapa de classificação.....	68
Figura 17 - Diagrama de blocos do algoritmo de treinamento da rede Perceptron.....	70
Figura 18 - Diagrama de blocos do perceptron.....	71
Figura 19 - Diagrama de blocos da atualização dos pesos sinápticos.....	72
Figura 20- Diagrama de blocos do algoritmo AP-Unet proposto para classificação.....	74
Figura 21 - Imagens redimensionada, (a) sem filtro, (b) com filtro mediana.....	76
Figura 22 - Algoritmo do modelo AP-Unet.....	77
Figura 23 - Curva ROC para o teste do LDA.....	79
Figura 24 - Resposta da rede Unet: (a) imagem SAR, (b) máscara, (c) resposta da rede Unet.....	82
Figura 25 - Resposta da rede Unet: (a) imagem SAR filtrada, (b) máscara, (c) resposta da rede Unet.....	83
Figura 26 - Diagrama de blocos do sistema simplificado de um radar.....	92

# Lista de Tabelas

Tabela 1 - Características da missão SENTINEL-1. ....	30
Tabela 2 - Métricas do teste com o LDA. ....	79
Tabela 3 - Métricas de treino e teste, entrada - imagens. ....	80
Tabela 4 – Métricas de treino e teste, entrada – imagens mais classificação LDA. ....	81
Tabela 5 - Métricas de treino e teste, entrada - imagens mais resposta da função discriminante. ....	81
Tabela 6 - Métricas de teste, entrada sem filtro mediana. ....	82
Tabela 7 - Métricas de teste - dados resultante do filtro mediana. ....	83

# Lista de Abreviaturas e Siglas

ANOVA	<i>Univariate Analysis of Variance</i> (Análise Univariada de Variância)
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
CNN	<i>Convolutional Neural Network</i> (Rede Neural Convolucional)
CP	Componente Principal
DCNN	<i>Deep Convolutional Neural Network</i> (Rede Neural Convolucional Profunda)
FN	<i>False Negative</i> (Falso Negativo)
FP	<i>False Positive</i> (Falso Positivo)
GPUs	<i>Graphic Processing Units</i> (Unidades de Processamento Gráfico)
IA	Inteligência Artificial
LDA	<i>Linear Discriminant Analysis</i> (Análise Discriminante Linear)
LIDAR	<i>Light Detection and Ranging</i> (Detecção de luz e Variação)
MANCOVA	<i>Multivariate Analysis of Covariance</i> (Análise Multivariada de Covariância)
MANOVA	<i>Multivariate Analysis of Variance</i> (Análise Multivariada de Variância)
MLP	<i>Multilayer Perceptron</i> (Perceptron Multicamadas)
PCA	<i>Principal Component Analysis</i> (Análise de Componente Principal)
RNA	Rede Neural Artificial

ROC	<i>Receiver Operating Characteristic</i> (Características operacionais do receptor)
RSSF	Rede de Sensores Sem Fio
SAR	<i>Synthetic Aperture Radar</i> (Radar de Abertura Sintética)
SVM	<i>Support Vector Machines</i> (Máquinas de vetores de suporte)
TN	<i>True Negative</i> (Verdadeiro Positivo)
TP	<i>True Positive</i> (Verdadeiro Positivo)
VANT	Veículo Aéreo não Tripulado

# Sumário

<b>CAPÍTULO 1 - INTRODUÇÃO .....</b>	<b>16</b>
1.1 JUSTIFICATIVAS .....	18
1.2 MOTIVAÇÃO .....	19
1.3 ESTADO DA ARTE.....	20
1.4 OBJETIVOS.....	23
1.4.1 <i>Objetivo Geral</i> .....	23
1.4.2 <i>Objetivos Específicos</i> .....	24
1.5 ORGANIZAÇÃO DA DISSERTAÇÃO .....	24
<b>CAPÍTULO 2 - PRELIMINARES .....</b>	<b>26</b>
2.1 SISTEMAS DE RADAR.....	27
2.1.1 <i>Radar de Abertura Sintética – SAR</i> .....	27
2.1.2 <i>Missão SENTINEL</i> .....	29
2.2 ANÁLISE MULTIVARIADA DE DADOS.....	31
2.2.1 <i>Avaliação dos Dados</i> .....	33
2.2.2 <i>Análise Discriminante Linear</i> .....	35
2.3 APRENDIZADO DE MÁQUINA .....	37
2.3.1 <i>Combinador Linear e Função de Ativação</i> .....	39
2.3.2 <i>Rede Perceptron de uma Única Camada</i> .....	41
2.3.3 <i>Redes Perceptron de Múltiplas Camadas</i> .....	42
2.3.4 <i>Deep Learning (Aprendizado profundo)</i> .....	44
2.4 MÉTRICAS DE AVALIAÇÃO .....	46
<b>CAPÍTULO 3 – MÉTODOS PARA ANÁLISE E CONSTRUÇÃO DE ALGORITMOS PARA O CRÍTICO DE UM SISTEMA DE DETECÇÃO .....</b>	<b>49</b>
3.1 DESCRIÇÃO DO SISTEMA DE DETECÇÃO DE MANCHA DE ÓLEO .....	49
3.2 DIAGRAMA DE BLOCOS DO SISTEMA PROPOSTO.....	51
3.3 O CRÍTICO DE UM SISTEMA DE DETECÇÃO.....	52
3.3.1 <i>Modelo LDA – MLP do Crítico</i> .....	53
3.3.2 <i>Modelo do Crítico via Aprendizado Profundo</i> .....	54
3.3.3 <i>Aquisição</i> .....	55
3.3.4 <i>Reconhecimento de Padrões</i> .....	55
3.3.5 <i>Redes Neurais Artificiais</i> .....	56
3.4 METODOLOGIA PARA EXECUÇÃO DA PESQUISA .....	57

<b>CAPÍTULO 4 – RESULTADOS DA DETECÇÃO E CLASSIFICAÇÃO</b> .....	<b>59</b>
4.1 BASE DE DADOS .....	60
4.2 ANÁLISE ESTATÍSTICA DOS DADOS .....	62
4.2.1 <i>Preparação da base de dados</i> .....	63
4.3 PROJETO DOS CLASSIFICADORES.....	65
4.3.1 <i>Modelo LDA-MLP</i> .....	66
4.3.2 <i>Modelo AP-Unet</i> .....	74
4.4 TESTES DOS CLASSIFICADORES LDA-MLP E AP-UNET.....	78
4.4.1 <i>Resultado do Método LDA-MLP</i> .....	78
4.4.2 <i>Resultado do Modelo AP-Unet</i> .....	81
4.5 ANÁLISE DE DESEMPENHO DOS CLASSIFICADORES.....	84
<b>CAPÍTULO 5 – CONCLUSÃO</b> .....	<b>86</b>
5.1 CONCLUSÕES GERAIS .....	86
5.2 CONTRIBUIÇÕES.....	87
5.3 TRABALHOS FUTUROS .....	88
<b>REFERÊNCIAS</b> .....	<b>89</b>
<b>APÊNDICE I. PRINCÍPIOS DO RADAR</b> .....	<b>92</b>



# Capítulo 1

## Introdução

Tendo como motivação a relevância da preservação do meio ambiente e para contribuir com uma solução para a questão ambiental, uma metodologia e algoritmos para detectar manchas de óleo na superfície do oceano são apresentados nesta dissertação. No contexto de uma dissertação de mestrado, os métodos e algoritmos propostos para detectar estão embasados pelas abordagens de análise multivariada de dados, redes neurais artificiais e aprendizado profundo.

A produção mundial de hidrocarbonetos, em especial o petróleo, teve início em meados do século XIX e desde então tem apresentado um crescimento. Segundo os dados da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), a produção total de petróleo no Brasil em 2019 foi de 161,703 bilhões de litros (1,017 bilhão de barris) (ANP, 2020).

O anuário estatístico brasileiro do petróleo, gás natural e biocombustíveis de 2022, apresenta a evolução desses derivados de hidrocarbonetos no Brasil, com dados de 2012 a 2021. Segundo dados desse anuário a produção de petróleo no mundo aumentou 1,6 % em relação ao ano de 2012, já a produção de petróleo do pré-sal alcançou a média de 333,90 milhões de litros/dia, e a produção de gás natural do pré-sal apresentou um aumento de 67,5 %, o consumo mundial de petróleo totalizou um aumento de 6 %, isso no ano de 2021. Consequentemente, as exportações de petróleo também aumentaram alcançando o valor de 206,70 milhões de litros/dia, já as importações alcançaram 25,949 milhões litros/dia, apresentando um crescimento de 21,2 %.

De acordo com esse crescimento, nas atividades petrolíferas, diversos acidentes têm ocorrido no Brasil e no mundo, com a liberação de substâncias tóxicas ou inflamáveis, causando sérios impactos ambientais a fauna e a flora, bem como mortes e danos à saúde da população que vive nas proximidades do local em que ocorreram os acidentes. Isso tem feito os países aumentarem as exigências ambientais relativas ao transporte marítimo, a operação, o monitoramento e a conservação de dutos destinados ao transporte de hidrocarbonetos.

No ano de 2007 foi instituído, por meio da Resolução ANP nº 43/2007, o Regulamento Técnico do Sistema de Gerenciamento de Segurança Operacional (SGSO), o qual é aplicável às instalações marítimas de perfuração e à produção de petróleo e gás natural, tornando-se um importante instrumento que visa garantir a proteção da vida humana e do meio ambiente (ANP, 2020).

Com o intuito de minimizar os danos causados por acidentes com o petróleo e seus derivados é fundamental investir na prevenção, na detecção, monitoramento e na resposta rápida, com equipes capacitadas e bem treinadas, dispostas de equipamentos e materiais apropriados tanto para conter e recolher as manchas de óleo próximo à fonte poluidora, como nas diversas frentes de trabalho, evitando que áreas sensíveis sejam contaminadas (CETESB, 2020).

De acordo com o levantamento bibliográfico há diversos métodos, ferramentas e técnicas que auxiliam no rastreamento e mapeamento de zonas afetadas pelo derramamento de óleo combustível no mar, uma delas trata-se da análise de imagens capturadas por sensor acoplado ao satélite. Forma mais utilizada atualmente para realizar o mapeamento de derramamento de óleo no meio aquático, devido à sua precisão, maior rapidez na aquisição de dados e à sua grande área de cobertura simultânea (Brink, 2014) (Paravastu , Manoharan, & Manimarabopathy, 2014).

Outra técnica que vem sendo utilizada para o monitoramento do meio aquático são as redes de sensores sem fio (RSSF), os sensores podem ser usados para monitorar ambientes que sejam de difícil acesso ou perigosos, tais como: fundo do oceano, vizinhanças de atividades vulcânicas, áreas de desastres e indústria de exploração e produção de petróleo e gás natural. Para o caso de detecção de manchas de óleo no meio aquático, os sensores ópticos apresentam vantagens, tais como: alta sensibilidade, longo alcance e baixo custo (Paravastu, 2013).

Em consequência, faz-se necessário a intensificação do monitoramento e detecção de manchas de óleo na superfície do mar, diminuindo os impactos ambientais, preservando a vida nos oceanos. Pois, de acordo com Pereira (2001), “os sistemas de detecção de vazamentos não evitam a ocorrência do vazamento, mas permitindo atuar rapidamente, avisando e indicando as situações de vazamento que dependem de outras ações, além da automação (...).”

Em face do exposto nos parágrafos anteriores, especificamente, a proposta apresentada nesta dissertação tem como objetivo o desenvolvimento de dois métodos para detecção e classificação. Estes métodos são baseados na integração de técnicas estatísticas e redes neurais artificiais (RNA), o outro método tem seus fundamentos teóricos baseado em aprendizado profundo. Em termos de aplicação, os algoritmos propostos são customizados para processamento de imagens de satélites para detecção e classificação de manchas de óleo na superfície do oceano.

## 1.1 Justificativas

A maioria dos acidentes com óleos e seus derivados estão relacionados à ocorrência de vazamentos, oriundos de acidentes no transporte ou rompimento da estrutura de seu oleoduto. Oriundos das atividades petrolíferas, uma quantidade considerável de desastres ambientais, tem ocorrido no Brasil. O último caso registrado foi em agosto de 2019, um derramamento de petróleo ou óleo bruto que atingiu a costa brasileira e alcançou 4.334 km uma faixa litorânea de em 11 estados do Nordeste e Sudeste (Pena et al., 2019).

As atividades produtivas do setor de petróleo e gás natural geram elevado crescimento econômico para o país. Porém, grandes impactos ambientais estão aliados a esses processos, como: vazamento de óleo, interferência nos recursos hídricos e insegurança nas comunidades. Os impactos negativos dessas atividades vêm incentivando as empresas a utilizarem métodos e técnicas menos agressivos ao meio ambiente. Além de buscarem sistemas com capacidade de detectar, rastrear e localizar os vazamentos de óleo, para que a empresa possa atuar de maneira rápida e eficaz, reduzindo os danos ao meio ambiente.

Em termos de justificativa para soluções de problemas que envolvem a questão ambiental, uma solução que contribua para evitar a expansão de manchas de óleo a ecossistemas aquáticos é apresentada nesta dissertação. Devido as projeções de crescimento na extração, produção, importação e exportação do petróleo e seus derivados que aumentam a probabilidade de ocorrências de vazamento de óleo, os resultados apresentados nesta dissertação contribuem para minimizar os danos causados ao meio ambiente e a população costeira, justificando o desenvolvimento de geração de conhecimento orientados para proteção do meio ambientes.

## 1.2 Motivação

A maior parte de nossas reservas de petróleo e seus derivados estão em campos marítimos, o que tem levado nossas atividades de perfuração a atingirem profundidades cada vez maiores. Nos próximos cinco anos, está prevista a entrada em operação de mais de uma dezena de novos sistemas de produção, que irão garantir um crescimento de 5 % na produção até 2023 (Petrobras, 2020).

De acordo com o crescimento na produção, consumo, exportações e importações de petróleo, diversos acidentes têm ocorrido no Brasil e no mundo. Portanto, se faz necessário intensificar as exigências ambientais relativas ao transporte marítimo, a operação, o monitoramento e a conservação de dutos destinados ao transporte de hidrocarbonetos.

A motivação científica é a oportunidade de desenvolver pesquisa para resolver o problema de detecção por meio das abordagens de aprendizado de máquinas e das abordagens da análise multivariada de dados, comparar o desempenho destas abordagens para classificar objetos em imagens de satélites. Quanto a motivação social e técnica, os algoritmos propostos podem ser embarcados nos nós das redes de sensores sem fios, sendo possível diminuir os danos causados ao meio ambiente. Com a detecção das manchas de óleo, as organizações de preservação do meio ambiente e gestores das regiões afetadas tem subsídios para elaborar planos de contingências rápidos e eficiente, evitando que o problema ambiental se alastre para uma área maior.

## 1.3 Estado da Arte

Devido a necessidade de um monitoramento e da detecção das anomalias, como manchas de óleo na superfície do meio aquático. Principalmente próximo as indústrias de exploração e refino do petróleo, além das rotas comerciais de navegação dos navios, levantamento e estudo sobre as técnicas para monitoramento e a detecção das manchas de óleo foram realizados. Levando em consideração que esta pesquisa visa a elaboração de algoritmos para a detecção das anomalias na superfície do oceano.

A detecção de manchas de óleo na superfície do oceano tem sido um tema muito estudado atualmente, pois o derramamento de óleo causa um impacto grande tanto para o ecossistema quanto para a população costeira. Portanto, tem-se pesquisado várias técnicas que podem realizar esse objetivo, de detecção das manchas de óleo, também tem-se estudado técnicas de monitoramento das manchas de óleo e detecção de vazamento entre outros ramos de pesquisa. De acordo com levantamento bibliográfico realizado as seguintes técnicas foram analisadas.

No seu trabalho, Mengyue et al (2019), propôs um sistema de reconhecimento facial que consiste em detecção do rosto, extração de recursos e reconhecimento, utilizando a rede neural convolucional multitarefa (*Multi-task convolutional neural network - MTCNN*) sob a estrutura CaffeOnACL para a detecção da face, o padrão binário local (*Local Binary Pattern – LBP*) aplicado como algoritmo de reconhecimento facial. Esse trabalho leva em consideração a velocidade, a estabilidade e a precisão do sistema, pois ele é desenvolvido para ser embarcado.

Em relação a algoritmos para sistemas embarcados, Seung-mok Yoo et al (2019), apresentou seu projeto em andamento, o qual propõe uma estrutura de aprendizado profundo para sistemas embarcados, especialmente veículo automotivos. No seu trabalho ele busca solucionar o desafio que é embarcar uma rede com aprendizado profundo, pois ela exige uma memória grande devido ao banco de dados, um poder computacional com alta velocidade para treinar a rede neural que consiste em várias camadas ocultas. A base do modelo proposto para alcançar esse objetivo é a estrutura do PlaidML, que é o aprendizado profundo baseado em código aberto desenvolvido pela Intel.

Em sua tese de doutorado o autor Carvalho (2015) apresenta a proposta de um método para uma análise exploratória, tendo como objetivo utilizar medidas de satélite para discriminar dois tipos de manchas de óleo: exsudações naturais e derrames operacionais. O algoritmo desenvolvido para executar essa tarefa é baseado em técnicas de análise multivariada, tais como: Correlação (modo-R), Análise de Componentes Principais (PCA) e Função Discriminantes. Nesta pesquisa ele utilizou os coeficientes de retroespalhamento SAR combinados com vários atributos referentes a geometria, a forma e a dimensão que descrevem as manchas de óleo. Os resultados obtidos indicaram que a combinação dessas diversas características com as técnicas propostas é capaz de distinguir o tipo de mancha de óleo, os testes foram realizados na Baía de Campeche (Golfo do México).

Já o autor Kelmas (2015), em seu trabalho, propôs o rastreamento das manchas de óleo e a previsão de suas trajetórias utilizando sensores remotos em satélites e aeronaves, pois eles apresentam um tempo de resposta rápida e imagens frequentes para realizar o monitoramento da dinâmica das manchas, o que ajudam a limitar os danos de um derramamento e facilitar a limpeza e seu controle. Para mostrar a eficácia de sensores remotos durante emergências de derramamento de óleo, o autor realizou um estudo de caso no petroleiro Sea Princess encalhando na costa do País de Gales e a explosão na plataforma Deepwater Horizon no Golfo do México.

No trabalho desenvolvido por Dongmei Song et al (2020), com o título “*A Novel Marine Oil Spillage Identification Scheme Based on Convolution Neural Network Feature Extraction From Fully Polarimetric SAR Imagery*”, que tem como objetivo principal detectar derramamento de óleo baseado na extração de características profundas de uma Rede Neural Convolucional (*Convolutional Neural Network - CNN*), é aplicado a Análise de Componente Principal (*Principal Component Analysis - PCA*) para realizar a redução da dimensão e diminuir a redundância dos dados, antes de classificar os dados por meio do classificador SVM (*Support Vector Machines*). Os resultados obtidos com esse método proposto apresentaram uma boa precisão na classificação, com uma detecção de derramamento de óleo mais exata, ou seja, com baixa taxa de alarmes falsos.

A análise discriminante é muito utilizada para realizar classificação, sendo utilizada até mesmo para classificar tipos de solos. Como foi utilizado no projeto desenvolvido por Sandra Deodoro et al (2020), com o título “Classificação e Mapeamento da Textura Superficial do Solo a partir de Dados de Sensoriamento Remoto e Análise Discriminante, na Região de Volta Grande do Rio Uruguai – Brasil”, que tem como objetivo obter um mapa da textura superficial do solo na região de Volta Grande do Rio Uruguai (SC/RS-Brasil) por meio de amostragem granulométrica, reflectância espectral do solo no sensor MSI (SENTINEL-2), a metodologia aplicada é baseada na obtenção de funções discriminantes para aplicação de um classificador estatístico que, a partir dos dados espectrais de solo, seja capaz de discriminar a textura em areia, silte e argila.

Quanto ao monitoramento da superfície do oceano uma técnica muito utilizada são as imagens do Radar de Abertura Sintética (*Synthetic Aperture Radar* - SAR) que são montadas em aeronaves ou satélites, ele possui uma tecnologia baseada em microondas, na qual emite pulsos de radiação em direção a superfície oceânica e recebe seu reflexo para capturar uma representação da cena, conhecida como imagem SAR.

As manchas de óleo na superfície do oceano são descritas nas imagens SAR, como manchas pretas, pois elas amortecem as ondas capilares e, assim, as ondas de rádio retroespalhada são suprimidas. Portanto, sensor SAR é considerado uma boa opção, pois ele é minimamente afetado por raios de sol e nuvens, possuindo a capacidade de capturar imagens durante todo o dia e em qualquer clima com ampla faixa e alta resolução, além de ser um sistema ativo, isto é, possui sua própria fonte de radiação, não necessitando de uma fonte externa (DONGMEI SONG, 2020).

Outra técnica que vem se destacando nessa área e a de Redes de Sensores sem Fio (RSSF), na qual são redes de dispositivos de sensores autônomos em que a comunicação é realizada através de canais sem fio. Essas redes consistem em vários nós de sensores (estáticos e dinâmicos) com vários sensores por nó que se comunicam entre si e com a estação base através de links de rádio sem fio (Selmic, Phoha, & Serwadda, 2016).

Quanto aos sensores de hidrocarbonetos há uma variedade no mercado que estão sendo utilizados para sensoriamento remoto como: espectrômetro de infravermelho com transformada de Fourier (FTIR), *light detection and Ranging* (LIDAR), fluorômetros, medidor de turbidez

entre outros (Paravastu, 2013). Estes sensores podem ser conectados em boias e quadrimotores para realizar o monitoramento do meio aquático, tanto por medições da visão de cima como da superfície. Logo, esse sistema seria híbrido e se comparado as imagens SAR, ele possui um custo mais acessível.

Recentemente, a Coppe/UFRJ anunciou o desenvolvimento de um sistema capaz de identificar vazamento de óleo nos oceanos, combinando uma embarcação autônoma (ASV) e um drone. O barco autônomo navega pelo mar e o drone levanta voo sozinho e faz uma varredura usando sua câmera térmica. Quando detecta alguma mancha, o drone retorna ao barco que, por sua vez, vai até o local indicado pelo drone e confirma a presença da mancha com seus sensores. A tecnologia, batizada de Ariel, foi contratada pela Repsol Sinopec Brasil, com recursos da cláusula de Pesquisa e Desenvolvimento da Agência Nacional de Petróleo (ANP), está sendo concebida em parceria com as empresas TideWise e Farol. O Ariel é um sistema autônomo e confiável para detectar possível presença de óleo no mar e desempenhar tarefas como levantamento de dados e monitoramento ambiental com baixo custo e redução da exposição de operadores, além de maior precisão na hora de identificar manchas de óleo, eliminando falsos positivos (Marcelo Andreotti & Alessandro Jacoud Peixoto, 2020).

## 1.4 Objetivos

Os objetivos deste trabalho de dissertação estão categorizados em gerais e específicos. Desta forma, distinguem-se pontos abrangentes a serem alcançados para que sejam logrados os fins essenciais.

### 1.4.1 Objetivo Geral

Propor dois métodos, um de integração de técnicas estatísticas e redes neurais artificiais (RNA), outro utilizando *deep learning* (aprendizado profundo), para detecção e classificação de manchas de óleo na superfície do oceano.



## 1.4.2 Objetivos Específicos

- Desenvolver a integração de métodos das abordagens da análise multivariada de dados com redes neurais;
- Compreender e estudar as características dos fenômenos a serem observados, como o petróleo, sua exploração, produção e transporte;
- Desenvolver o algoritmo de integração dos métodos de análise multivariada de dados com redes neurais artificiais e avaliar o desempenho desse método estatístico aplicado para detecção, isto é, classificação das imagens de satélites;
- Desenvolver procedimento e algoritmo utilizando o aprendizado profundo, com a arquitetura Unet e avaliar o desempenho do método de *deep learning* aplicado para detecção das manchas de óleo na superfície do oceano;
- Realizar análise comparativa dos dois métodos proposto para detecção de manchas de óleo na superfície oceânica.

## 1.5 Organização da Dissertação

Neste capítulo é feita uma contextualização com a motivação e os objetivos da pesquisa.

A fundamentação teórica para entendimento e compreensão desta pesquisa é apresentada no Capítulo 2. Neste capítulo é abordado sobre sensoriamento remoto, discorrendo sobre radar de abertura sintética (SAR) e a missão SENTINEL, um pouco da teoria de análise multivariada de dados, dando ênfase às técnicas de reconhecimento de padrão (agrupamento de classes). Ainda neste capítulo é exposto alguns métodos utilizados para avaliar os dados, quanto seu agrupamento nas classes. Outro ponto apresentado no Capítulo 2 é a rede neural artificial, tratando-se a respeito do modelo de um neurônio, das possíveis funções de ativação e dando ênfase a rede *perceptron*, a Unet. E por fim, são expostas as métricas de avaliação, onde é apresentado a precisão, a acurácia, o *recall*, a medida F1 e a curva ROC.

No Capítulo 3 apresenta-se a descrição do sistema de detecção de mancha de óleo na superfície do oceano, com sua interpretação em diagrama de bloco. Outro assunto tratado refere-se aos dois algoritmos propostos para a detecção de mancha de óleo na superfície do oceano, dos passos seguidos.

No Capítulo 4 são apresentados os resultados obtidos através dos experimentos computacionais para os algoritmos de classificação, detecção proposto, que utiliza as técnicas de análise multivariada de dado, rede neural artificial e *deep learning*. Além de expor também a comparação entre os dois métodos. No Capítulo 5 apresenta-se as conclusões do trabalho, a sua contribuição e os trabalhos futuros. Em seguida, citam-se as referências, utilizadas para o desenvolvimento deste trabalho.

# Capítulo 2

## Preliminares

Os tópicos das principais abordagens que são necessários para o desenvolvimento da metodologia e dos algoritmos para detecção de perturbações no meio aquático são apresentados neste capítulo. Este capítulo contém o referencial teórico desta dissertação. Ressalta-se os tópicos de radar de abertura sintética (*Synthetic Aperture Radar - SAR*), de análise multivariada de dados, de redes neurais artificiais (RNA), de aprendizado profundo (*deep learning*) e das métricas de avaliação para classificação das variáveis (objeto) em observação (estudo).

O capítulo é organizado em quatro seções que tratam do sistema de radar, de análise multivariada de dados, de redes neurais artificiais (Aprendizado de Máquina) e de métricas de avaliação da classificação do objetos (variáveis) em estudo. Tópicos em radar de abertura sintética (SAR) e missão SENTINEL são apresentados na Seção 2.1. A avaliação dos dados e análise do discriminante linear da abordagem da análise multivariada de dados são apresentados na Seção 2.2. As redes neurais do tipo *perceptron* de múltiplas camadas e *deep learning* (aprendizado profundo) são os principais tópicos de Aprendizado de Máquina que são apresentados na Seção 2.3. As métricas de avaliação da classificação do objetos são apresentadas na Seção 2.4.

## 2.1 Sistemas de Radar

Nesta seção são apresentados os princípios do radar, dando ênfase ao radar de abertura sintética (SAR) com seu funcionamento, vantagens e desvantagens. Além da missão SENTINEL-1, que utiliza o SAR para o monitoramento de área terrestre e oceânica.


Os sistemas de radar foram inicialmente utilizados para fins militares durante a Segunda Guerra Mundial, na qual tinham como objetivo a detecção e alerta sobre a aproximação de aeronaves hostis e para direcionar as armas. O termo Radar vem do inglês *Radio Detection and Ranging*, que significa detecção e alcance de rádio. Os radares podem ser acoplados em satélites, foguetes ou balões para obter imagens da superfície de uma determinada área que se deseja monitorar. O seu funcionamento é baseado na emissão e na recepção de um sinal, no Apêndice I, esses princípios de funcionamento são detalhados.

### 2.1.1 Radar de Abertura Sintética – SAR

O radar de abertura sintética foi desenvolvido na década de 50 com o propósito de melhorar a resolução da captura sem aumentar o tamanho da antena, pois é tecnologicamente impossível aumentar mais o tamanho da antena. Para isso utilizou o conceito de abertura sintética. Consequentemente, a ideia principal do SAR é sintetizar o efeito de um radar físico de grande abertura, cuja construção é inviável (Tomiyasu, 1978).

As características do SAR são de um radar convencional, porém com visada lateral, isto é, o diagrama de irradiação da antena do radar é disposto obliquamente em relação ao eixo definido pelo vetor velocidade da plataforma na qual esta instalada a antena. Como observa-se na Figura 1 a geometria de iluminação do sistema SAR ao longo de sua trajetória de voo.

Figura 1 - Geometria de iluminação do sistema SAR.



Fonte: (Fernandes & Fernandes, 1998).

De acordo com a Figura 1 o eixo radial é relativo a direção de propagação da onda eletromagnética e o eixo azimutal é relativo a direção de voo. A antena do radar ilumina uma determinada região e a medida que a plataforma com a antena se desloca é iluminada uma faixa nessa região. Durante o deslocamento da antena o sensor SAR transmite pulsos de rádio frequência. O sinal refletido, produzido pelo retro-espalhamento (*backscattering*) da energia transmitida incidente na superfície monitorada, é recebido pela antena do sensor SAR e é enviado ao receptor radar que gera o vídeo bruto (*raw data*). O vídeo bruto é processado e gera a imagem da cena imageada (Tomiyasu, 1978).

O SAR é um sistema ativo, portanto, possui sua própria fonte de radiação, não necessitando de uma fonte externa de energia, isso diferencia ele dos demais sensores ópticos. Conseqüentemente, esse radar pode obter imagens em qualquer horário, inclusive durante a noite, além disso, as microondas facilitam a captura mesmo em dias nublados e com o ar poluído, pois a atenuação desses sinais são relativamente baixa.

A resposta do SAR contém importantes variações do nível de discretização que podem ocorrer entre células de resolução adjacentes. Ao considerar que a célula de resolução de uma cena imageada possui um número muito grande de elementos difusores, estes elementos são responsáveis pela formação de cada pixel da imagem, que estão aleatoriamente distribuídos. Os

retroespalhamentos de cada um destes elementos interferem entre si construtivamente, fazendo aparecer variações súbitas de intensidade da imagem, caracterizando o ruído *speckle* (ESA, 2004). Esse ruído é a desvantagem do sistema SAR, pois ele dificulta a interpretação das imagens, pois causa nestas uma textura granulada.

O radar de abertura sintética está envolvido em grandes projetos de monitoramento da superfície terrestre e oceânica, como a missão SENTINEL.

### 2.1.2 Missão SENTINEL

A série de satélites SENTINEL se desenvolveu a partir de um projeto da Agência Espacial Europeia (ESA)/Comissão Europeia em atendimento ao Programa Copernicus. Essa série começou a ser lançada em 2014, tem como objetivo dar continuidade a algumas missões antigas gerenciadas pela ESA, como ERS, ENVISAT e SPOT ao monitorar os recursos naturais terrestres, o uso e a ocupação das terras, os ambientes marinhos, o clima e os desastres naturais. Essa missão é denominada Global Monitoring for Environment and Security (GMES) e em 2012 passou a se chamar SENTINEL (Embrapa, 2020).

A missão é constituída por uma série de pares de satélites especializados, apropriados para o monitoramento da área de interesse, que pode ser terrestre, oceânico, de vegetação, de solo, de áreas costeiras, marinho e de qualidade do ar, isto é, cada satélite é apto para monitorar uma determinada área e leva consigo o sensor pertinente ao que se deseja observar.

Os satélites SENTINEL-1 são aplicados ao monitoramento terrestre e oceânico e levam a bordo sensores de radar. O primeiro satélite dessa série foi o SENTINEL-1A, equipado com o sensor de radar SAR, um sensor de abertura sintética que opera na banda C (entre 4 e 8 GHz ou 7,5 e 3,8 cm) lançado em 2014. O satélite SENTINEL-1B foi lançado em 2016, leva a bordo também o mesmo sensor, mas porta outros instrumentos como sensores de identificação de embarcação, entre outros equipamentos de diversas agências de pesquisa europeias (da Dinamarca) e Escola Politécnica de Turin (Itália) ((ESA), Sentinel-1, s.d.). A Tabela 1 apresenta as características dessa missão SENTINEL-1.

Tabela 1 - Características da missão SENTINEL-1.

<b>MISSÃO SENTINEL-1</b>		
<b>Instituições Responsáveis</b>	ESA (European Space Program)	
<b>País/Região</b>	Europa	
<b>Satélite</b>	SENTINEL-1 <sup>a</sup>	SENTINEL-1B
<b>Lançamento</b>	03/04/2014	22/04/2016
<b>Local de Lançamento</b>	Kourou (Guiana Francesa)	Kourou (Guiana Francesa)
<b>Veículo Lançador</b>	Soyuz	Soyuz
<b>Situação Atual</b>	Ativo	Ativo
<b>Órbita</b>	Polar, heliossíncrona	Polar, heliossíncrona
<b>Altitude</b>	693 km	693 km
<b>Inclinação</b>	98,18°	99,2°
<b>Tempo de Duração da Órbita</b>	97,7 min	97,2 min
<b>Horário de Passagem</b>	6:00 P.M.	6:00 P.M.
<b>Período de Revista</b>	12 dias	12 dias
<b>Tempo de Vida Projetado</b>	12 dias	12 dias
<b>Instrumentos Sensores</b>	SAR	SAR

Fonte: (Embrapa, 2020).

De acordo com as características da missão SENTINEL-1, apresentadas na Tabela 1, ela é uma missão de imagens de radar dia e noite em órbita polar para todos os climas, para serviços terrestres e oceânicos. O SENTINEL-1A foi lançado em 3 de abril de 2014 e o SENTINEL-1B em 25 de abril de 2016. Ambos foram colocados em órbita em um foguete Soyuz do espaçoporto europeu na Guiana Francesa. A missão do SENTINEL-1B terminou em 2022 e existem planos para lançar o SENTINEL-1C o mais rápido possível.

A missão SENTINEL tem outros pares de satélites como o SENTINEL-2 direcionado ao monitoramento do solo, da vegetação e de áreas costeiras, o SENTINEL-3 adequado para o monitoramento marinho, as séries 4 e 5 aplicados ao monitoramento da qualidade do ar (Embrapa, 2020).

## 2.2 Análise Multivariada de Dados

Nesta seção é apresentado uma técnica estatística, que é a análise multivariada de dados, dando ênfase para o método de análise discriminante linear (*Linear Discriminant Analysis - LDA*). Além de ressaltar sobre a avaliação de dados, que é uma etapa fundamental antes de aplicar qualquer análise na base de dados.

Atualmente as pessoas estão cercadas de muita informações, essas informações estão sendo coletadas e armazenadas em um banco de dados, estando disponível para serem compreendidas e utilizadas para fins de melhorias na tomada de decisões. Por exemplo, a missão de um satélite captura um banco de imagens que são armazenadas. Em um segundo momento, essas informações do banco de dados são utilizadas para elaborar um modelo preditivo e/ou para treinar uma rede para detectar manchas de óleo na superfície oceânica.

Parte dessa informação coletada pode ser analisada e compreendida com estatística simples, mas uma grande porção demanda técnicas estatísticas multivariadas mais complexas para converter tais dados em conhecimento, contribuindo para uma tomada de decisão mais segura, pois será baseada em dados e fatos.

A análise multivariada refere-se a todas as técnicas estatísticas que simultaneamente analisam múltiplas medidas sobre indivíduos ou objetos sob investigação, a partir delas as organizações criam conhecimento, melhorando assim sua tomada de decisão (Joseph F. Hair, Black, Babin, Anderson, & Tatham, 2009). Alguns autores estabelecem que o objetivo da análise multivariada é medir, explicar e prever o grau de relação entre variáveis estatísticas (combinações ponderadas de variáveis). Assim, o caráter multivariado reside nas múltiplas variáveis estatísticas (combinações múltiplas de variáveis), não somente no número de variáveis ou observações.

Os métodos da análise multivariada de dados irão influenciar não apenas nos aspectos analíticos da pesquisa, mas também no planejamento e na abordagem da coleta de dados para a tomada de decisões e resolução de problemas. A seleção adequada da técnica multivariada para um problema vai depender se as variáveis podem ser divididas em independentes e dependentes, se podem, quantas podem ser tratadas como dependentes e se como as variáveis são medidas



(se são métricas ou não-métricas) (Joseph F. Hair, Black, Babin, Anderson, & Tatham, 2009). As técnicas multivariadas são:

- Análise de componentes principais e análise dos fatores comuns,
- Regressão múltipla,
- Análise discriminante múltipla e regressão logística,
- Análise de correlação canônica,
- Análise multivariada de variância e covariância,
- Análise conjunta,
- Análise de agrupamentos,
- Mapeamento perceptual, também conhecido como escalonamento multidimensional,
- Análise de correspondência,
- Modelagem de equações estruturais e análise fatorial confirmatória.

Para construir um modelo multivariados, com um bom desempenho, é preciso definir primeiro o problema que se deseja resolver, os objetivos de análise em termos conceituais, antes mesmo de especificar quaisquer variáveis ou medidas, com base nisso selecionar a técnica multivariada apropriada para o problema em questão. Depois de selecionado a técnica, a atenção volta-se para a implementação, na qual é necessário desenvolver o plano de análise, que aborda questões particulares ao seu propósito e projeto. O terceiro passo já com os dados coletados é realizar a avaliação das suposições subjacentes, como de normalidade multivariada, linearidade e igualdade de variância.

O quarto passo é a estimação do modelo multivariado, depois que o modelo é estimado, uma avaliação do ajuste geral deve ser realizada para se atingir níveis aceitáveis sobre os critérios estatísticos, se identifica as relações propostas e se tem significância prática. Depois de obter um nível aceitável de ajuste do modelo, é preciso interpretar a(s) variável(eis) estatística(s) e revelar a natureza da relação multivariada. Por último, antes de aceitar os resultados, tem que submetê-los a um conjunto final de análise diagnósticas que avaliem o grau de generalidade dos resultados pelos métodos de validação do modelo multivariado.

## 2.2.1 Avaliação dos Dados

A avaliação dos dados é o terceiro passo na análise multivariada de dados, ela é realizada depois que os dados já são coletados e armazenados em um banco, analisando-os antes da aplicação de qualquer técnica multivariada, pois a partir dela é possível ter uma visão crítica das características dos dados e das relações entre variáveis, contribuindo para especificação e refinamento do modelo multivariado. Além de contribuir na interpretação dos resultados. Essa análise de dados assegura que os dados inerentes à análise atendem todas as exigências para uma análise multivariada, que os resultados obtidos a partir dessa análise são válidos e precisos (Joseph F. Hair, Black, Babin, Anderson, & Tatham, 2009).

Sem essa avaliação dos dados é possível que o resultado da análise multivariada apresente perturbações, isto é, que dados perdidos insiram um viés nas correlações entre variáveis ou que variáveis não-normais invalidem os resultados. Consequentemente, afim de evitar esses problemas é fundamental realizar o exame dos dados, no qual será reconhecido o problema e corrigido antes que a análise multivariada seja executada, umas das análises realizadas são: análise de normalidade, análise de homocedasticidade.

A análise de normalidade é fundamental em análise multivariada, refere-se a forma de distribuição dos dados para uma variável métrica individual e sua correspondência com a distribuição normal, que é o padrão de referência para métodos estatísticos. Essa análise é realizada de forma gráfica, na qual se dar pela verificação visual do histograma que compara os valores de dados observados com uma distribuição aproximadamente normal (Joseph F. Hair, Black, Babin, Anderson, & Tatham, 2009).

Além de analisar o histograma da distribuição dos dados pode-se usar testes estatísticos para avaliar a normalidade, como o teste de Kolmogorov-Smirnov, o teste de Shapiro-Wilk e o teste Jarque-Bera que são testes não-paramétricos de aderência para uma amostra, pois têm como objetivo comparar a distribuição acumulada de uma variável com uma determinada distribuição teórica específica, que nesse caso é a distribuição normal.

A análise de homocedasticidade verifica a variância ao longo do domínio das variáveis preditoras, quando a dispersão (variância) dos valores da variável dependente for relativamente semelhante em cada valor da variável preditora, isto é, quando a variância pertence constante ao longo de um domínio de variáveis preditoras, diz-se que os dados são homoscedásticos. Já quando essa dispersão for desigual ao longo de valores da variável independente, ou seja, a variância for crescente ou flutuante, diz-se que os dados são heteroscedásticos (Joseph F. Hair, Black, Babin, Anderson, & Tatham, 2009).

A análise multivariada de variância (MANOVA – *multivariate analysis of variance*) é uma técnica estatística utilizada para explorar simultaneamente as relações entre diversas variáveis independentes categóricas (geralmente chamadas de tratamentos) e duas ou mais variáveis dependentes métricas. Como tal, representa uma extensão da análise univariada de variância (ANOVA – *univariate analysis of variance*). A análise multivariada de covariância (MANCOVA – *multivariate analysis of covariance*) pode ser usada em conjunção com MANOVA para remover (após o experimento) o efeito de quaisquer variáveis independentes métricas não controladas (conhecidas como covariáveis estatísticas) sobre as variáveis dependentes.

O teste gráfico de igualdade de dispersão de variância é melhor representado pelos gráficos de caixas, no qual ilustram o grau de variação entre grupos formados por uma variável categórica, o comprimento da caixa e os *whiskers* (bigodes) retratam, cada um, a variação dos dados dentro daquele grupo. Assim, heteroscedasticidade seria retratada por diferenças substanciais no comprimento das caixas e *whiskers* entre grupos que representam a dispersão de observações em cada grupo.

Assim como na análise de normalidade é recomendável realizar também os testes estatísticos para igual dispersão de variância para avaliar a igualdade de variâncias dentro de grupos formados por variáveis não-métricas. O teste mais comum é o teste Levene utilizado para avaliar se as variâncias de uma única variável métrica são iguais em qualquer número de grupos. Se mais do que uma variável métrica está sendo testada, de forma que a comparação envolve a igualdade de matrizes de variância/covariância, o teste M de Box é aplicável (Joseph F. Hair, Black, Babin, Anderson, & Tatham, 2009).

## 2.2.2 Análise Discriminante Linear

A Análise Discriminate Linear (*Linear Discriminant Analysis* - LDA) tem como objetivo através das variáveis independentes distinguir os grupos (categorias) da variável dependente, ou seja, esta pretende descobrir as características (variáveis explicativas) que distinguem os membros de um grupo dos de outro, de forma que conhecidas as características de um novo caso (indivíduo), seja possível classificar a que grupo da variável dependente pertencerá.

O problema de discriminação entre dois grupos ou mais, foi abordado inicialmente por Fisher, no ano de 1936. Este problema consiste em obter-se uma combinação linear de características observadas que apresente maior poder de discriminação entre as populações, esta combinação é denominada de função discriminante. Consequentemente, a função discriminante tem a propriedade de minimizar as probabilidades de má classificação, quando estas são normalmente distribuídas com média  $\mu$  e a variância  $\Sigma$  conhecidas (Rezende, Filho, & Vieira, 2019).

Para atingir esse objetivo tem-se as seguintes etapas: a primeira etapa é calcular a média das classes e a média global; a segunda etapa é calcular a matriz de covariância das classes para em seguida calcular a matriz de covariância comum das classes; a terceira etapa é calcular o vetor discriminante e o ponto médio entre as médias das populações; e a quarta e última etapa é construir uma equação diferencial que produza uma separação entre as classes de forma satisfatória, aumentando a variância entre as classes e minimiza a variância dentro das classes (Richard O. Duda, 2001).

Considerando que se tem um conjunto com  $n$  imagens e deseja separá-las em duas classes, sendo que a classe  $C_1$  tem  $n_1$  imagens e a classe  $C_2$  tem  $n_2$  imagens, a média de cada classe é dado por

$$\mu_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_j, \quad (1)$$

sendo  $\mu_j$  a média da classe  $j$ ,  $n_j$  o número de imagens da classe  $j$  e  $x_j$  as imagens da classe  $j$ .

Em seguida, no intuito de verificar a dispersão dos dados da classe em questão, calcula-se a matriz de covariância de cada classe, que é dada por

$$cov_j = \frac{(x_j - \mu_j)(x_j - \mu_j)'}{n_j - 1}, \quad (2)$$

sendo  $x_j$  as dados da classe  $j$  e  $\mu_j$  a sua média,  $n_j$  o número de amostras da classe  $j$  e  $cov_j$  a matriz de covariância da classe  $j$ . Portanto, deseja que essa dispersão dentro da classe seja a mínima possível, para que a função discriminante de Fisher possa minimizar as probabilidades de má classificação.

No caso particular da função de Fisher assume-se que as matrizes de covariância são iguais, podendo ser estimada uma matriz comum de covariância para duas classes, que é dada por

$$\Sigma = \left[ \frac{(n_1 - 1)}{(n_1 - 1) + (n_2 - 1)} \right] cov_1 + \left[ \frac{(n_2 - 1)}{(n_1 - 1) + (n_2 - 1)} \right] cov_2, \quad (3)$$

sendo  $\Sigma$  a estimativa da matriz comum de covariância de duas classes,  $cov_1$  e  $cov_2$  as matrizes de covariância da classe  $C_1$  e da classe  $C_2$ , respectivamente. Portanto, a função discriminante linear de Fisher é dada por

$$D(x) = L'x, \quad (4)$$

sendo  $x$  o vetor de característica da população e  $L$  o vetor discriminante estimado para duas classes que é dado por

$$L = (\mu_1 - \mu_2)' \Sigma^{-1}. \quad (5)$$

Em seguida é necessário calcular o ponto médio entre as médias de duas populações, para aplicar a regra de classificação baseada na função discriminante de Fisher, é dada por

$$m = \frac{1}{2}(\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2), \quad (6)$$

e a regra de classificação é dada por

$$\begin{cases} x \text{ pertence a } C_1 \text{ se } D(x) \geq m \\ x \text{ pertence a } C_2 \text{ se } D(x) < m \end{cases} \quad (7)$$

O que se deseja desse classificador é que apresente pouca probabilidade de má classificação, pois sabe-se que no mundo real a fronteira entre regiões não está exatamente definida e sempre haverá superposição, isto é, erro de classificação (Varella, 2020).

## 2.3 Aprendizado de Máquina

Inicialmente, nesta seção é apresentada a contextualização das abordagens de aprendizado de máquina que são utilizadas nesta dissertação, tais como: combinador linear e função de ativação, esse conjunto é conhecido como modelo de um neurônio. A partir desse modelo de neurônio foram desenvolvidas as redes neurais artificiais, como o *perceptron* de uma única camada, ou com múltiplas camadas, que também são apresentadas nesta seção, além de relatar sobre o aprendizado profundo, com a rede Unet.


O homem sempre quis uma máquina que conseguisse imitar suas capacidades mentais, ou seja, que fizesse o trabalho de agir e pensar como um ser humano. Mas foi após a Segunda Guerra Mundial que a inteligência artificial (IA) começou a ser abordada e desde então foi ganhando espaço na ciência e tecnologia, hoje a IA é um campo próspero com muitas aplicações práticas e tópicos de pesquisa ativos. Um dos campos da IA é o aprendizado de máquina que é essencialmente uma forma de estatística aplicada com maior ênfase no uso de computadores para estimar estatisticamente funções complicadas e um menor destaque em provar intervalos de confiança em torno dessas funções (Goodfellow, Bengio, & Courville, 2016).

Portanto, a procura constante por *software* inteligente capaz de automatizar os trabalhos de rotina, compreender a fala ou imagens, fazer diagnósticos entre outras atividades foi o que impulsionou o desenvolvimento das redes neurais artificiais (aprendizado de máquina). Uma Rede Neural Artificial (RNA) pode ser vista como um modelo matemático composto de

elementos computacionais lineares ou não, chamados neurônios, trabalhando em paralelo e massivamente conectados por ligações caracterizadas por diferentes pesos denominados de sinapses (Haykin, 2008).

A RNA assemelha-se ao cérebro, pois ela é capaz de interagir com o ambiente ao qual está inserida, adquirindo conhecimento através de um processo de aprendizagem, esse conhecimento é armazenado para tomadas de decisões futuras. Portanto, a rede neural artificial pode ser entendida por dois passos: o primeiro é o treinamento, no qual ela vai aprender por meio de um processo iterativo de ajustes, o segundo é o teste, no qual vai ser verificado sua tomada de decisão, se é adequada para o problema em questão. A Figura 2 é um diagrama de blocos de um sistema neural, no qual podemos fazer uma relação com o sistema nervoso humano.

*Figura 2 - Diagrama de blocos de um sistema neural.*



De acordo com a Figura 2 temos os receptores que convertem os estímulos em impulsos elétricos que será transmitido para a rede neural e os atuadores que convertem os impulsos elétricos gerados como saída da rede neural em resposta adequada como saída do sistema. A rede neural pode ser considerada como o cérebro, pois recebe várias informações do meio externo (estímulos) e a partir delas toma decisões apropriadas (resposta).

Como já mencionado, a primeira etapa da rede neural artificial é o treinamento, no qual é feito através de um processo iterativo de ajuste aplicados a seus pesos, no qual o aprendizado ocorre quando a rede atinge uma solução generalizada para uma classe de problemas, ou seja, ela aprende uma determinada função. Esse aprendizado pode ser atingindo por diversos algoritmos que se diferem basicamente pela maneira que seus ajustes de pesos são feitos (Haykin, 2009).

Esses métodos de aprendizado podem ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado. O aprendizado supervisionado

é o mais comum no treinamento de redes neurais artificiais, no qual tanto a entrada quanto a saída desejada são fornecidas para a rede por um supervisor (professor) externo. Nesse tipo de aprendizado, a rede tem sua saída calculada comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta (Braga, Ludermir, & Bernarda, 2011).

Uma desvantagem do aprendizado supervisionado é que, na ausência do supervisor, a rede neural não consegue aprender novas estratégias para as situações diferentes das utilizadas em seu treinamento. Um dos exemplos mais conhecidos desse método é a regra delta, a sua generalização para redes de múltiplas camadas é o algoritmo *Backpropagation*.

Já no aprendizado não supervisionado como o próprio nome já diz, não há um supervisor para acompanhar o processo de aprendizado, além de ser fornecido a rede neural só o sinal de entrada, ou seja, ela desconhece a saída desejada. Portanto, esse tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada, pois sem redundância seria impossível encontrar quaisquer padrões ou características nos dados de entrada. A partir do momento que essa rede neural estabelece uma harmonia com as regularidades estatísticas dos dados de entrada, desenvolve-se nela uma habilidade de formar representações internas para codificar características de entrada e criar novas classes ou grupos automaticamente (Braga, Ludermir, & Bernarda, 2011).

A última etapa é o teste e validação, na qual o modelo resultante do treinamento recebe como dado de entrada um banco de dados que não foi utilizado para o aprendizado da rede, suas respostas são avaliadas para verificar se o modelo calculado consegue reconhecer e separar as classes. Pois, o objetivo final de um sistema neural é a tomada de decisão, ou seja, dada uma determinada entrada o sistema irá processá-la e em seguida tomar uma decisão como saída.

### **2.3.1 Combinador Linear e Função de Ativação**

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural (Haykin, 2008). Três elementos básicos é identificado em um neurônio, que são: um conjunto de pesos sinapses, no qual cada um caracteriza um peso em relação a entrada correspondente, seu valor pode estar em um intervalo que inclui valores negativos bem como positivos; um somador para somar os sinais de entrada, ponderados pelas



respectivas sinapses do neurônio e a última que é uma função de ativação para restringir a amplitude da saída de um neurônio.

O modelo também inclui um *bias*, representado por  $b_k$ , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente. De acordo com (Haykin, 2008), um neurônio  $k$  é representado por

$$u_k = \sum_{j=1}^m w_{kj} x_j, \quad (8)$$

e

$$y_k = \varphi(u_k + b_k), \quad (9)$$

sendo  $x_1, x_2, \dots, x_m$  os sinais de entrada,  $w_1, w_2, \dots, w_{km}$  os pesos sinápticos do neurônio  $k$ ,  $u_k$  a saída do combinador linear devido aos sinais de entrada,  $b_k$  o *bais*,  $\varphi(\cdot)$  a função de ativação e  $y_k$  o sinal de saída do neurônio.

A função de ativação,  $\varphi(\cdot)$ , que define a saída de um neurônio em termos do campo local induzido  $u$  (Haykin, 2008), identifica-se três tipos de função de ativação:

- *Função de Limiar* – para este tipo de ativação, tem-se

$$\varphi = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (10)$$

De acordo com a Equação (10) a saída de um neurônio como este assume o valor 1, se o campo local induzido é não negativo e 0 caso contrário.

- *Função Linear por Partes* – para esta função, tem-se

$$\varphi = \begin{cases} 1 & \text{se } u \geq +\frac{1}{2} \\ u & \text{se } +\frac{1}{2} > u > -\frac{1}{2} \\ 0 & \text{se } u \leq -\frac{1}{2} \end{cases} \quad (11)$$

De acordo com a Equação (11) esta forma de função de ativação pode ser vista como uma aproximação de amplificador não-linear, na qual possui duas situações: a primeira região linear de operação é mantida sem entrar em saturação, um combinador linear e a segunda região que se reduz a função de limiar, se o fator da região linear é infinitamente grande.

- *Função Sigmóide* – o gráfico tem a forma de s, é de longe a forma mais utilizada na função de ativação de redes neurais, e um exemplo é a função logística que é dado por

$$\varphi(u) = \frac{1}{1 + \exp -au}, \quad (12)$$

sendo  $a$  o parâmetro de inclinação da função sigmóide, então a função sigmóide pode assumir valores contínuos no intervalo de 0 a 1, além de ser um função diferenciável.

### 2.3.2 Rede Perceptron de uma Única Camada

A rede *perceptron* de uma única camada é a forma mais simples de uma rede neural, utilizada para a classificação de padrões linearmente separáveis. Porém, ela é limitada para realizar classificação de padrões com apenas duas classes. Essa rede como o próprio nome já diz consiste de um único neurônio com seus pesos sinápticos e *bias*, os quais são processados pelo combinador linear, de acordo com a Equação (8), seguido por uma função de aditivção, que pode ser uma das funções citadas acima: função de limiar, função linear por partes e função sigmóide.

O ajuste do vetor de pesos sinápticos  $w(n)$  pode ser feito de acordo com a regra de aprendizado por correção de erro (Haykin, 2009), que é dado por

$$w(n + 1) = w(n) + \eta[d(n) - y(n)]x(n), \quad (13)$$


sendo  $w(n)$  o peso sináptico atual e  $w(n + 1)$  o da próxima interação,  $\eta$  a taxa de aprendizagem que é uma constante restrita ao intervalo de  $0 < \eta \leq 1$ ,  $[d(n) - y(n)]$  a diferença que assume o papel de um sinal de erro, na qual  $d(n)$  é o sinal desejado e  $y(n)$  a saída do *perceptron* e  $x(n)$  o sinal de entrada da rede neural. Pois, o objetivo da rede neural *perceptron* é classificar corretamente o conjunto de estímulos (dados de entrada) em duas classes  $C_1$  e  $C_2$ .

### 2.3.3 Redes Perceptron de Múltiplas Camadas

Uma Rede Neural Artificial (RNA) pode ter uma ou várias camadas e a maneira como seus neurônios são agrupados é uma importante característica para definir o tipo de arquitetura da rede.

Um *perceptron* de multicamadas é uma rede neural artificial composta por mais de um *perceptron*, onde eles organizados em paralelos formam camadas e cada camada conecta-se a próxima em uma única direção, em direção a saída, ou seja, não há caminho de volta como observa-se na Figura 3.

Figura 3 - Rede perceptron de múltiplas camadas.



Fonte: (Silva, Spatti, & Flauzino, Redes neurais artificiais: para engenharia e ciências aplicadas, 2010).

As redes *perceptron* de multicamadas são constituídas de uma camada de entrada que recebe os dados que serão processados pela rede, a(s) camada(s) oculta(s) (ou intermediárias), na Figura 3 temos apenas duas camadas ocultas. Por último tem-se a camada de saída que irá retornar a resposta, o número de neurônios dessa camada está relacionado com a tarefa que a rede está executando (Silva, Spatti, & Flauzino, Redes Neurais Artificiais para engenharia e ciências aplicadas, 2010).

As camadas intermediárias constituem um mecanismo computacional da rede *perceptron* de múltiplas camadas (*Multilayer Perceptron* - PMC), isto é, elas funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação. O número de camadas ocultas vai depender do problema que se deseja solucionar.

Para a rede *perceptron* de uma única camada o erro é obtido diretamente através da diferença entre a saída desejada e a saída da rede, como já foi mencionado. Porém, para a rede PMC esse procedimento pode ser aplicado apenas na camada de saída, já que não tem-se saídas desejadas definidas para as camadas intermediárias. Portanto, o problema passa a ser como calcular ou estimar o erro das camadas intermediárias (Braga, Ludermir, & Bernarda, 2011).

Um dos algoritmos mais utilizado para realizar o treinamento é o *backpropagation*, que é baseado na heurística do aprendizado por correção de erro, em que o erro é retropropagado da camada de saída para as camadas intermediárias da rede. Esse algoritmo opera em dois passos: a fase *forward* que calcula os pesos sinápticos dos neurônios, baseado nos dados da camada de entrada, de modo a produzir a resposta na camada de saída, a fase *backward* que a saída obtida é comparada com a saída desejada, caso tenha erro, esse é propagado a partir da camada de saída até a camada de entrada e os pesos dos neurônios das camadas intermediárias vão sendo modificados conforme o erro é retropropagado (Silva, Spatti, & Flauzino, Redes neurais artificiais: para engenharia e ciências aplicadas, 2010).

O processo de treinamento do *perceptron* de múltiplas camadas é o mesmo de uma única camada, no qual a saída da camada 1 é entrada para a camada 2 e assim sucessivamente, até chegar na camada de saída da rede neural. A diferença entre o valor desejado e a saída da rede indica o erro cometido pela rede para o dado de entrada, este valor é utilizado na fase *backward*, para ajustar os pesos sinápticos da rede.

### 2.3.4 Deep Learning (Aprendizado profundo)

Nos últimos anos, houve um aumento na disponibilidade de dados e no poder computacional, o que levou a um desenvolvimento na tecnologia de *deep learning* (aprendizado profundo). Com esse aprendizado profundo tem sido mais simples para um algoritmo realizar tarefas que antes eram muito difíceis, como por exemplo reconhecer os objetos em uma imagem. O desempenho superior das redes neurais profundas reflete o fato de que as redes neurais biológicas também obtêm grande parte de seu poder a partir da profundidade. As redes biológicas estão conectadas de maneiras que não entendemos completamente, mas o pouco que a estrutura biológica é compreendida já foi alcançado avanços significativos ao projetar redes neurais artificiais nesse sentido. Um exemplo clássico desse tipo de arquitetura é o uso da rede neural convolucional para reconhecimento de imagem (Goodfellow, Bengio, & Courville, 2016).

O Yann LeCun e seus colaboradores desenvolveram um algoritmo para reconhecer dígitos manuscritos, denominado de LeNet, no qual é uma rede *feedforward* com muitas camadas ocultas, o algoritmo de treinamento é o *backpropagation*, formando uma rede ampla que pode lidar com vários caracteres ao mesmo tempo. Mais tarde, esta arquitetura foi formalizada com o nome rede neural convolucional (*convolutional neural network* - CNN), que são redes neurais profundas, muito utilizadas para classificar imagens, agrupá-las por similaridade e realizar reconhecimento de objetos dentro de uma cena. A eficácia das CNNs no reconhecimento de imagem é uma das principais razões pela quais o aprendizado profundo ganhou destaque.


Outras redes profundas foram desenvolvidas a partir da CNN, como a Unet, VGG16, GoogleNet, etc. Essas redes profundas impulsionaram grandes avanços na visão computacional, com aplicações em robótica, drones, carros autônomos, entre outros.

A rede Unet é uma rede totalmente convolucional, que tem como característica ser mais rápida, pois evita o uso de camadas mais densas e muitos parâmetros, possibilitando sua utilização para qualquer tamanho de imagem. Nessa rede ocorre uma redução de amostragem inicial, pois é aplicado um filtro convolucional que contrai a imagem em diferentes resoluções,

filtrando e detectando diferentes estruturas e texturas. Na segunda etapa é realizado o aumento de resolução, fazendo interconexões entre imagens e escalas equivalentes, gerando uma melhor qualidade da imagem (Flood, Watson, & Collett, 2019).

A Unet recebe essa nomenclatura por causa do seu formato, como citado anteriormente é dividida em 2 etapas, a primeira contrai a imagem para extrair suas características, a segunda é composta pelo aumento da resolução das imagens usando deconvoluções, como a Figura 4.

Figura 4 – Arquitetura da rede Unet.



Fonte: (Flood, Watson, & Collett, 2019).

A arquitetura da rede neural convolucional Unet apresentado na Figura 4, na qual cada caixa representa um mapa de bits, com os números no topo da caixa dando o número de “bandas” naquele mapa, os números à esquerda da caixa dando o número de pixels. As setas de conexão representam diferentes operações, conforme mostrado na legenda.

Ainda de acordo com a Figura 4, tem-se os quatro passos de contração, que são duas camadas de convolução (conv), uma *max pool*, os mapas de recursos dobram à medida que se desce, começando em 64, depois 128, 256 e 512. Da mesma forma a expansão tem quatro passos, a camada de deconvolução, concatenação com o mapa de recursos do caminho de contração correspondente e duas camadas de convolução.

## 2.4 Métricas de Avaliação

Nesta seção são apresentados as métricas de avaliação que são fundamentais para examinar o desempenho dos métodos proposto, os resultados experimentais precisam ser avaliados por métricas de avaliação, como: a acurácia ( $A$ ), a precisão (sensibilidade), a especificidade (*recall*), a medida F1 e a Curva ROC (*Receiver Operating Characteristic*). Um classificador binário, isto é, que possui apenas duas classes, pode rotular uma classe como positiva (P) e a outra classe como negativa (N), a avaliação de um modelo de classificação é realizada a partir da comparação entre as classes preditas pelo modelo e as classes verdadeiras.

Todas as métricas de classificação têm como objetivo medir quão distante o modelo está da classificação ideal, porém cada métrica faz isso de uma forma diferente. Sabe-se que a acurácia ( $A$ ) indica a probabilidade de uma classificação correta, isto é, mede quantas amostras de fato foram classificadas corretamente, independente de classe, logo quanto maior for  $A$  mais o modelo preditivo se aproxima de um classificador ideal, é calculada pela razão entre o número de amostras classificadas corretamente e o número total de amostras (Eberhart & Shi, 2007), dada por

$$A = \frac{TP + TN}{TP + FN + TN + FP}, \quad (14)$$

sendo  $TP$  o verdadeiro positivo (*True Positive*) são as imagens que retratam manchas de óleo na superfície do oceano (positiva) que são classificadas corretamente,  $TN$  o verdadeiro negativo (*True Negative*) são as imagens sem manchas de óleo (negativas) que são classificadas corretamente,  $FP$  o falso positivo (*False Positive*) que são as imagens negativas que são classificadas como positiva e  $FN$  o falso negativo (*False Negative*) que são as imagens positivas que são classificadas como negativas.

A precisão ( $PR$ ), também conhecido como valor preditivo positivo, ela é uma das métricas mais comum para avaliar classificadores, ela indica a probabilidade dos falsos positivos, sendo definida pela razão entre a quantidade de amostras classificadas corretamente como positivas e o número de amostras classificadas como positivas pelo sistema (Eberhart & Shi, 2007), dada por

$$PR = \frac{TP}{TP + FP}, \quad (15)$$

observando a Equação (15) percebe-se que a precisão dá uma ênfase maior para os erros por falso positivos. Esta é uma métrica importante quando é imperativo que um sinal seja atendido.

A revocação (*recall* em inglês), também conhecida como sensibilidade ou probabilidade de detecção, ela é definida pela razão entre a quantidade de amostras classificadas corretamente como positivo e o total de amostras que são de fato positivo (Eberhart & Shi, 2007), é dada por

$$recall = \frac{TP}{TP + FN}, \quad (16)$$

sendo que o *recall* a proporção de verdadeiros positivos, fornecendo uma indicação do número relativo de falsos negativos. Consequentemente, é uma métrica muito importante quando tem-se um problema de detecção.

A métrica F1 leva em consideração tanto a precisão quanto o *recall*, ela é definida como a média harmônica entre a precisão e a *recall* (Eberhart & Shi, 2007), dada por

$$F1 = \frac{(\beta^2 + 1) * PR * recall}{(\beta^2 * PR) + recall}, \quad (17)$$

sendo  $\beta$  qualquer valor não negativo, um caso típico é  $\beta = 1$ , pois resulta em pesos iguais para a precisão e o *recall*. Ao observar a Equação (17) percebe-se que se a precisão ou o *recall* for igual a zero ou muito próximo disso o F1 será baixo, logo o modelo do classificador não é um modelo capaz de acertar suas predições, ou seja, não é um bom classificador. Portanto, essa métrica tende a ser um bom resumo da qualidade do modelo, ela também é dada em porcentagem.

Outra forma de medir o desempenho de um sistema é com a curva ROC (*Receiver Operating Characteristic* – Curvas Características Operacionais Relativas), ela fornece um meio de quantificar a precisão de um sistema de classificação comparando as decisões ou classificação do sistema. A curva ROC é uma representação gráfica da performance de um



modelo de dados quantitativos, que faz uso de duas razões: a sensibilidade (razão de verdadeiros positivos) e a proporção de falsos positivos ( $TN/(FP + TN)$ ) (Eberhart & Shi, 2007). Consequentemente, é um gráfico da proporção de verdadeiros positivos versus a proporção de falsos positivos.

Esta curva é geralmente obtida traçando pontos para vários valores do limite de saída, em seguida conectar esses pontos com segmentos de linha ou com curva suave. Outra maneira de plotar é utilizando os valores de saída obtidos para um conjunto de treinamento ou teste. Ao observar a curva resultante, quanto mais a direita ela estiver, isto é, mais próximo do eixo  $y$  (taxa de verdadeiro positivo), melhor o desempenho geral do sistema. Caso essa curva seja uma diagonal, na qual as proporções de verdadeiros positivos e falsos positivos são iguais, ela representa uma situação que não existe discriminação, isto é, o sistema atingiu esse desempenho por acaso. O cálculo da área sob a curva ROC também é uma forma de avaliar o desempenho do modelo.

# Capítulo 3

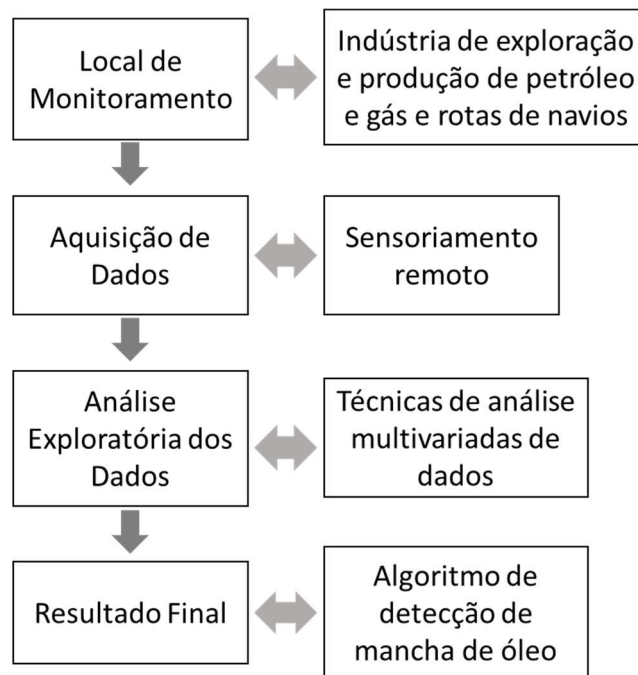
## Métodos para Análise e Construção de Algoritmos para o Crítico de um Sistema de Detecção

A metodologia para o desenvolvimento de métodos para análise e construção de algoritmos para o módulo da unidade do crítico de um sistema de detecção é apresentado neste capítulo. O capítulo contém a descrição do sistema de detecção de mancha de óleo na superfície do oceano com a exposição dos elementos que o constitui, a sua representação em diagrama de blocos e sua interpretação em relação a um sistema de controle. Neste capítulo também é apresentado os algoritmos propostos para realizar a detecção e classificação das manchas de óleo na superfície do oceano, no qual é relatada desde a aquisição dos dados até o resultado final, que é a classificação dos dados em dados com manchas de óleo e superfície limpa.

### 3.1 Descrição do Sistema de Detecção de Mancha de Óleo

A descrição resumida das etapas do método proposto para detecção de manchas de óleo na superfície do oceano é ilustrada no diagrama da Figura 5. Esta figura é constituída do meio a ser monitorado, da coleta dos dados e do método utilizado para a detecção das manchas de óleo na superfície do oceano.

Figura 5 - Descrição do sistema de detecção de mancha de óleo na superfície do oceano.



De acordo com a Figura 5, primeiro é preciso determinar o local a ser monitorado, que pode ser nas indústrias de exploração e produção de petróleo e gás natural e onde há um grande fluxo de navios, pois a maior parte do petróleo é transportada por navios. Após a finalização da coleta de dados por sensores, que pode ser por meio de sensoriamento remoto (satélite) ou por meio de rede de sensores (nós de sensores móveis).

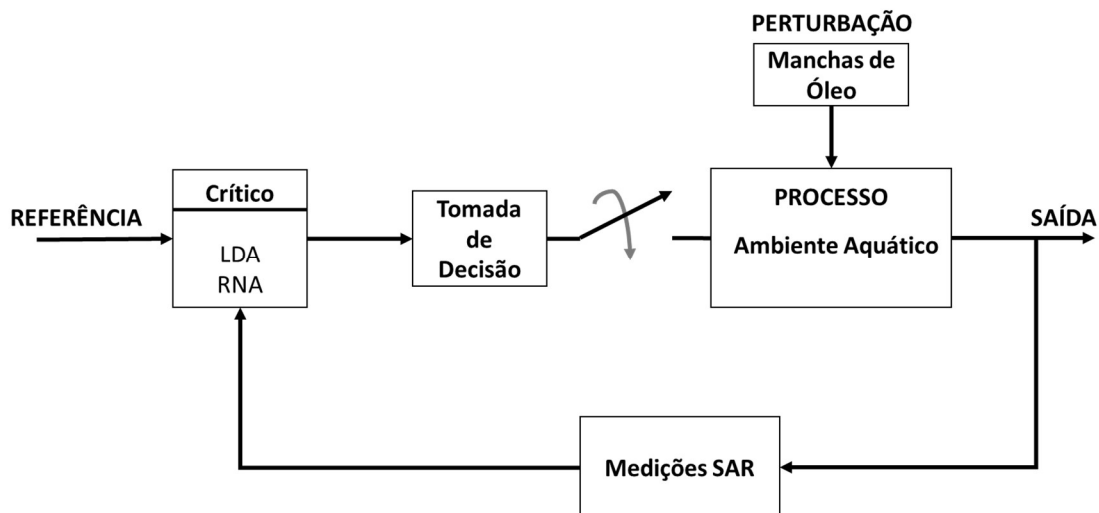
O sensoriamento remoto utiliza a radiação eletromagnética registrada por um sensor a bordo de uma aeronave ou satélite, esta energia refletida e detectada pelo sensor contém informação espectral valiosa sobre as características da superfície (ou próxima a superfície) do meio aquático (Jenen, 2009). Já as redes de sensores sem fio com nós dinâmicos, que pode utilizar veículo aéreo não tripulado (VANT), robôs terrestres e submarinos, sendo capazes de monitorar grandes áreas, coletar dados, realizar processamento localmente e assim permitir o mapeamento, rastreamento e localização de alvos (Selmic, Phoha, & Serwadda, 2016), os sensores utilizados dependem do que se deseja monitorar.

As abordagens de análise multivariada de dados e redes neurais são apresentadas nas Seções 2.2 Análise Multivariada de Dados e 2.3 Aprendizado de Máquina constituem os fundamentos teóricos para o desenvolvimento da poposta, que é apresentada na Seção 3.1 deste capítulo.

## 3.2 Diagrama de Blocos do Sistema Proposto

O desenvolvimento do módulo de processamento de sinais do sistema para detecção de anomalias em ambiente aquático é apresentado nesta seção. A problemática é investigada e as soluções propostas são contextualizadas por meio do diagrama de bloco da Figura 6, este é o diagrama do sistema de detecção de mancha de óleo na superfície do oceano. Observa-se nesta figura que o sistema é constituído por cinco blocos funcionais que são: a) Processo, objeto da monitoração; b) Perturbações, os agentes que provocam alterações no processo; c) Medições, dispositivos ou equipamentos responsáveis pela aquisição da informação (sinais); d) Crítico, dispositivo ou nó de sensor que avalia o impacto da perturbação no processo e e) Tomada de Decisão, unidade responsável pelo planejamento tarefas e sua execução que são baseadas nas avaliações do crítico.

Figura 6 - Diagrama de blocos do sistema de detecção de mancha de óleo na superfície do oceano.



Em termos de metas a serem atingidas, cita-se que desenvolvimento de métodos baseados nas abordagens de análise multivariada de dados e aprendizado de máquina para detecção das manchas de óleo na superfície do oceano, conduzem ao desenvolvimento de algoritmos para o módulo do crítico da Figura 6 que atendem restrições de tempo e memória. Desta forma, viabilizando a construção de algoritmo para soluções locais do problema de preservação do meio ambiente.

O método para detecção de manchas de óleo na superfície do oceano proposto neste trabalho é baseado em análise multivariada de dados e rede neural artificial (RNA), na qual os dados são imagens provenientes de satélites, esse método é contextualizado como parte do módulo do crítico de um sistema dedicado a tomada de decisão, o diagrama de blocos da Figura 6 apresenta o crítico no contexto do sistema de tomada de decisão.

De acordo com o diagrama de blocos da Figura 6 que representa o sistema de detecção de óleo no ambiente aquático, tem-se o sinal de referência (ambiente aquático limpo, sem manchas), o crítico que fornece uma representação paramétrica da função valor, baseada nos dados da medição. Conseqüentemente, o método de detecção proposto é orientado para ser embarcado nesta unidade, isto é, nele que se encontra o algoritmo de detecção, responsável por detectar anomalias no processo.

O processo é o meio aquático que está sendo monitorado, as manchas de óleo são consideradas como perturbações do processo, as medições do meio aquático são dados do monitoramento, estes dados são sinais de redes de sensores ou imagens de satélites. As informações provenientes dos dispositivos de medição são entradas do algoritmo de detecção. O sinais das medições são processados por meio de métodos e técnicas da análise multivariada de dados, RNA e aprendizado profundo.

De acordo com o diagrama de blocos da Figura 6, o fluxo de informação do crítico é enviado para o módulo da tomada de decisão. Caso ocorra a detecção de manchas de óleo na superfície do oceano que está sendo monitorado essas medidas serão aplicadas por um indivíduo externo, ou seja, a implementação da política de controle adequada para conter as manchas e limpar o meio aquático afetado de forma a minimizar os impactos ambientais. Essa tomada de decisão não faz parte do sistema de detecção proposto nesse projeto.

### 3.3 O Crítico de um Sistema de Detecção

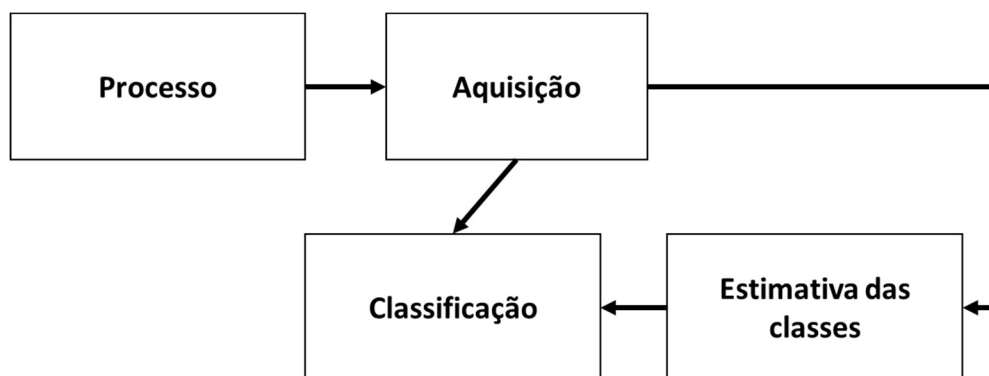
Nesta pesquisa é apresentado dois métodos de detecção e classificação da mancha de óleo na superfície do oceano: um método LDA-MLP, utilizando a integração de métodos estatístico, como a análise discriminante linear (LDA), a rede neuronal artificial, tipo

*perceptron* (MLP). O segundo método é baseado no aprendizado profundo, AP-Unet, que utiliza a rede neural convolucional na arquitetura Unet.

### 3.3.1 Modelo LDA – MLP do Crítico

O algoritmo LDA-MLP proposto para a detecção de manchas de óleo na superfície do meio aquático consiste nas seguintes etapas: a captura das imagens, a estimativa da classe que a imagem pertence e por último é realizada a classificação do dado de entrada com a estimativa feita pelo LDA. O método proposto não realiza processamento na imagem para a construção do modelo preditivo, reduzindo o tempo de processamento e é um diferencial dos demais métodos de classificação, que primeiro fazem todo um tratamento na imagem, eliminando ruído, realizando segmentação da imagem, entre outros tratamentos. A Figura 7 apresenta em forma de blocos a funcionalidade de cada etapa, as trajetórias de fluxo da informação para detecção via algoritmo proposto.

Figura 7 - Esquema do algoritmo LDA-MLP de detecção de manchas de óleo na superfície do oceano.



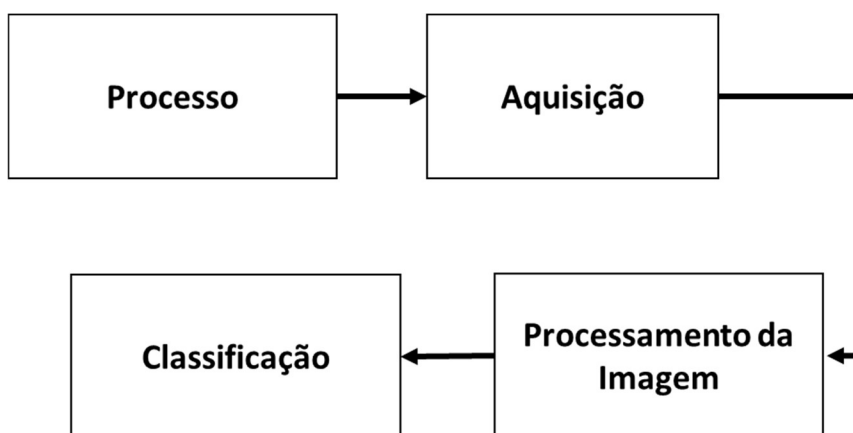
De acordo com o esquema da Figura 7 tem-se o processo que nesse estudo de caso é a superfície oceânica, no diagrama de blocos da Figura 6 é como meio aquático e as manchas de óleo como as perturbações, faz-se necessário realizar a aquisição das imagens da superfície do oceano, ou seja, da superfície a ser monitorada, no diagrama de blocos da Figura 6 essa etapa ocorre no crítico, sem antes fazer qualquer processamento na imagem, deste modo, utiliza-se a imagem do jeito que ela é recebida do satélite.

Em seguida é realizada a estimativa das classes, na qual se calcula as classes que a imagem pertence, a resposta da função discriminante de Fisher. Por último, é realizada a classificação, na qual é separado as imagens em dois grupos: superfície com manchas de óleo e superfície limpa (sem mancha de óleo), que no diagrama de blocos da Figura 6, essa etapa também ocorre no bloco crítico. Conseqüentemente, no contexto do sistema de tomada decisão da Figura 6, as principais características dos blocos funcionais do algoritmo do crítico para detecção da mancha de óleo da Figura 7 são descritas.

### 3.3.2 Modelo do Crítico via Aprendizado Profundo

O algoritmo proposto para a detecção de manchas de óleo na superfície do meio aquático consiste em um conjunto de etapas que são: a captura das imagens, o processamento da imagem, por último é realizado a classificação do dado de entrada. Portanto, diferente da classificação pelo método proposto por meio da abordagem LDA – MLP este método realiza processamento na imagem, como um filtro ou um ajuste, para eliminar ruídos e instâncias que não são interessantes para essa classificação, antes de utilizá-la para a construção do modelo do classificador convolucional. Para o algoritmo proposto, a Figura 8 mostra as etapas do processamento para detecção de manchas de óleo na superfície do oceano, em forma de diagrama de blocos, que baseia-se no algoritmo AP-Unet.

Figura 8 - Esquema do algoritmo AP-Unet de detecção de manchas de óleo na superfície do oceano.



De acordo com o esquema da Figura 8 tem-se o processo, que nesse estudo de caso é a superfície oceânica, e as perturbações são consideradas como as manchas de óleo, conforme

ilustrado no diagrama de blocos da Figura 6, a aquisição das imagens da superfície do oceano, ou seja, da superfície a ser monitorada, pois é a partir dessa aquisição que realiza-se a análise do processo, como essas imagens coletadas contém ruídos há dificuldade a interpretá-las, elas passam por um processamento de modo a tentar eliminar ao máximo os ruídos.

Após o processamento do banco de dados, as imagens estão prontas para treinar a rede neural profunda, depois do treinamento é realizado o teste para analisar a eficiência do classificador treinado, essa etapa está representada no diagrama de blocos da Figura 6 no crítico.

### 3.3.3 Aquisição

A aquisição é responsável pela captação da imagem. Para o monitoramento do meio aquático pode ser utilizado as imagens do Radar de Abertura Sintética (SAR), pois elas são minimamente afetadas por raios de sol e nuvens, possuindo a capacidade de capturar imagens durante todo o dia e em qualquer clima com ampla faixa e alta resolução (Dongmei Song, Z. Z., 2020).

Mas pode-se utilizar também os dados de uma Rede de Sensores sem Fio (RSSF), na qual são redes de dispositivos de sensores autônomos em que a comunicação é realizada através de canais sem fio. Essas redes consistem em vários nós de sensores (estáticos e dinâmicos) com vários sensores por nó que se comunicam entre si e com a estação base através de links de rádio sem fio (Selmic, R. R., Phoha, V. V., Serwadda, A., 2016).

### 3.3.4 Reconhecimento de Padrões

O reconhecimento de padrões é responsável por classificar ou agrupar as imagens com base em seus conjuntos de características. Como o objetivo deste reconhecimento de padrões é classificar se há ou não manchas de óleo na superfície do mar e para isso utiliza-se a técnica de análise discriminante linear (Linear Discriminant Analysis - LDA), que é utilizada para analisar a relação entre uma variável dependente não métrica e variável independente métricas (variáveis explicativas ou também denominadas de preditoras) (Hair, J. F., Black, B., Babin, B., Anderson, R. E., Tatham, R. L., 2019).



Essa técnica é um método da Análise Multivariada de Dados, que foi apresentada no Capítulo 2, na Subseção 2.1.3, na qual para atingir esse objetivo tem-se as seguintes etapas: a primeira etapa é calcular a separabilidade entre diferentes classes (ou seja, a distância entre as médias das diferentes classes), que é chamada de variância entre classes ou matriz entre classes; a segunda etapa é calcular a distância entre a média e as amostras de cada classe, que é chamada de variância dentro da classe ou dispersão dentro da classe; a terceira etapa é construir uma equação diferencial que classifique de forma satisfatória as classes, aumentando a variância entre as classes e minimiza a variância dentro das classes (Duda, R. O., Hart, P. E., Stork, D. G.).

### 3.3.5 Redes Neurais Artificiais

Nos últimos anos a Inteligência Artificial (IA) ganhou destaque graças a disponibilidade de GPUs (*Graphic Processing Units*), proporcionando processamento paralelo mais rápido, barato e mais poderoso, além da abundância de dados que se tem hoje na internet. Uma das técnicas desenvolvidas para alcançar uma IA é o *machine learning* (aprendizado de máquinas), que é a prática de usar algoritmos para coletar dados, aprender com eles, então fazer uma determinação ou predição a respeito do que se está analisando. Portanto, para executar uma tarefa basta treinar a máquina, utilizando uma quantidade grande de dados e algoritmos, fornecendo a máquina a habilidade de aprender como executar a tarefa (Braga, Ludermir, & Bernarda, 2011).

Apesar do sucesso e da eficácia dessa técnica, ela não foi suficiente para alcançar o objetivo final de uma IA genérica, mas foi desenvolvido uma técnica para implementar o *machine learning*, essa técnica é denominada de *deep learning* (aprendizado profundo). Portanto, a *deep learning* é uma subárea de *machine learning*, que emprega algoritmos para processar dados e imitar o processamento feito pelo cérebro humano (Medium, 2016).

Nos dois métodos são utilizadas redes neurais artificiais que é uma abordagem de *machine learning* (ML). No caso do método LDA-MLP, utilizou-se o aprendizado de máquinas, com uma de sua rede propulsora, que é *perceptron*. Já no método AP-Unet utilizou-se um modelo com aprendizado profundo com a arquitetura Unet. Esses dois modelos de rede foram apresentados na Seção 2.3, do Capítulo 2.

## 3.4 Metodologia para Execução da Pesquisa

A metodologia planejada para execução da pesquisa é apresentada nesta seção, além do planejamento da metodologia e suas etapas para execução.

O desenvolvimento desta pesquisa em métodos e algoritmos para detecção de perturbações no meio aquático via aprendizado profundo e integração de método estatístico e rede neural artificial é constituída das seguintes etapas:

- a) Pesquisa bibliográfica para elaboração do estado da arte em detecção de anomalias em ambientes aquáticos. Nesta pesquisa é analisado as técnicas utilizadas atualmente pelas empresas para a detecção de manchas de óleo no oceano, as técnicas que estão sendo estudadas, ou seja, em estágio inicial de testes. Além de fazer um estudo sobre a indústria de petróleo, gás natural e biocombustível, sua exploração, produção, transporte e o mercado, analisando a ocorrência de desastre com derramamento de óleo, suas maiores causas e os impactos causados;
- b) Estudo sobre sensoriamento remoto, imagens SAR. Neste estudo foi analisado sobre os princípios de radar e especificamente sobre o Radar de Abertura Sintético (SAR), que é a técnica mais utilizada atualmente para o monitoramento de derramamento de óleo na superfície do oceano. Além de ser estudado sobre a missão SENTINEL, dando ênfase a missão SENTINEL-1 que carregava o SAR, que é utilizado para o monitoramento de áreas terrestre e oceânica;
- c) Aquisição e preparação do banco de dados. A base de dado utilizada é constituída de imagens SAR, obtidas pela missão SENTINEL-1, esse banco de dados é disponibilizado pela Oil Spill Detection Dataset – MKLab através do contato com o LabSAR;
- d) Estudo sobre análise multivariada de dados com suas técnicas para agrupamento, classificação de dados. Neste estudo foi pesquisado sobre a avaliação de dados, que é a etapa que antecede a aplicação da técnica selecionada. Em seguida, analisa-se as

técnicas para detecção de alvo, verificando qual técnica melhor se aplica a detecção de manchas de óleo na superfície do oceano, a selecionada foi a Análise Discriminante Linear;

- e) Estudo de redes neurais artificiais. Este estudo está orientado para observar que esta é a técnica mais utilizada, atualmente, para a detecção de manchas de óleo na superfície oceânica. Principalmente quando se utiliza a arquitetura de aprendizado profundo. Conseqüentemente, as duas técnicas selecionadas para utilizar nessa pesquisa foram a rede mais básica que é o *perceptron* e uma mais atual com aprendizado profundo;
- f) Em paralelo as fases anteriores, realiza-se o desenvolvimento de métodos e algoritmos para detecção. Nesta etapa da pesquisa são propostos dois algoritmos para a detecção de mancha de óleo na superfície do oceano, que é o método de integração de técnica estatística e rede neural artificial, investiga-se a eficiência da análise discriminante linear e a rede *perceptron* para resolver o problema de detecção. Já o segundo algoritmo proposto consiste de uma rede convolucional, com aprendizado profundo, que é a arquitetura *Unet*;
- g) Testes computacionais dos métodos desenvolvidos. Nesta etapa foi implementado os dois algoritmos, utilizando o ambiente de simulação *MATLAB* e o *Python*;
- h) Avaliação de resultados obtidos. Nesta etapa analisa-se os resultados obtidos através das simulações computacionais e para realizar a análise, as métricas de avaliação como a acurácia, a precisão, a métrica *F1*, a curva *ROC* e o *recall* são utilizadas.

# Capítulo 4

## Resultados da Detecção e Classificação

Para avaliar o desempenho da metodologia de detecção proposta nesta dissertação, as imagens da base de dados *Oil Spill Detection Dataset* – MKLab são utilizadas. O banco de dados é constituído por imagens do *Synthetic Aperture Radar* (SAR). A descrição dos experimentos e análise dos resultados dos dois métodos propostos para detectar manchas de óleo no oceano são apresentados neste capítulo. No contexto desta dissertação, o primeiro algoritmo que é resultado da integração de métodos estatísticos e redes neurais artificiais, quando implementado, obtém-se um produto que é *software/código* para detectar as manchas, sendo chamado de classificador LDA-MLP. O segundo método proposto tem sua origem no aprendizado profundo (AP), gerando um produto que é chamado classificador AP-Unet. Ambos classificadores são projetados para compor o núcleo de *software* do módulo do Crítico do Sistema de Detecção, conforme apresentado na Figura 6 do Capítulo 3. Esses classificadores têm por objetivo detectar/classificar as manchas de óleo na superfície do oceano, isto é, classificar as imagens na superfície oceânica limpa ou com manchas de óleo. O classificador LDA-MLP é baseado nas abordagens de análise multivariada de dados e na RNA-*perceptron*. O outro classificador AP-Unet é baseado no aprendizado profundo com a arquitetura Unet.

Os resultados das simulações seguem as descrições da funcionalidade e fluxo da informação estabelecidas na Seção 3.1 do Capítulo 3. Os resultados apresentados são provenientes de experimentos dos dois métodos propostos de solução para o problema de detecção.

O capítulo está organizado em cinco seções. Na primeira seção, a caracterização das imagens da base de dados é apresentada, descrevendo-se as imagens SAR, cobertura de alcance do sensor SAR, espaçamento de pixel e ressaltando o problema produzido pelo ruído *speckle*. Na segunda seção, a metodologia para análise estatística dos dados e a preparação da base de dados são apresentadas, as informações das imagens são analisadas por meio de histogramas. Outros tipo de análises que são realizadas nos dados, tais como: análise homocedasticidade para verificar as variâncias e análise por meio do gráfico de caixa (boxplot). Na terceira seção é apresentado o projeto dos classificadores que são baseados no modelo RNA e sua integração com método estatístico, gerando o classificador LDA-MLP, modelo baseado em aprendizado profundo, gerando o classificador AP-Unet. Na quarta seção são apresentados os resultados do experimentos dos classificadores LDA-MLP e AP-Unet. Na última seção é apresentada a análise do desempenho dos classificadores.


## 4.1 Base de Dados

Disponibilizado pela Oil Spill Detection Dataset – MKLab, a base de dados utilizada neste estudo contém 1.112 imagens, retratando instâncias de 5 classes, ou seja, derramamento de óleo, sósia (que parece muito com mancha de óleo, porém não é), terra, navio e áreas marítimas. Essas imagens SAR foram adquiridas por meio das missões do satélite europeu SENTINEL-1, durante o período de 28 de setembro de 2015 até 31 de outubro de 2017. As informações das coordenadas geográficas, data e hora do evento da poluição são fornecidas pela Agência Europeia de Segurança Marítima (*European Maritime Safety Agency - EMSA*) através do serviço CleanSeaNet (Krestenitis M. O., 2019).

A cobertura de alcance terrestre do sensor SAR utilizado pela missão SENTINEL-1 é de aproximadamente 250 km, com espaçamento de pixels igual a  $10 \times 10$  m. Esse radar consegue cobrir grande área de interesse, além de capturar instâncias de tamanhos relativamente pequenos. Esse sistema empregado opera na banda *c*, a polarização de seu radar é dupla, isto é, polarização vertical transmitida – polarização vertical recebida (VV) e polarização vertical transmitida – polarização horizontal recebida (VH). Para construir o conjunto de dados apenas os dados brutos da banda VV foram processados, seguindo uma série de etapas de pré-processamento para extrair visualizações comuns (Krestenitis M. O., 2019). As imagens

capturadas foram redimensionadas para  $1250 \times 650$  pixels. A Figura 9 é uma imagem capturada por esse sistema SAR.

*Figura 9 - Imagem do banco de dados SAR.*



Os pontos negros que cobrem grandes áreas das imagens SAR são geralmente relacionados a sósias (que parecem com mancha de óleo), ao contrário das manchas escuras, alongados que são derramamentos de óleo, como observa-se na Figura 9. No entanto, nem sempre é esse o caso. Consequentemente, a detecção de uma mancha de óleo consiste em uma situação significativamente desafiadora, uma vez que a forma da mancha de óleo é ambígua.

O banco de dados ainda contém as máscaras das imagens, no qual retratam as instâncias presente na imagem, como mancha de óleo e navios, sendo utilizado cores diferentes para representa cada uma das 5 classes. A Figura 10 é a máscara correspondente da Figura 9.

*Figura 10 -Máscara do banco de dados SAR.*



De acordo com a Figura 10, tem-se a máscara da Figura 9, na qual a cor verde representa terra, o preto a superfície do oceano, o marrom navios, o vermelho sócias e o ciano mancha de óleo. Essas máscaras são muito importante para o treinamento e o processo de avaliação das redes que serão utilizadas para realizar a detecção da mancha de óleo.

Quando se constrói um classificador, geralmente assume-se que o conjunto de amostras de teste não é conhecido, mas existe outro conjunto de dados previamente conhecido que é utilizado para se extrair o conhecimento, chamado de amostras de treinamento ou aprendizado. Logo, o conjunto de treinamento é utilizado na fase de construção do classificador (Richard O. Duda, 2001).

Nesta pesquisa a base de dados contém 1112 imagens, sendo 1002 para treino e 110 para teste. No total tem-se 880 imagens com manchas de óleo na superfície do oceano, o que totaliza 79,14 % de todos os dados, 232 imagens limpas sem manchas de óleo, o que totaliza 20,86 % de toda a base de dados. Nos experimentos são apresentados os testes com a divisão provenientes da base de dados.

As imagens SAR são muito afetadas pelo ruído *speckle*, que é um ruído multiplicativo proporcional a intensidade do sinal recebido. O seu efeito visual é uma textura granulosa que pode dificultar a interpretação das imagens, por isso muitos pesquisadores realizam o processamento das imagens antes de utilizá-las para obter o modelo predito, pois esse processamento é responsável por melhorar a qualidade da imagem, isto é, eliminar ruídos, salientar bordas, suavizar a imagem etc. Outra técnica muito utilizada pelos pesquisadores é a segmentação, pois ela divide a imagens em regiões, o que ajuda na hora da classificação. Porém, nesta pesquisa são apresentados tanto testes realizados sem nenhum pré-processamento na imagem, como também testes com pré-processamento no banco de dados.

## 4.2 Análise Estatística dos Dados


Nesta seção é apresentada a análise estatística dos dados, pois antes de aplicar qualquer técnica, primeiro é necessário fazer a análise dos dados para verificar se é possível aplicar a técnica determinada, se os grupos são separáveis. Além de contribuir para a interpretação dos resultados.

## 4.2.1 Preparação da base de dados

Antes de aplicar qualquer técnica para processar as informações no banco de dados, primeiro é necessário realizar a análise dos dados, como citado no Capítulo 2, na Subseção 2.2.1, que é realizado antes de aplicar qualquer método, pois esta análise fornece informação sobre o comportamento das classes, indicando se é possível separar as duas classes. Os dados das classes quanto a sua distribuição e sua variância são analisados.

Portanto, a fim de analisar a distribuição das imagens e analisar se há semelhança na distribuição dos grupos, o que é de extrema importância para prever se os dois grupos são separáveis, é selecionado de forma aleatória 4 imagens de cada grupo e plotado seus histogramas, a Figura 11 e a Figura 12 são esses histogramas, na qual o eixo  $x$  representa o valor dos pixels, que varia de 0 a 255 e o eixo  $y$  representa a frequência que é o valor de pixel que aparece naquela imagem.


Figura 11 - Histograma de imagens da superfície do oceano SEM manchas de óleo.



De acordo com a Figura 11, os histogramas das quatro imagens sem manchas de óleo na superfície do oceano apresentam uma semelhança, onde os picos estão mais próximos de 150 há uma quantidade maior de pixels que se aproxima da cor branca. Outro fato a se observar é que os histogramas apresentam características de uma distribuição normal, que é distribuição referência para os métodos estatísticos utilizados nesse estudo.




Figura 12 - Histograma de imagens da superfície do oceano COM manchas de óleo.



De acordo com a Figura 12 os histogramas das imagens com mancha de óleo também apresentam semelhança entre si, onde seus picos estão próximos de 100, o que mostra que possui mais pixels na cor mais escura, aproxima-se da cor preta, uma distribuição normal. Quando comparados os histogramas de cada grupo, observa-se que há diferenças entre as distribuições.

A segunda análise realizada nos dados é a de homocedasticidade para verificar as variâncias, assim como na análise de normalidade foi realizado a análise gráfica, por meio do gráfico de caixa, fornecendo informação a respeito da localização, dispersão, assimetria, comprimento de cauda e medidas discrepantes (*outliers*) do conjunto de dados. Para essa análise, calcula-se a média de 140 imagens do conjunto de treinamento de cada grupo, em seguida plota-se o gráfico de caixa para analisar a variância entre os grupos, a Figura 13 é o gráfico de caixa obtido.

Figura 13 - Gráfico boxplot dos dois grupos.



De acordo com as Figura 13, observa-se que 1 representa o Grupo 1 (imagens sem mancha de óleo) e 2 representa o Grupo 2 (imagens com mancha de óleo). Agora analisando as informações que esse gráfico apresenta tem-se que o Grupo 1 não apresenta *outlier*, sua mediana é de 128,71 e sua dispersão (variância) é de 184,56, já o Grupo 2 apresenta três *outlier*, sua mediana é de 135,07 e sua dispersão é de 180,35. Portanto, os dois grupos apresentam mediana com valores próximos, o Grupo 1, grupo das imagens da superfície do oceano sem manchas de óleo, não apresenta *outlier* e sua dispersão maior é maior que a do Grupo 2, grupo das imagens da superfície do oceano com manchas de óleo.

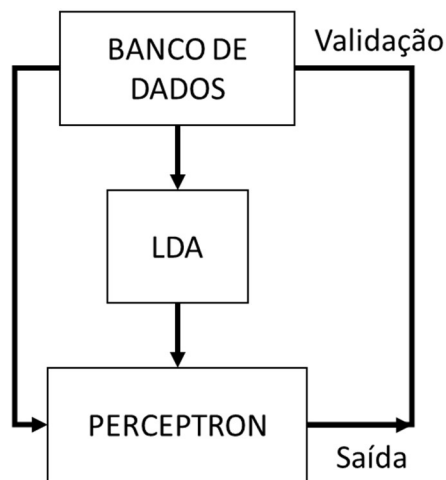
### 4.3 Projeto dos Classificadores

Como citado no Capítulo 3, na Seção 3.3, são dois algoritmos de detecção de mancha de óleo na superfície do oceano, o modelo LDA-MLP é constituído basicamente de três passos: a aquisição das imagens (captura de satélites), a estimativa das classes que as imagens pertence (análise discriminante linear) e classificação (rede *perceptron* de multiplas camadas). Já o AP-Net também é constituído por três passos: a aquisição das imagens, o processamento das imagens, como corte da imagem e filtro e por último a classificação pela rede de arquitetura Unet.

### 4.3.1 Modelo LDA-MLP

O modelo LDA-MLP como citado anteriormente possui três passos e o diagrama de blocos da Figura 14 apresenta a relação entre essas técnicas para que se alcance o objetivo, que é a detecção das manchas de óleo.

Figura 14- Diagrama de blocos do algoritmo LDA-MLP proposto para a classificação.



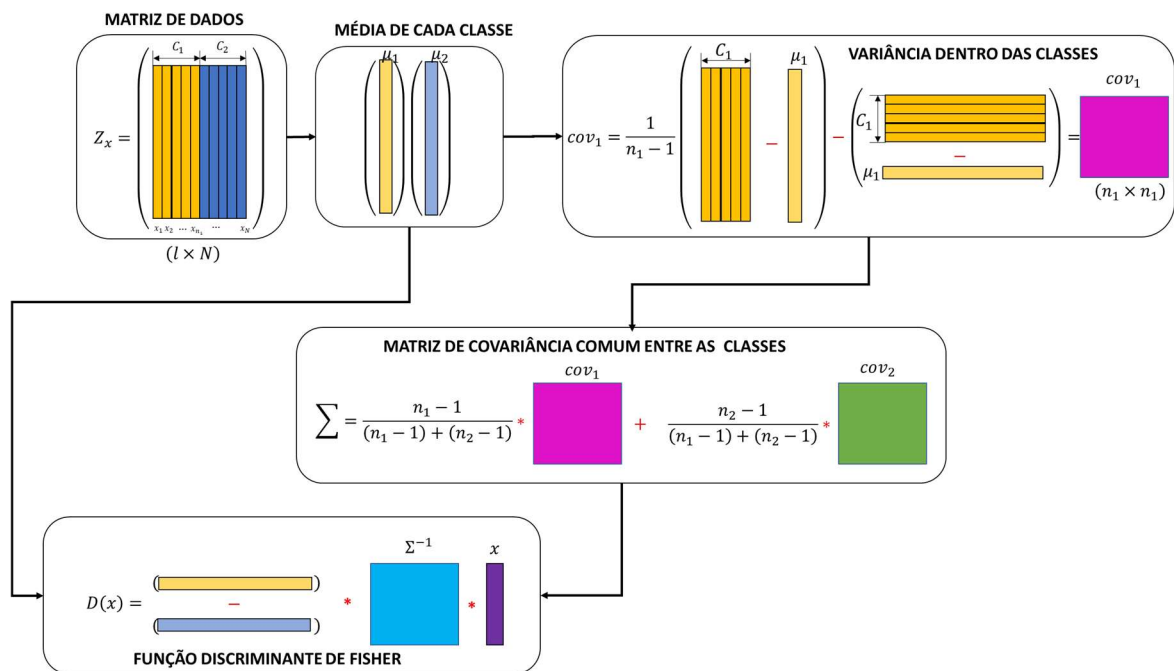
De acordo com a Figura 14, os dados são as imagens provenientes do satélite (imagens SAR), que são utilizadas para calcular a estimativa das classes. Essas estimativas são uma informação a mais ao banco de dados para treinar a rede *perceptron* simples (uma camada escondida), além de ser utilizadas para realizar os testes e verificar se o classificador atua de modo adequado.

O terceiro passo é o reconhecimento de padrões que é realizado por meio da rede *perceptron* simples, na qual tem como entrada os dados e a estimativa do LDA. A saída do classificador são valores 0 (superfície oceânica limpa) e 1 (superfície oceânica com manchas de óleo), esses valores são comparados com a saída desejada para verificar a eficiência do modelo.

### A. Algoritmo LDA

Após a aquisição das imagens, a estimativa das classes das imagens da superfície oceânica em limpa ou com mancha de óleo é realizada. Para tanto, aplica-se a Análise Discriminante Linear, em que primeiro constrói-se um espaço dimensional inferior para depois realizar a classificação. De acordo com o diagrama de blocos da Figura 14, esse algoritmo LDA é o segundo bloco do algoritmo geral, a Figura 15 relata os passos que foram seguidos em diagrama de blocos.

Figura 15 - Diagrama de blocos da Análise Discriminante Linear – LDA.




De acordo com a Figura 15 tem-se os dados de entrada que é a matriz com as imagens, em seguida é calculado as médias de cada classe, pois com elas e com as amostras é possível calcular a variância dentro das classe, matriz de covariância de cada classe, que é o que se deseja diminuir, a matriz de covariância comum entre as duas classes. Para construir a função discriminante de Fisher calcula-se a matriz inversa da matriz de covariância comum entre as classes, multiplicado pela subtração das médias e pelo vetor de entrada.

Uma vez que os parâmetros da função discriminante são calculados, conforme o critério de Fisher, é necessário decidir a qual classe a amostra pertence. Para isso, precisa-se do valor do ponto médio entre as classes, como já tem-se o resultado da função discriminante, aplica-se

esses dados na Equação (7) da Seção 2.2 e de acordo com o seu resultado o dado de entrada é classificado em superfície oceânica limpa, se for menor igual que a média e em superfície oceânica com manchas de óleo, caso contrário. A Figura 16 relata os passos seguidos.

Figura 16 - Diagrama de blocos da etapa de classificação.



De acordo com a Figura 16, a classificação de Fisher é dada a partir do cálculo da função discriminante, a Figura 15 apresenta os passos para calcular, em seguida calcula-se o ponto médio, o limiar, a partir desses resultados obtidos é classificado em superfície oceânica limpa, se o valor da função discriminante for maior igual a média, ou superfície oceânica com manchas de óleo, se o valor da função discriminante for menor que a média.

O algoritmo para a classificação da imagem, em ambiente aquático limpo ou com manchas de óleo, desenvolvido para esse sistema de detecção de mancha de óleo na superfície do oceano, executa a leitura das imagens que advêm da base de dados de treinamento. Esse algoritmo utiliza a média de cada classe para calcular as matrizes de covariância das classes e a matriz de covariância comum. Por meio dessas matrizes constrói-se a função discriminante para em seguida vir a etapa de classificação, seu código está exposto no ALGORITMO 1 – LDA.

**ALGORITMO 1 – LDA**• **Inicialização**

- 1 Ler as imagens;
- 2 Redimensionar as imagens;

• **LDA**• **Média de cada classe**

$$\mu_j \leftarrow \frac{1}{n_j} * \sum_{i=1}^{n_j} x_{ij};$$

• **Matriz de covariância**

$$\phi_j \leftarrow x_{ij} - \mu_j;$$

$$cov_j \leftarrow \frac{(\phi_j - \phi'_j)}{n_j - 1};$$

$$\Sigma \leftarrow \frac{1}{(n_1 - 1) + \dots + (n_c - 1)} * \sum_{j=1}^c (n_j - 1) * cov_j;$$

• **Vetor discriminante**

$$L \leftarrow (\mu_1 - \mu_2)' * \Sigma^{-1};$$

• **Função discriminante**

$$D(x) \leftarrow L * x;$$

• **Ponto médio entre as classes**

$$m \leftarrow \frac{1}{2} * (\mu_1 - \mu_2)' * \Sigma^{-1} * (\mu_1 + \mu_2);$$

• **Classificação**

$$\begin{cases} D(x) \geq m \rightarrow C_1 \\ D(x) < m \rightarrow C_2 \end{cases}$$

• **Fim do Algoritmo**

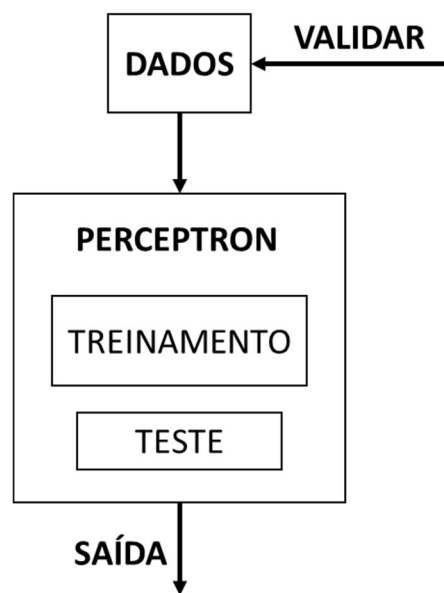
De acordo com o algoritmo de LDA, as imagens são redimensionadas para  $63 \times 33 \times 3$ , de modo a minimizar o esforço computacional,  $\mu_j$  a média da classe  $j$ ,  $x_{ij}$  as amostras da classe  $j$ ,  $n_j$  o número de amostras da classe  $j$ ,  $c$  o número de classes,  $cov_j$  a matriz de covariância da classe  $j$ ,  $\Sigma$  matriz de covariância comum entre as classes,  $L$  o vetor discriminante, com os parâmetros da função, parâmetros geram uma melhor separação entre as classes,  $D$  a função discriminante de Fisher,  $x$  os dados de teste, que contém tanto imagens com mancha de óleo como imagens com a superfície oceânica limpa,  $m$  o ponto médio para a classificação de Fisher.

## B. Algoritmo Perceptron de uma Única Camada

Após aplicar o LDA o seu resultado é adicionado as imagens de entrada. Portanto, o vetor da imagem passa a ter dimensão  $6238 \times 1$ , pois é adicionado mais uma informação que é a estimativa da classe da imagem, para analisar o método é planejado e realizado o experimento com a estimativa da classe, com a resposta da função discriminante e sem a informação do LDA.

De acordo com o algoritmo de detecção de manchas de óleo utilizando a rede neural *perceptron* simples, apresentado no Capítulo 3, na Seção 3.3.1. Este algoritmo é constituído de três etapas: a aquisição do meio aquático que está sendo monitorado (imagens SAR), o treinamento, que é a parte do algoritmo no qual são ajustados os pesos para que o classificador se aproxime o máximo possível do ideal, o último é o teste para verificar a eficiência do classificador. A Figura 17 é a organização dessas etapas.

Figura 17 - Diagrama de blocos do algoritmo de treinamento da rede Perceptron.



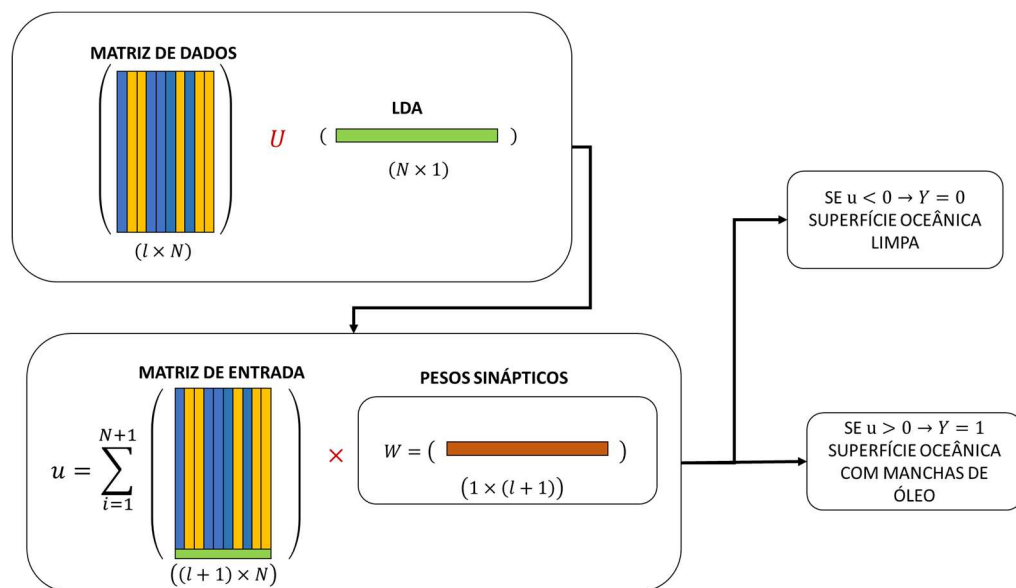
De acordo com a Figura 17, tem-se o primeiro bloco que é o banco de dados, dividido em dados de treinamento e dados de teste, que como já mencionado é constituído por imagens SAR. O segundo bloco é a rede *perceptron* simples, na qual primeiro é realizado o treinamento, ajustando os seus pesos sinápticos para que o modelo do classificador consiga separar as classes

com erro mínimo, após o ajuste é realizado o teste, que utiliza-se os dados de teste para analisar se o classificador calculado possui um bom desempenho, classificando corretamente os dados, por isso a saída do *perceptron* é comparada com a saída desejada.

### ▪ Topologia da Rede

Como se tem um banco de dados que já veio dividido em banco de treinamento e de teste, não é necessário realizar a divisão, pois utiliza-se a divisão que já veio. Em seguida, realiza-se o treinamento da rede de modo a calcular o vetor de pesos sinápticos que geram um erro pequeno, para realizar esse treinamento os passos seguidos estão ilustrados pelo diagrama de blocos da Figura 18.

Figura 18 - Diagrama de blocos do perceptron.



De acordo com a Figura 18, tem-se a matriz de entrada, em que cada coluna da matriz é uma imagem e  $l$  é o número de parâmetros. O vetor LDA que contém a estimativa das classes, é adicionado para dar mais uma informação na hora da modelagem do classificador. Em seguida é calculado o combinador linear, que é a soma ponderada da matriz de entrada (matriz de dados junto com o LDA) multiplicado pelos pesos sinápticos,  $W$  um vetor linha, na qual os pesos são responsáveis por determinar o impacto que o valor de cada variável de entrada tem no valor das variáveis de saída.

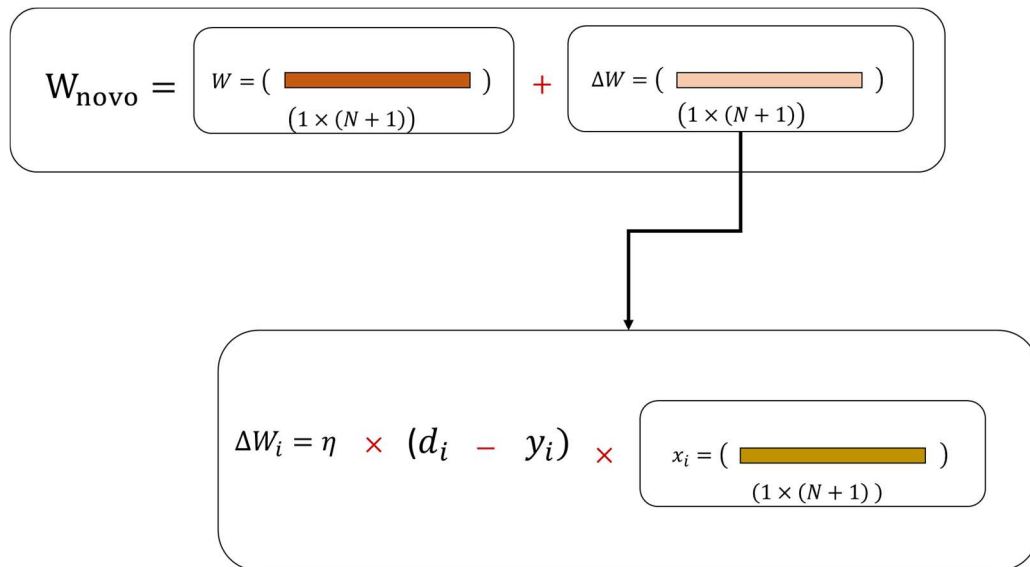


A saída do combinador linear passa por um função de ativação, nesse trabalho foi selecionada a função de limiar, que quando a saída do combinador for menor que zero ela atribui 0 (zero) para a saída do *perceptron*  $y = 0$ , caso a saída do combinador seja maior que 0 (zero) ela atribui 1 (um) para a saída do *perceptron*,  $y = 1$ .

#### ▪ Treinamento da Rede

Como no treinamento da rede os pesos sinápticos precisam ser atualizados em cada iteração, até obter um vetor de pesos que possua valores que atribua o referido impacto da variável de entrada na saída do *perceptron* de modo a obter um classificador com erro mínimo ou sem erro. Os passos para a atualização desses pesos sinápticos são apresentados no diagrama da Figura 19.

Figura 19 - Diagrama de blocos da atualização dos pesos sinápticos.



De acordo com a Figura 19 tem-se que a atualização dos pesos é dada pela soma do peso anterior vezes o delta do peso, no qual este é dado pelo erro  $(d_i - y_i)$ , sendo  $d_i$  a saída desejada e  $y_i$  a saída do *perceptron*, vezes a taxa de aprendizado  $(\eta)$ , vezes o vetor  $x_i$  correspondente.

Esse algoritmo utiliza o banco de dados de treinamento para calcular os pesos sinápticos que melhor relacione a variável de entrada com a saída da rede neural, seu pseudo-código é no ALGORITMO 2 – PERCEPTRON.

**ALGORITMO 2 – PERCEPTRON**

- **Inicialização**

```

1 Carregar dados;
2 Ler(dados);
3  $X_{train(i,:)} \leftarrow dados(treinamento);$ 
4  $X_{test(i,:)} \leftarrow dados(teste);$ 
5  $d_{Train} \leftarrow classes(treinamento);$ 
6  $d_{Test} \leftarrow classes(teste);$ 
7  $W = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}_{(l+1) \times 1};$ 
8  $epoca = 1000;$ 

```

- **Processo Iterativo**

- **Soma Ponderada**

```

9  $Y \leftarrow \sum_{i=1}^l W * X_{train}(i,:);$ 

```

- **Função de Ativação**

```

10  $R \leftarrow ReLU(D);$ 

```

- **Atualização dos Pesos**

```

11 SE  $d_{Train} \neq Y$  ENTÃO
12  $\Delta W \leftarrow \eta * (d(i) - Y(i)) * X_{train}(i,:);$ 
13  $W \leftarrow W + \Delta W;$ 

```

- **Fim do Loop**

- **Processo Iterativo – Teste**

- **Soma Ponderada**

```

14  $u \leftarrow \sum_{i=1}^K W * X_{test}(i,:);$ 

```

- **Função de Ativação**

```

15 SE  $u < 0$  ENTÃO
 $Y \leftarrow 0;$ 
SE  $u > 0$  ENTÃO
 $Y \leftarrow 1;$ 

```

- **Fim do Loop**

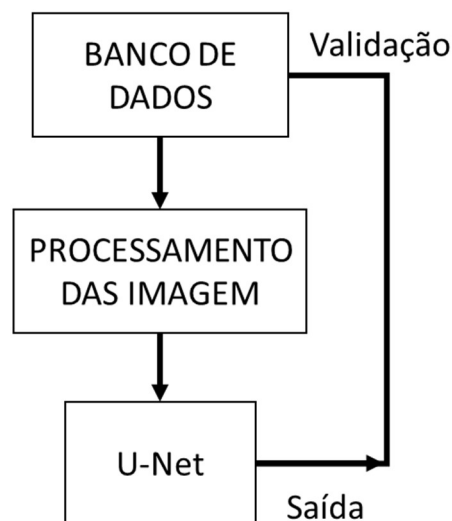
- **Fim do Algoritmo**

De acordo com o algoritmo do *Perceptron* a variável *dados* é a base de dados com as 1112 imagens,  $X_{train}$  é a matriz com as imagens de treinamento que contém 1002 imagens, já com a informação do LDA, na qual cada coluna corresponde a um imagem,  $d_{Train}$  é o vetor de saídas desejadas,  $W$  é o vetor dos pesos sinápticos, *epoca* é o número de iterações,  $u$  é a resposta da soma ponderada,  $Y$  é a saída do perceptron,  $\eta$  é a taxa de aprendizado,  $\Delta W$  é a diferença calculada de acordo com o erro de classificação para atualizar os pesos sinápticos e  $X_{test}$  é a matriz com as imagens e a informação do LDA para teste do classificador.

### 4.3.2 Modelo AP-Unet

De acordo com o diagrama de blocos da Figura 20, o procedimento para detectar/classificar manchas de petróleo, modelo AP-Unet é constituído por três etapas: a aquisição das medições (imagens) do meio aquático que se deseja monitorar, o pré-processamento das imagens, pois como já mencionado as imagens SAR contém ruído *speckle*, o que dificulta a interpretação das imagens, além de possuir uma dimensão muito grande, então uma imagem é dividida em quatro imagens. Depois desse processamento, ocorre a terceira etapa, as informações do banco de dados já estão adequadas para treinar a rede de aprendizado profundo.

Figura 20- Diagrama de blocos do algoritmo AP-Unet proposto para classificação.



As informações armazenadas no bloco do banco de dados da Figura 20, são as imagens provenientes do satélite (imagens SAR), que são utilizadas para treinar a rede Unet. Diferente do método LDA-MLP, antes de usar o banco de dados para treinar a rede, essas imagens passam por um processamento para melhorar a qualidade e diminuir a dimensão de cada imagem. Por último é realizado o teste de avaliação, este teste verifica se o classificador está atuando de modo adequado.


#### A. *Processamento da Base de Dados*

A base de dados como já mencionado já veio dividido em 90 % de dados de treinamento e 10 % de dados de teste, cada imagem em tons de cinza e com uma dimensão  $1250 \times 650 \times 3$ , isto é com 1250 de altura, 650 de largura e com profundidade 3, que é determinada pela quantidade de canais de cores. As máscaras também possuem a mesma dimensão, porém em cores RGB.

O primeiro processo realizado nos dados foi a divisão de uma imagem em quatro imagens, de modo a diminuir a dimensão da imagem para  $320 \times 608 \times 3$ , além de aumentar o banco de dados que passou a ser 4 vezes maior que o real. No banco de treinamento permanece apenas as imagens que relatavam mancha de óleo contabilizando 1651 imagens.

Em seguida é aplicado o filtro mediana  $5 \times 5$ , para tentar minimizar o ruído *speckle*, ou seja, para tentar suprir a textura granulada das imagens, esse filtro é aplicado tanto no banco de treino quanto no banco de testes, a Figura 21 é a imagem original e a imagem resultante do filtro mediana. Depois de realizar a filtragem nas imagens é criado um novo banco que é denominado validação, contendo 100 imagens que são retiradas do banco de dados de treinamento.

Figura 21 - Imagens redimensionada, (a) sem filtro, (b) com filtro mediana.




Nas máscaras também são realizadas a divisão da imagem em quatro imagens, foram transformada as imagem de RGB em tons de cinza. Logo, as manchas de óleo, agora, estão representadas pelo pixel de valor 178. Portanto, com o valor do pixel que representa a mancha de óleo é possível excluir todas as outras instâncias da imagem, deixando apenas a mancha de óleo e a superfície do oceano.

Assim como no banco de treinamento das imagens, permaneceram apenas a máscaras correspondentes as imagens que relatam manchas de óleo, contabilizando 1651 máscaras, mas no banco de dados de teste não é realizado essa exclusão, então o banco das máscaras de teste é constituído por 440 máscaras.

## B. Algoritmo Unet

Como já mencionado no Capítulo 2, na Subseção 2.3.4, a rede Unet consiste em um caminho de contração e um caminho de expansão, o caminho de contração consiste na aplicação de quatro vezes o bloco de convolução, que é constituído por duas convolução  $3 \times 3$ , cada uma seguida pela normalização e pela função de ativação ReLU (unidade linear retificada). Outro parâmetro que é determinado na convolução é o *padding* (preenchimento), que faz com que as camadas não diminuam mais rárido que o necessário para o aprendizado da rede, para esse modelo de rede determinou-se que a saída fosse do mesmo tamanho da entrada. Essa convolução funciona como um filtro que percorre toda a imagem captando os traços mais relevantes. Esses passos são apresentados na Figura 22, na qual a imagem de entrada tem dimensão  $320 \times 608 \times 3$ .

Figura 22 - Algoritmo do modelo AP-Unet.



O modelo AP-Unet, como é apresentado na Figura 22, possui no primeiro bloco de convolução 64 filtros, no segundo tem 128, no terceiro 256 e no quarto 512, ou seja, vai duplicando até chegar no último bloco de convolução. Após cada bloco de convolução, uma operação de agrupamento (camada de *pooling*) ocorre, tendo como objetivo simplificar a informação da camada anterior, o método utilizado é o *max pooling* (agrupamento máximo) de área  $2 \times 2$  com passo 2 para redução da quantidade de pesos a serem aprendidos, também para evitar *overfitting* (sobreajuste) e após o último *max pool* a imagem de entrada vai estar com a dimensão  $20 \times 38 \times 3$ .

Já no caminho expansivo há necessidade de convoluções transpostas, pois estar utilizando uma transformação indo na direção oposta da convolução normal, ou seja, de algo que tem a forma da saída de alguma convolução para algo que tem a forma de sua entrada, mantendo um padrão de conectividade compatível com a referida convolução.

Portanto, esse caminho é constituído por quatro blocos de convolução, iguais os que são utilizados no caminho de contração, o que muda é a quantidade de filtros por blocos que agora foi de 512, 256, 128 e 64, para os blocos 1, 2, 3 e 4, respectivamente. Mas, antes de cada bloco de convolução é aplicado uma convolução transposta, com a quantidade de filtro igual ao do bloco, com dimensão  $2 \times 2$ , passo 2, seu tamanho de saída tem que ser do mesmo tamanho da entrada. Além do convolução transposta tem a camada de concatenação.

Na camada final é utilizada uma convolução  $1 \times 1$  para mapear cada vetor de recurso de 64 componentes para o número desejado de classes, a função de ativação utilizada é a sigmóide, tendo como saída uma imagem com dimensão  $320 \times 608 \times 3$ , a mesma dimensão da imagem de entrada, todos esses passos são apresentados na Figura 22. Portanto, no total a rede possui 23 camadas convolucionais. Toda esse esquema foi apresentado na Figura 4.

## 4.4 Testes dos Classificadores LDA-MLP e AP-Unet

Nesta seção é apresentado os resultados obtidos, tanto para o método, que utiliza a interação de técnicas estatísticas e rede neural artificial, quanto os obtidos para o método AP-Unet que realiza processamento na base de dados antes de utilizá-los para treinar a rede, que usa o aprendizado profundo que é uma das técnicas mais atuais em rede neurais.

### 4.4.1 Resultado do Método LDA-MLP

Como a base de dados já veio separada em treinamento e teste, não precisou realizar essa divisão. A única operação realizada na imagem foi uma redução de dimensão, de  $1250 \times 650 \times 3$  para  $63 \times 33 \times 3$ , pois a dimensão da imagem é muito grande, acarreta maior consumo de memória e tempo de processamento dos algoritmos. Em seguida, calcula-se a função discriminante linear, utilizando esse banco de dados de treinamento, a função discriminante calculada apresenta um acerto de 100 %, isto é, apresentou uma taxa de verdadeiro positivo de 100 % e uma taxa de falso positivo também de 100 %.

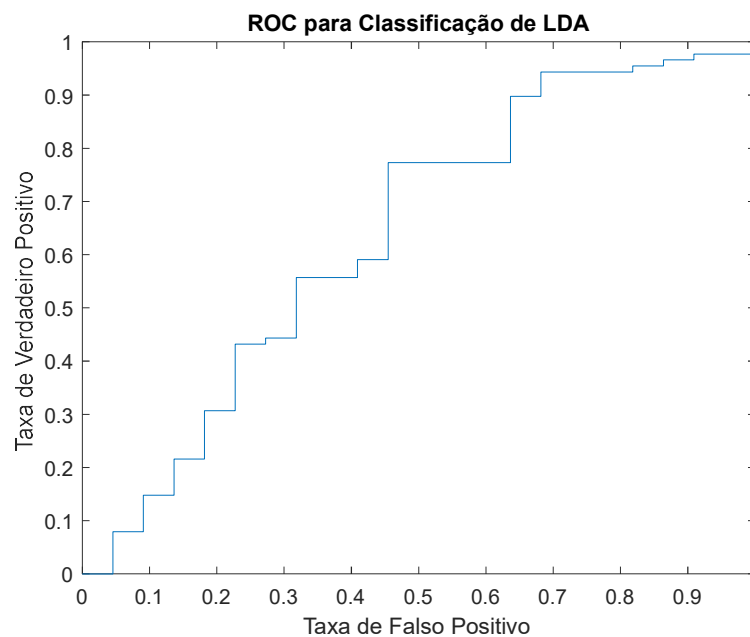
Para verificar o desempenho do modelo discriminante são realizados experimentos com o banco de dado de teste, que contém 110 imagens. Os valores das métricas de avaliação estão apresentados na Tabela 2.

Tabela 2 - Métricas do teste com o LDA.

MÉTRICAS	PORCENTAGEM
Acurácia	45,45
AUC	63,74
F1	58,90
Precisão	74,14
Recall	48,86

De acordo com a Tabela 2, observa-se que a função discriminante calculada do LDA apresenta uma classificação, que acerta 48,86 % das imagens com manchas de óleo e 31,82 % das imagens sem mancha. Ao observar a curva ROC, sabendo que ela é uma técnica gráfica utilizada para avaliar a capacidade do modelo preditivo e fazer a classificação adequada, na Figura 23 é apresentada a curva ROC para o modelo preditivo.

Figura 23 - Curva ROC para o teste do LDA.



De acordo com a Figura 23, observa-se que a curva inicialmente possui uma taxa de falso positivo igual a 0 (zero). Logo em seguida seu ângulo se aproxima de 45°, o que não é muito bom, pois o classificador se tornar menos preciso, mas depois esse ângulo começa a mudar, melhorando o desempenho da classificação. A área sob a curva ROC obtida pelo classificador da rede neural *perceptron* foi de  $AUC = 0,637$ , portanto, o classificador não é o



ideal, apesar de apresenta uma boa classificação, pois é maior que  $AUC = 0,5$ , com esse valor o classificador não consegue separar as classes.

Em busca de melhorar a classificação, utilizou-se a rede *perceptron* simples para classificar o banco de dados, mais adicionou-o ao banco de dados imagens SAR a estimativa do LDA, adicionando mais informação e esses resultados são apresentados abaixo.

O primeiro teste realizado utilizando um *perceptron* simples constituía-se de uma camada intermediária com 6237 neurônios, que são a quantidade de parâmetros do dado de entrada, tendo como entrada apenas as imagens, em que o banco de treino é constituído por 1002 imagens e o banco de teste é constituído por 110. Os resultados obtidos para esse teste são apresentados na Tabela 3.

Tabela 3 - Métricas de treino e teste, entrada - imagens.

MÉTRICAS	TREINAMENTO	TESTE
Acurácia	74,35	69,09
F1	62,00	70,00
Precisão	75,00	71,00
Recall	74,00	69,00

De acordo com a Tabela 3, observa-se que a rede *perceptron* para as imagens como entrada apresentou valores de métricas melhores para o treinamento do que para o teste. Além de apresentar-se mais eficiente na classificação das imagens que relatam mancha de óleo na superfície do oceano.

A segunda análise realizada nesta rede com uma única camada intermediária e 6238 neurônios, que é o número de parâmetros do dado de entrada com a classificação obtida pelo LDA. Os resultados obtidos para esse teste estão apresentados na Tabela 4.

Tabela 4 – Métricas de treino e teste, entrada – imagens mais classificação LDA.

<b>MÉTRICAS</b>	<b>TREINAMENTO</b>	<b>TESTE</b>
<b>Acurácia</b>	99,90	65,45
<b>F1</b>	100	68,00
<b>Precisão</b>	100	72,00
<b>Recall</b>	100	65,00

De acordo com a Tabela 4, o *perceptron* apresentou-se ideal no treinamento, pois obteve-se as métricas igual a 100 %, mas no teste apresentou valores próximo do experimento anterior, que utiliza apenas as imagens como entrada. Porém, aumentou a precisão, e assim como o anterior apresentou-se mais eficaz na classificação de imagens com mancha de óleo.

A terceira análise realizada na rede *perceptron* com uma camada intermediária e 6238 neurônios, que é o número de parâmetros do dado de entrada com o valor obtido pela função linear discriminante. Os resultados obtidos para esse teste estão apresentados na Tabela 5.

Tabela 5 - Métricas de treino e teste, entrada - imagens mais resposta da função discriminante.

<b>MÉTRICA</b>	<b>TREINAMENTO</b>	<b>TESTE</b>
<b>Acurácia</b>	78,94	63,63
<b>F1</b>	71,00	67,00
<b>Precisão</b>	82,00	73,00
<b>Recall</b>	79,00	64,00

De acordo com a Tabela 5, o *perceptron* apresentou-se satisfatório para detectar/classificar as imagens com mancha de óleo. Observando os três testes, conclui-se que a informação do LDA adicionada contribui para melhorar o treinamento da rede, apresentando valores melhores para as métricas de avaliação.

#### 4.4.2 Resultado do Modelo AP-Unet

Com o modelo da rede Unet da Subseção 4.3.2 do Capítulo 4, utilizando o banco de dados sem aplicar o filtro, apenas com o corte de uma imagem em quatro imagens, o


treinamento da rede utilizando otimizador Adam é executado. O otimizador é baseado na descida do gradiente estocástico com pouco requisitos de memória, taxa de aprendizado de  $\eta = 1 \times 10^{-4}$ , o tamanho do lote utilizado das amostras processadas é 8 (antes que o modelo seja atualizado), a quantidade de épocas é 50. O resultado obtido no treinamento tem uma precisão de 68,15 %, um *recall* de 67,13 %. Os valores de teste estão apresentados na Tabela 6, com as mesmas métricas que são analisados os resultados do método LDA-MLP.

Tabela 6 - Métricas de teste, entrada sem filtro mediana.

MÉTRICA	TESTE
Acurácia	98,64
F1	63,44
Precisão	84,74
Recall	69,28

De acordo com os valores apresentados na Tabela 6, a rede Unet mostra que consegue aprender, classificando com precisão 84,74 % das imagens de teste. Essa rede nos dar como resposta, além dessas métricas para avaliação, a imagem resposta, em que ele relata a mancha de óleo que ela detectou, essa resposta é apresentada na Figura 24.

Figura 24 - Resposta da rede Unet: (a) imagem SAR, (b) máscara, (c) resposta da rede Unet.



De acordo com a Figura 24, tem-se primeiro a imagem SAR, que é o dado de entrada que se deseja classificar, em seguida é a máscara, na qual relata apenas a mancha de óleo existente, por último é a resposta da rede Unet, que visualmente percebe-se que se aproxima bastante da máscara, para essa imagem a rede apresenta uma acurácia de 99,88 %, uma métrica F1 de 83,68 %, uma precisão de 75,15 % e um *recall* de 77,12 %. Portanto, mostrou-se eficiente, mesmo tendo algumas imagens representando manchas, sendo que a superfície não tinha manchas de óleo.


Portanto, para verificar se com filtro mediana melhora os resultados, realiza-se mais uma análise, utilizando o banco de dados que é aplicado o filtro mediana  $5 \times 5$ . O treinamento da rede AP-Unet é com otimizador Adam, uma taxa de aprendizado de  $\eta = 1 \times 10^{-4}$ , o tamanho do lote é 8, a quantidade de épocas é 50. O resultado obtido no treino tem precisão média de 74,08 % e um *recall* médio de 64,8 % e os resultados de teste estão apresentados na Tabela 7.

Tabela 7 - Métricas de teste - dados resultante do filtro mediana.

MÉTRICA	TESTE
Acurácia	98,94
F1	61,81
Precisão	72,29
Recall	81,45

De acordo com os valores apresentados na Tabela 7, a rede Unet mostra que com esse novo dados de entrada também consegue aprender, classificando com precisão de 72,29 % das imagens de teste, uma precisão mais baixa que a obtida para o banco de dados sem aplicar o filtro. Essa rede fornece como resposta as métricas para avaliação e uma imagem que relata a mancha de óleo que ela detecta, isto é, uma imagem que tenta replicar a máscara, quanto mais próximo essa imagem resposta se aproximar da máscara melhor é o aprendizado da rede, essa resposta é apresentada na Figura 25.

Figura 25 - Resposta da rede Unet: (a) imagem SAR filtrada, (b) máscara, (c) resposta da rede Unet.



De acordo com a Figura 25, tem-se a mesma imagem que a Figura 24, só que nesse treinamento e teste foi utilizado as imagem resultante de um filtro mediana  $5 \times 5$ , a primeira imagem é o dado de entrada que se deseja classificar, em seguida é a máscara, na qual relata apenas a mancha de óleo existente, por último é a resposta da rede Unet, que visualmente

percebe que não se aproxima tanto quando a anterior, mas em relação a mancha existente ela apresentou uma acurácia de 99,90 %, uma métrica F1 de 88,51 %, uma precisão de 91,49 % e um *recall* de 85,71 %. Portanto, mostra que consegue detectar com mais precisão a mancha de óleo, representando melhor na sua resposta, porém apresenta uma detecção errada, pois detectou mais manchas na imagem onde na verdade não existia.

## 4.5 Análise de Desempenho dos Classificadores

O sensoriamento remoto via radar (SAR) tem um papel crucial para a detecção de mancha de óleo na superfície aquática, uma vez que tem a capacidade de fornecer imagens de alta resolução, sendo possível a detecção dessas perturbações.

O método LDA-MLP proposto faz a integração da técnica de análise multivariada de dados utilizada, a Análise Discriminante Linear (LDA), da rede neural artificial (*perceptron*) para viabilizar a detecção de manchas de óleo na superfície do oceano, alertando caso seja detectado um derramamento de óleo. Já o método AP-Unet utiliza a rede neural convolucional com a arquitetura Unet, mas antes de treinar a rede um processamento na imagem é realizado, dividindo a imagem em 4 imagens e aplicando um filtro mediana para tentar eliminar o ruído *speckle*.

Ao analisar os dois métodos proposto, o LDA-MLP e o método AP-Unet, o segundo método apresenta uma precisão melhor no teste, principalmente no teste que não foi aplicado o filtro mediana. Mas o método LDA-MLP mostra que mesmo tendo outros métodos mais avançados, ele ainda é bastante eficiente para executar a tarefa que lhe é repassada, atendendo as expectativas, mostrando que não é ultrapassado, que foi a partir das técnicas clássicas como LDA e o MLP o começo para o desenvolvimento tecnológico. Ao analisar essas novas técnicas, observa-se que elas têm fundamento nas clássicas.

Na análise realizada, os resultados iniciais indicam que os dois modelos propostos fornecem uma estimativa satisfatória da detecção das manchas de óleo na superfície oceânica, com uma precisão de 73 % e 84,74 %, respectivamente. Portanto, a rede neural com aprendizado profundo se mostrou mais eficiente para classificar esse banco de dados. Os dois

modelos propostos mostraram que têm características para classificar as imagens, ambos modelos podem ser embargados em um microprocessador, tendo em vista um monitoramento local e contínuo de um determinado ambiente para evitar os desastres ao ecossistema e a população.

# Capítulo 5

## Conclusão

A conclusão e comentários gerais da dissertação juntamente com suas principais contribuições e propostas são apresentadas neste capítulo. Ainda, aponta-se sugestões para desenvolvimentos futuros relacionados à métodos de monitoramento e detecção de manchas de óleo na superfície do oceano.

### 5.1 Conclusões Gerais

Nesta dissertação foram apresentados métodos de análise e desenvolvimento de algoritmos para detecção de perturbações no meio aquático. Em primeira instância a metodologia proposta foi avaliada para detecção de manchas de óleo na superfície do oceano por meio da teoria e métodos das abordagens de análise multivariada de dados e aprendizado de máquina. Especificamente, redes neurais artificiais do tipo MLP e sua integração com os métodos estatísticos de LDA.

Os métodos propostos foram apresentados desde a sua concepção até a caracterização e formulação de problema específico de detecção a ser resolvido. Como parte da metodologia, nesta dissertação foram apresentados os algoritmos e procedimentos, baseados em aprendizado de máquina e na análise multivariada de dados, para o desenvolvimento da unidade do módulo do crítico em sistema de detecção.

O método de aprendizado profundo, com a rede Unet, também se mostrou eficiente na detecção das manchas de óleo. Apresentando como vantagem a imagem resposta, que é a projeção da mancha que ele detectou, o que possibilita utilizar esse dado para realizar outros estudos, tal como: o deslocamento dessa mancha.

Os algoritmos LDA-MLP propostos utilizam-se de métodos mais simples e integrando esses dois métodos observou-se um bom resultado para a classificação das imagens. Além de ser um algoritmo que não realizou processamento na base de dados. O que o difere dos demais trabalhos com imagem SAR, que na maioria das vezes realizam primeiro um processamento nas imagens, por exemplo: um tratamento para atenuar o impacto dos ruídos. Já o algoritmo AP-Unet tem como diferencial a imagem com a mancha detectada, porém é um algoritmo que demanda mais tempo para o treinamento da rede, tendo sido realizado um processamento na imagem.

## 5.2 Contribuições

Esta pesquisa procura contribuir para monitorar e mitigar os efeitos nocivos causados ao meio ambiente pelo ser humano. No caso específico da orientação desta pesquisa, tem-se um foco de aplicação e contribuição social de detectar/classificar manchas de óleo que constituem uma das principais ameaças para o oceano e o ambiente costeiro. Consequentemente, o monitoramento eficiente e alertas preventivos são necessários para combater os riscos e limitar os danos causados ao meio ambiente.

A contribuição científica deste trabalho é uma proposta de metodologia para detectar perturbações exógenas em ambientes aquáticos. A metodologia proposta é orientada para o desenvolvimento de métodos, procedimentos e algoritmo para o problema de detecção/classificação. Desta forma, a metodologia proposta pode ser aplicada o nó de sensores da rede sem fio (RSSF). Por exemplo, no monitoramento portuário, localmente e on-line via RSSF, para detectar a presença de agentes poluentes na zona de atracamento.



Inicia um processo de viabilização para aplicações dos algoritmos propostos em redes de sensores sem fio. Especificamente, aplicações da referida metodologia para projeto, implementação e implantação de sistemas embarcados que são orientados para detecção de objetos intrusos em um dado ambiente, o sensoriamento. A aplicação da metodologia proposta em imagens obtidas pelo radar-SAT, viabilizou a primeira aplicação dos algoritmos propostos para detecção de objetos em ambientes aquáticos. Como também, contribuiu de forma motivadora e construtiva para aplicações dos algoritmos propostos em sistemas baseados nas tecnologias de IoT e sensores encontrados *on the shelf*.

### 5.3 Trabalhos Futuros

Em função do tempo para a conclusão desta dissertação, recomenda-se para trabalhos futuros:

- Implementar e realizar testes do algoritmo de detecção de mancha de óleo na superfície do oceano proposto para o banco de dados proveniente de uma rede de sensores sem fio;
- Realizar a comparação dos algoritmos propostos com outras técnicas de rede neural artificial;
- Embarcar o algoritmo proposto em um nó de sensor;
- Desenvolver algoritmos para nós de sensores móveis e fixos de RSSF com restrições de tempo e de memória para detecção de agentes poluentes no meio aquático.

# Referências

- (ESA), E. S. (s.d.). *Instrument Payload*. Obtido em 12 de Dezembro de 2022, de Sentinel online:  
<https://sentinel.esa.int/web/sentinel/missions/sentinel-1/instrument-payload>
- (ESA), E. S. (s.d.). *Satellite Description*. Obtido em 12 de Dezembro de 2022, de Sentinel Online:  
<https://sentinel.esa.int/web/sentinel/missions/sentinel-1/satellite-description>
- (ESA), E. S. (s.d.). *Sentinel-1*. Obtido em 12 de Dezembro de 2022, de Sentinel Online:  
<https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- Alaa Tharwat a, b. T. (May de 2017). Linear discriminant analysis: A detailed tutorial. *Ai Communications*, 22. doi: 10.3233/AIC-170729
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Cambridge: Springer.
- Braga, A. D., Ludermir, A. P., & Bernarda, T. (2011). *Redes Neurais Artificiais - Teoria e Prática* (Vol. 2). LTC.
- Carvalho, G. d. (2015). Multivariate Data Analysis of Satellite-Derived Measurements to Distinguish Natural From Man-Made Oil Slicks On The Sea Surface of Campeche Bay (Gulf of Mexico). Rio de Janeiro, Brasil.
- DONGMEI SONG, Z. Z. (2020). A Novel Marine Oil Spillage Identification Scheme Based on Convolution Neural Network Feature Extraction From Fully Polarimetric SAR Imagery. *IEEE Access*, 08, 59801 a 59820.
- Eberhart, R. C., & Shi, Y. (2007). *Computational Intelligence: Concepts to Implementations* (1st ed.). Morgan Kaufmann.
- Embrapa. (2020). *SENTINEL - Missão Sentinel*. Obtido em 12 de Dezembro de 2022, de Satélites de Monitoramento: <https://www.embrapa.br/satelites-de-monitoramento/missoes/sentinel>
- ESA, E. S. (2004). ASAR Product Handbook. *Europe Space Agency - ESA*(11<sup>a</sup>).
- Fávero, L. P., & Belfiore, P. (2017). *Manual de análise de dados*. Rio de Janeiro: Elsevier.
- Fernandes, D., & Fernandes, M. T. (11-18 de Setembro de 1998). Imagens de Radar de Abertura Sintética como instrumento de auxílio na avaliação do impacto ambiental. *IX Simpósio Brasileiro de Sensoriamento Remoto*, pp. 733-744.
- Flood, N., Watson, F., & Collett, L. (Junho de 2019). Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia. *Int J Appl Earth Obs Geoinformation*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. Obtido de [www.deeplearningbook.org](http://www.deeplearningbook.org)
- Haykin, S. (2009). *Neural networks and learning machines*. Pearson.
- Ibama. (2019). *Manchas de Óleo Litoral Brasileiro*. Obtido em 18 de Novembro de 2022, de Ibama: <http://www.ibama.gov.br/manchasdeoleo-galeria>
- Jenen, J. R. (2009). *Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres* (Vol. 2). São José dos Campos: Parêntese.

- Joseph F. Hair, J., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (2009). *Análise Multivariada de Dados* (6 ed.). Porto Alegre, Brasil: Bookman.
- Klemas, V. (2010). Tracking Oil Slicks and Predicting their Trajectories Using Remote Sensors and Models: Case Studies of the Sea Princess and Deepwater Horizon Oil Spills. *Journal of Coastal Research*, 789 a 797.
- Krestenitis, M. O. (Janeiro de 2019). Early Identification of Oil Spills in Satellite Images Using Deep CNNs. (C. Springer, Ed.) *In International Conference on Multimedia Modeling*, 424 - 435.
- Krestenitis, M. O. (2019). Oil Spill Identification from Satellite Images Using Deep Neural Networks. *Remote Sensing*, 11,1762.
- Marcelo Andreotti, R. S., & Alessandro Jacoud Peixoto, J. C. (2020). ARIEL: An Autonomous Robotic System for Oil Spill Detection. *Offshore Technology Conference. Medium*. (25 de Agosto de 2016). Obtido em 2022, de A Diferença Entre Inteligência Artificial, Machine Learning e Deep Learning: <https://medium.com/data-science-brigade/a-diferen%C3%A7a-entre-intelig%C3%Aancia-artificial-machine-learning-e-deep-learning-930b5cc2aa42>
- Moreira, S. (24 de Dezembro de 2018). *Rede Neural Perceptron Multicamadas*. Obtido de Medium: <https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>
- OLIVEIRA, P. Á. (2020). *DEEP LEARNING NA SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS DE SATÉLITE*. Viçosa - MINAS GERAIS .
- Paravastu, V. M. (2013). A proposal of an automatic sensor system for petroleum detection. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 335 a 338.
- Pena, P. G. (2020). Derramamento de óleo bruto na costa brasileira em 2019: emergência em pública em questão. *Cad Saúde Pública*. doi:10.1590/0102-311X00231019
- Pereira, S. B. (2001). Investimentos em automação no Projeto PEGASO da PETROBRAS chegam a US\$ 225 milhões. *Revista InTech n° 32*.
- Petrobras. (2020). *Exploração e Produção de Petróleo e Gás*. Obtido em 08 de julho de 2020, de Petrobras: <https://petrobras.com.br/pt/nossas-atividades/areas-de-atuacao/exploracao-e-producao-de-petroleo-e-gas/>
- Rebello, V. P. (2015). Ranking Fuzzy de Exsudações de Óleo Detectadas com dados RADARSAT-1 na Bacia de Campos. Rio de Janeiro, Brasil.
- Rezende, A. C., Filho, G. L., & Vieira, F. H. (Novembro de 2019). Aplicação da Análise Discriminante Linear (LDA) para Classificação de Sinais Eletromiográficos (EMG) de Movimento da Mão. *VII Escola Regional de Informática de Goiás*.
- Richard O. Duda, P. E. (2001). *Pattern Classification* (Second ed.). Canada: Wiley Interscience Publication.
- Selmic, R. R., Phoha, V. V., & Serwadda, A. (2016). *Wireless Sensor Networks Security, Coverage, and Localization*. USA: Springer International Publishing.
- Silva, I. N., Spatti, D. H., & Flauzino, R. A. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas* (2ª ed.). São Paulo: Artliber Editora Ltda.
- Silva, I. N., Spatti, D. H., & Flauzino, R. A. (2010). *Redes neurais artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber.

- Skolnik, M. I. (1981). *Introduction to radar systems* (2<sup>a</sup> ed.). McGraw-Hill.
- Souza, D. L. (2006). *Sistema Inteligente para Detecção de Manchas de Óleo na Superfície Marinha através de Imagens SAR*. Natal: Universidade Federal do Rio Grande do Norte.
- Tomiyasu, K. (5 de may de 1978). Tutorial Review of Synthetic Aperture Radat (SAR) with Applications to Imaging of th Ocean Surface. *IEEE*, 66.
- Varella, C. A. (2020). *ANÁLISE DISCRIMINANTE*. Rio de Janeiro.
- Woods, R. C. (2010). *Processamento digital de imagens* (3 ed.). São Paulo, Brasil: Pearson Prentice Hall.
- Yoo, S.-m., Cho, C., & Lee, K. H. (2019). Structure of Deep Learning Inference Engines for Embedded Systems. *International Conference on Information and Communication Technology Convergence (ICTC)*. doi:10.1109/ictc46691.2019.8939843
- Zhang, M., Liao, W., Zhang, J., Gao, H., Wang, F., & Lin, B. (2019). Embedded Face Recognition System Based on Multi-task Convolutional Neural Network and LBP Features. *International Conference of Intelligent Applied Systems on Engineering - IEEE ICIASE*. doi:10.1109/iciase45644.2019.907

# Apêndice I

## PRINCÍPIOS DO RADAR

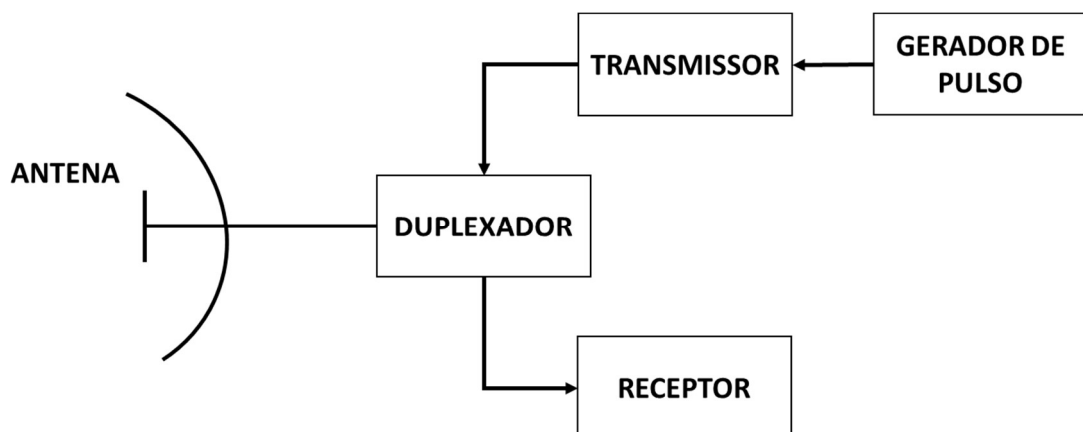
---

---

O radar é um sistema que utiliza radiação eletromagnética de microondas com o objetivo de detecção e de localização de objetos, opera transmitindo uma determinada forma de onda. Por exemplo, uma onda senoidal modulada por pulso, detecta a natureza do sinal refletido (o eco). O radar não possui uma resolução tão detalhada como o olho humano, mas ele é projetado para ver através das condições inviável à visão humana, tais como: escuridão, neblina, chuva e neve. Além disso, o radar tem a vantagem de medir a distância ou o alcance do objeto (Skolnik, 1981).

Um radar consiste basicamente de uma antena, um transmissor, que emite pulsos eletromagnéticos que são gerados por um oscilador, de um duplexador, para utilizar apenas uma antena, de um receptor, dispositivo de detecção de energia, recebe o sinal que é refletido, a Figura 26 apresenta esse diagrama de blocos.

Figura 26 - Diagrama de blocos do sistema simplificado de um radar.



De acordo com a Figura 26 tem-se o gerador de pulso, na qual o tipo de pulso vai depender do que se deseja monitorar, em seguida esse pulso passa pelo transmissor e pelo duplexador, que permite a conexão do transmissor e do receptor na mesma antena, sem que haja distorção dos sinais, o sinal transmitido pela antena colide em um objeto (alvo), e este reflete o sinal em todas as direções, é esse sinal refletido que interessa ao radar, pois a antena detecta, esse sinal e encaminha ao receptor, que irá decodificar o sinal recebido.

Conseqüentemente, a capacidade do radar de obter informações está relacionada com a quantidade de sinais refletidos pelo objeto alvo. No caso das imagens, estas são construídas a partir da integração de várias ondas eletromagnéticas refletidas, assim, cada elemento da imagem produz um brilho diferente (à qual corresponde aos pixels da imagem após o processamento), que traduz a percentagem de energia refletida pela área correspondente.

A distância do radar até o alvo é determinada pela medição do tempo que o sinal do radar leva para chegar ao alvo e retornar. A posição angular do alvo é determinada a partir da direção de chegada dos feixes na antena. Se houver movimento relativo entre o alvo e o radar, a mudança na frequência portadora da onda refletida (efeito *doppler*) é uma medida da velocidade relativa (radial) do alvo e pode ser usada para distinguir alvos em movimento de objetos estacionários. Em radares que rastreiam continuamente o movimento de um alvo, também está disponível uma indicação contínua da taxa de mudança da posição do alvo (Skolnik, 1981).

O transmissor do radar também pode operar com sinal contínuo, em vez de pulsado, mas isso só é possível se puder separar o sinal transmitido (sinal forte) do sinal refletido (sinal fraco). Uma solução é a utilização de antenas separadas para a transmissão e recepção, porém o isolamento ainda não é suficiente. Conseqüentemente, uma técnica viável para separar esses dois sinais, quando há movimento relativo entre o radar e o alvo é baseada no reconhecimento da mudança na frequência do sinal de eco causada pelo efeito *doppler*, pois se a fonte emissora ou observadora do sinal estiver em movimento, ocorrerá uma aparente mudança na frequência. Esse efeito *doppler* é a base do radar de onda contínua (*continuous wave - CW*) (Skolnik, 1981).

A resolução de alcance do radar ( $\delta_r$ ) é determinada pelo comprimento efetivo do pulso do radar  $\tau$ , e  $\delta_r = c\tau/2$ , onde  $c$  é a velocidade da luz. A resolução angular azimutal ou de alcance cruzado do alvo é estabelecida pela orientação do feixe da antena, que está relacionada ao tamanho da antena (Tomiyasu, 1978).

Os radares podem ter diferentes configurações de polarização, na qual essa polarização dar informação a respeito da orientação dos campos magnéticos e elétrico de uma onda eletromagnética. As polarizações lineares mais comuns são: HH, VV, HV e VH, sendo H – horizontal e V – vertical, na qual a primeira letra indica a polarização do pulso emitido pelo radar e a segunda letra indica a polarização do sinal captado pelo sensor (Souza, 2006).