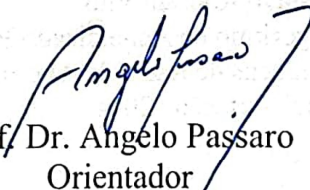


Dissertação apresentada à Pró-Reitoria de Pós-Graduação do Instituto Tecnológico de Aeronáutica, como parte dos requisitos para obtenção do título de Mestre em Ciências no Programa de Pós-Graduação em Ciências e Tecnologias Espaciais, Área de Sensores e Atuadores Espaciais.

Luis Gustavo Ronsani Vito

**ALGORITMO DE APRENDIZADO PROFUNDO PARA
DETECÇÃO DE MANCHAS DE ÓLEO E EMBARCAÇÕES
EM IMAGENS DE RADAR DE ABERTURA SINTÉTICA**

Dissertação aprovada em sua versão final pelos abaixo assinados:


Prof. Dr. Angelo Passaro
Orientador

Prof. Dr. André Valdetaro Gomes Cavaliere
Pró-Reitor de Pós-Graduação

Campo Montenegro
São José dos Campos, SP – Brasil
2024

Dados Internacionais de Catalogação-na-Publicação (CIP)

Divisão de Informação e Documentação

Vito, Luis Gustavo Ronsani
Algoritmo de Aprendizado Profundo para Detecção de Manchas de Óleo e Embarcações em Imagens de Radar de Abertura Sintética / Luis Gustavo Ronsani Vito.
São José dos Campos, 2024.
97f.

Dissertação de Mestrado – Curso de Ciências e Tecnologias Espaciais, Área de Sensores e Atuadores Espaciais – Instituto Tecnológico de Aeronáutica, 2024. Orientador: Prof. Dr. Angelo Passaro.

1. Monitoramento. 2. Sensoriamento Remoto. 3. Deep Learning. I. Instituto Tecnológico de Aeronáutica. II. Algoritmo de Aprendizado Profundo para Detecção de Manchas de Óleo e Embarcações em Imagens de Radar de Abertura Sintética.

REFERÊNCIA BIBLIOGRÁFICA

VITO, Luis Gustavo Ronsani. **Algoritmo de Aprendizado Profundo para Detecção de Manchas de Óleo e Embarcações em Imagens de Radar de Abertura Sintética**. 2024. 97f. Dissertação de Mestrado em Ciências e Tecnologias Espaciais – Instituto Tecnológico de Aeronáutica, São José dos Campos, 2024.

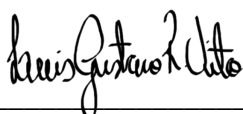
CESSÃO DE DIREITOS

NOME DO AUTOR: Luis Gustavo Ronsani Vito

TÍTULO DO TRABALHO: Algoritmo de Aprendizado Profundo para Detecção de Manchas de Óleo e Embarcações em Imagens de Radar de Abertura Sintética.

TIPO DO TRABALHO/ANO: Dissertação / 2024

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



Luis Gustavo Ronsani Vito

Rua H9B, 203 – Apto 203 Bloco B, Campus do CTA

CEP: 12.228-611, São José dos Campos - SP

**ALGORITMO DE APRENDIZADO PROFUNDO PARA
DETECÇÃO DE MANCHAS DE ÓLEO E EMBARCAÇÕES
EM IMAGENS DE RADAR DE ABERTURA SINTÉTICA**

Luis Gustavo Ronsani Vito

Composição da Banca Examinadora:

Prof. Dr. Elcio Hideiti Shiguemori	Presidente	- IEAv
Prof. Dr. Angelo Passaro	Orientador	- IEAv
Prof. Dr. Renato Machado	Membro Interno	- ITA
Dr. José Alberto Silva de Sá	Membro Externo	- UEPA

ITA

Dedico este trabalho à minha filha, Laís e
em especial à minha esposa, Layanne,
pelo apoio incondicional e constante incentivo.

Agradecimentos

Inicialmente, gostaria de expressar minha profunda gratidão a Deus, que me guiou em todas as etapas da minha vida e colocou pessoas incrivelmente especiais em meu caminho, cuja contribuição foi fundamental para a conclusão deste trabalho.

À minha esposa e eterna companheira, Layanne, agradeço o incentivo e apoio incondicional em todos os momentos, e por estar ao meu lado em cada desafio da minha carreira.

À minha filha, Laís, minha luz e inspiração, especialmente nos momentos mais desafiadores.

Aos meus pais, Santos e Arlete (in memoriam), agradeço o imenso esforço e dedicação na minha formação e educação.

Ao meu orientador, Prof. Angelo Passaro, sou grato por aceitar o desafio de me orientar com tanta dedicação, paciência e profissionalismo, frequentemente sacrificando seu próprio tempo de descanso para auxiliar no progresso deste mestrado.

Aos meus amigos e colegas de curso, em especial ao Capitão de Corveta Amilton, Capitão-Tenente Taffarel e Capitão-Tenente Antônio Pedro, por todas as conversas enriquecedoras e aprendizados compartilhados. Ao Capitão de Corveta Gabriel, minha gratidão pelo acolhimento e pelos valiosos ensinamentos.

À equipe do PPGA0, representada aqui pelo Cel. Rebouças, cuja ajuda foi essencial e incondicional durante todo o processo.

Ao Instituto de Estudos Avançados (IEAv) e ao LEV (Laboratório de Engenharia Virtual) por me proporcionarem um ambiente de pesquisa de alta qualidade. Agradeço também aos meus colegas, cuja colaboração e apoio foram fundamentais para o desenvolvimento deste trabalho.

À CAPES e ao CNPq, pelo apoio financeiro em publicações científicas.

À Força Aérea Brasileira, por abrir as portas da instituição a militares de outras Forças Armadas, minha profunda gratidão.

E, por fim, à Marinha do Brasil, agradeço por confiar em mim e me atribuir esta missão tão importante.

"A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original".

(Albert Einstein)

Resumo

Esta dissertação aborda o desenvolvimento de um algoritmo para a detecção de manchas de óleo e embarcações em imagens de Radar de Abertura Sintética (SAR), utilizando uma versão modificada da rede neural U-Net, originalmente proposta por Ronneberger, Fischer e Brox (2015). Este trabalho destaca-se pelo aprimoramento da arquitetura U-Net, por meio de modificações, tais como o uso de blocos residuais, inclusão de regularização L2, adaptação da última camada convolucional, entre outras, visando melhorar os resultados dos estudos de referência no campo de detecção por meio da segmentação semântica de imagens SAR. A pesquisa abrange um conjunto de processos metodológicos, divididos em cinco etapas principais. A primeira etapa envolve a aquisição e construção de bancos de dados (*dataset*) de imagens SAR, fornecidas pelos satélites Sentinel-1 da Agência Espacial Europeia (ESA) contendo alvos específicos de manchas de óleo e embarcações. A segunda etapa se concentra no processamento dessas imagens SAR, um passo importante para garantir a qualidade e a precisão dos dados para os treinamentos subsequentes. A terceira etapa aborda a implementação de modificações na arquitetura U-Net. Estas alterações visam aumentar a eficácia do modelo em lidar com as complexidades inerentes à detecção de alvos em imagens SAR. A quarta etapa, envolvendo treinamentos e validações dos modelos, é feita de forma individualizada para cada tipo de alvo - manchas de óleo e embarcações. Esta abordagem garante que o algoritmo seja otimizado para identificar cada tipo de alvo de forma individualizada. A etapa final é a confecção do algoritmo de detecção, que opera de forma sequencial. Inicialmente, detecta-se as manchas de óleo e, em seguida, as embarcações, mas apenas nas imagens onde a detecção de manchas de óleo foi confirmada. Esta estratégia sequencial permite uma análise mais focada no alvo a ser detectado. Os resultados obtidos nos treinamentos foram promissores. O modelo para detecção de manchas de óleo apresentou uma Acurácia de 94%, Precisão de 86% e Índice de Jaccard (IoU) de 67,51%. O modelo para detecção de embarcações alcançou uma Acurácia de 99%, Precisão de 89% e IoU de 76,23%. Estes resultados superam algumas abordagens de referência anteriores que fizeram o uso da arquitetura U-Net, como KRESTENITIS *et al.* (2019) e SHABAN *et al.* (2021), evidenciando a eficácia das modificações implementadas e da metodologia adotada. O estudo demonstra a viabilidade de combinar sensoriamento remoto SAR com inteligência artificial para enfrentar desafios ambientais contemporâneos. Sugere-se para estudos futuros a pesquisa por melhorias

na rede com outras modificações e seus hiperparâmetros, ampliação dos conjuntos de dados e utilização de outras técnicas de aumento de dados, a exploração de outras arquiteturas de redes neurais para avaliar seu desempenho em comparação com a U-Net e a integração de métodos de detecção de mudanças para identificar os alvos.

Abstract

This dissertation discusses the development of an algorithm for detecting oil spills and vessels in Synthetic Aperture Radar (SAR) images, using a modified version of the U-Net neural network originally proposed by Ronneberger, Fischer, and Brox (2015). This work is distinguished by improvements to the U-Net architecture through modifications such as the use of residual blocks, the inclusion of L2 regularization, adaptation of the final convolutional layer, and others, aimed at enhancing the results of reference studies in the field of detection through semantic segmentation of SAR images. The research encompasses a set of methodological processes, divided into five main stages. The first stage involves the acquisition and construction of SAR image datasets, provided by the European Space Agency's (ESA) Sentinel-1 satellites, containing specific targets of oil spills and vessels. The second stage focuses on the processing of these SAR images, a crucial step to ensure the quality and accuracy of the data for subsequent training. The third stage addresses the implementation of modifications to the U-Net architecture, aiming to increase the model's effectiveness in dealing with the complexities inherent in target detection in SAR images. The fourth stage involves the training and validation of the models, conducted individually for each type of target - oil spills and vessels. This approach ensures that the algorithm is optimized for identifying each type of target individually. The final stage is the development of the detection algorithm, which operates sequentially. Initially, it detects oil spills and then vessels, but only in images where oil spill detection has been confirmed. This sequential strategy allows for a more targeted analysis of the object to be detected. The results obtained in the training were promising. The model for oil spill detection showed an Accuracy of 94%, Precision of 86%, and Jaccard Index (IoU) of 67.51%. The model for vessel detection achieved an Accuracy of 99%, Precision of 89%, and IoU of 76.23%. These results surpass some previous reference approaches that used the U-Net architecture, such as KRESTENITIS et al. (2019) and SHABAN et al. (2021), demonstrating the effectiveness of the implemented modifications and the adopted methodology. The study demonstrates the feasibility of combining SAR remote sensing with artificial intelligence to address contemporary environmental challenges. Future studies are suggested to research improvements in the network with other modifications and hyperparameters, expansion of datasets, use of other data augmentation techniques, exploration of other neural network architectures to evaluate

their performance in comparison with U-Net, and the integration of change detection methods to identify targets.

Lista de Figuras

Figura 1.1 – Evolução das técnicas de detecção de alvos em imagens de sensoriamento remoto orbital.....	23
Figura 1.2 – Área oceânica que compõe a Amazônia Azul: em azul claro, as áreas sob jurisdição nacional e em azul escuro as áreas solicitadas para ampliação do limite exterior da plataforma continental, que estão sob análise na ONU (GOMES E SALDANHA-CORRÊA, 2021).....	25
Figura 2.1 – Ilustração do satélite com sensor SAR Sentinel-1. Imagem extraída de (EUROPEAN SPACE AGENCY, 2023).	33
Figura 2.2 – Geometria básica de aquisição de um sistema SAR.	34
Figura 2.3 – Imagem SAR com mancha de óleo (região mais escura ao centro das imagens) demonstrando o efeito degradante do <i>speckle</i> : (a) imagem SAR original, (b) imagem SAR com filtro <i>speckle</i>	39
Figura 2.4 – Modos dos produtos dos satélites Sentinel 1 (EUROPEAN SPACE AGENCY, 2023).....	41
Figura 2.5 – Comparação entre a imagem ótica (a) e SAR (b) de uma mesma região, obtidas em horários próximos, demonstra a independência das imagens SAR em relação às condições climáticas.	42
Figura 2.6 – Mecanismos de espalhamento da superfície do oceano e alvos.....	47
Figura 2.7 – Principais redes CNNs para detecção de objetos em imagens.....	49
Figura 2.8 – Arquitetura da rede U-Net original (RONNEBERGER; FISCHER; BROX, 2015).....	53
Figura 3.1 – Metodologia da pesquisa.....	58
Figura 3.2 - Exemplos de imagens SAR do <i>dataset</i> do autor (KRESTENITIS <i>et al.</i> , 2019)...	59

Figura 3.3 - Exemplos de imagens SAR do <i>dataset</i> do autor (CONCEIÇÃO <i>et al.</i> , 2021).....	59
Figura 3.4 - Exemplos de imagens com alvos com manchas de óleo (a) e embarcações (b) com seus respectivos rótulos (c) e (d), determinando a localização dos alvos. Azul: Mancha de óleo; Marrom: Embarcações.....	62
Figura 3.5 - Exemplos de imagens SAR com falsos positivo (a) e (b) e seus respectivos rótulos (c) e (d). Azul: Mancha de óleo; Vermelho: Falso positivo; Verde: Continente.	63
Figura 3.6 – Script do algoritmo de detecção.....	69
Figura 3.7 – Imagens SAR utilizadas na aplicação prática do algoritmo: (a) litoral Nordeste brasileiro (Rio Grande do Norte, 2019); (b) litoral Paulista (porto de Santos, 2023); (c) Mar Vermelho, 2020; (d) litoral Nordeste brasileiro (Bahia, 2019); (e) Mar Mediterrâneo, 2018..	70
Figura 4.1 – Curva de aprendizado do treinamento do modelo de detecção de manchas de óleo. (Gráfico da perda de treinamento e validação em função do número de épocas para o modelo de detecção de manchas de óleo).....	76
Figura 4.2 – Curva de desempenho do treinamento do modelo de detecção de manchas de óleo. (Gráfico do IoU em função do número de épocas para o modelo de detecção de manchas de óleo)	76
Figura 4.3 – Curva de aprendizado do treinamento do modelo de detecção de embarcações. (Gráfico da perda de treinamento e validação em função do número de épocas para o modelo de detecção de manchas de óleo).....	78
Figura 4.4 – Curva de desempenho do treinamento do modelo de detecção de embarcações. (Gráfico da IoU em função do número de épocas para o modelo de detecção de manchas de óleo).....	78
Figura 4.5 – Representação dos resultados após a Fase 1 (detecção de manchas de óleo) no formato probabilístico. As áreas em tons de vermelho indicam maior probabilidade de presença de manchas de óleo, enquanto as regiões em azul sugerem menor probabilidade.	79

Figura 4.6 – Representação dos resultados após a Fase 1 (detecção de manchas de óleo) no formato binário, destacando apenas as detecções com probabilidade superior a 90%. As áreas em vermelho correspondem às manchas de óleo identificadas pelo modelo, enquanto as regiões em azul indicam áreas não detectadas como manchas. Observa-se que somente nas imagens (a), (c), (d) e (e) houve a identificação de manchas de óleo. 80

Figura 4.7 – Representação dos resultados após a Fase 2 (detecção de embarcações) nos formatos probabilístico e binário. Observa-se que somente nas imagens (a), (b), (c) houve a identificação clara de embarcações. Na imagem (e) a detecção ocorreu de maneira menos intensa, e na imagem (d) nada foi identificado..... 81

Lista de Tabelas

Tabela 2.1 – Principais sensores orbitais SAR.	32
Tabela 3.1 – Características dos <i>datasets</i> .	60
Tabela 3.2 – Identificação dos rótulos (máscaras binárias) dos <i>datasets</i> .	64
Tabela 3.3 – Principais parâmetros da rede U-NET com modificações.	67
Tabela 4.1 – Métricas obtidas nos treinamentos dos modelos.	74
Tabela 4.2 – Comparação dos resultados do modelo de manchas de óleo do método proposto com U-Net original e com trabalhos de referência utilizando arquitetura U-Net.	84
Tabela 4.3 – Comparação dos resultados do modelo de embarcações do método proposto com U-Net original e com trabalhos de referência utilizando arquitetura U-Net.	85

Lista de Abreviaturas e Siglas

ATR	Reconhecimento Automático de Alvos (<i>Automatic Target Recognition</i>)
CNN	Rede Neural de Convolução (<i>Convolutional Neural Network</i>)
dB	Decibel
ESA	Agência Espacial Europeia (<i>European Space Agency</i>)
EW	<i>Extra Wide</i>
FCN	Redes Completamente Convolucionais (<i>Fully Convolutional Networks</i>)
FRP	Frequência de Repetição de Pulsos
GPU	Unidade de Processamento Gráfico (<i>Graphics Processing Unit</i>)
GRD	<i>Ground Range Detected</i>
HH	Transmissão na polarização horizontal e recepção na polarização horizontal
IA	Inteligência Artificial
IoU	<i>Intersection over Union</i>
IW	<i>Interferometric Wide Swath</i>
JAXA	Agência de Exploração Aeroespacial do Japão (<i>Japan Aerospace Exploration Agency</i>)
JPEG	<i>Joint Photographic Experts Group</i>
ND	Nível Digital
OCN	<i>Ocean</i>
RADAR	Detecção e Medição de Alcance por Rádio (<i>Radio Detection And Ranging</i>)
RCS	Seção Reta Radar (<i>Radar Cross Section</i>)
RGB	Bandas ou canais vermelho, verde e azul (<i>Red, Green, and Blue</i>)
ReLU	Função <i>Rectified Linear Unit</i>
SAR	Radar de Abertura Sintética (<i>Synthetic Aperture Radar</i>)

SLC	<i>Single Look Complex</i>
SM	Modo <i>Stripmap</i>
SNAP	<i>Sentinel Application Platform</i>
VHF	Banda do espectro eletromagnético de operação rádio (<i>Very High Frequency</i>)
VV	Transmissão na polarização vertical e recepção na polarização vertical

Lista de Símbolos

E	Amplitude do campo elétrico
R	distância em Range de um SAR
t	tempo
E_0	Amplitude do campo elétrico no tempo 0.
e	Número de Euler ($e = 2,718281828\dots$)
j	Raiz quadrada de -1.
ω	Frequência angular
ϕ	Fase
β	Constante de fase ou número de onda
S	Matriz de Sinclair ou matriz de espalhamento
δr	resolução em Range de um SAR
c	velocidade da luz
τ	tamanho do pulso
$\delta \alpha$	resolução em azimute de um SAR
L	comprimento útil de uma antena SAR
Z	Imagem SAR no formato complexo
In	Inphase (parte real da imagem complexa)
Q	Quadrature (parte imaginária da imagem complexa)
i	linha do feature map
A	Imagem SAR em Amplitude
I	Imagem SAR em Intensidade
$arctg$	Função arco-tangente
x	Logits (outputs do modelo que não são normalizados para uma probabilidade)
y	Rótulos binários verdadeiros (0 ou 1)
\log	Função logaritmo

Sumário

1	INTRODUÇÃO	20
1.1	Contexto global dos oceanos e derramamentos de óleo	21
1.1.1	Impactos ambientais, econômicas e sociais	22
1.1.2	Desafios globais de derramamentos de óleo	22
1.2	Tecnologias e métodos de monitoramento marítimo mundial	22
1.3	Relevância da América Latina e o Brasil no cenário marítimo	24
1.3.1	A Amazônia Azul: Significado e importância	24
1.3.2	Relevância da Amazônia Azul para o Brasil	25
1.3.3	Desafios de monitoramento e proteção da Amazônia Azul	26
1.3.4	Comparação com outras regiões marítimas	27
1.4	Objetivo principal e metas específicas	28
1.5	Organização da Dissertação	28
2	CONCEITOS TEÓRICOS	29
2.1	Polarimetria e matrizes de espalhamento	29
2.2	Sensor SAR	31
2.2.1	Sensores orbitais SAR - Sentinel-1	40
2.2.2	Sensoriamento Remoto por imagens de Radar	42
2.2.3	Retroespalhamento dos alvos, do <i>Background</i> e dos Falsos positivos	43
2.3	Aprendizado Profundo (<i>Deep Learning</i>)	47
2.3.1	Redes Neurais Convolucionais (CNNs)	49
2.3.2	Algoritmos de detecção	50
2.3.3	Segmentação semântica	51
2.3.4	Arquitetura U-Net	52
2.4	Indicadores utilizados para avaliação	54
3	METODOLOGIA	57
3.1	Etapa 1: Banco de dados (<i>Dataset</i>)	58
3.2	Etapa 2: Processamento das imagens	61
3.3	Etapa 3: Arquitetura U-Net e modificações	64
3.4	Etapa 4: Treinamentos e Validações	67
3.5	Etapa 5: Implementação do algoritmo	69

3.5.1	Fase 1: Detecção de manchas de óleo	71
3.5.2	Fase 2: Detecção de embarcações	71
3.5.3	Análise da estratégia metodológica	72
4	RESULTADOS E DISCUSSÕES	73
4.1	Resultado dos Treinamentos	73
4.1.1	Modelo de manchas de óleo	75
4.1.2	Modelo de embarcações	77
4.2	Resultados da aplicação prática do algoritmo	79
4.3	Discussão sobre os Treinamentos	82
4.4	Discussão sobre a aplicação prática dos algoritmos	82
4.5	Discussão sobre a comparação dos resultados obtidos com algoritmos de	
	Referência	83
5	CONCLUSÃO E TRABALHOS FUTUROS	86
6	REFERÊNCIAS	88

1 Introdução

O monitoramento e gestão de ambientes oceânicos compreendem uma temática de destaque em discussões acadêmicas e político-econômicas globais, dada a complexidade e amplitude de implicações interligadas a estes ecossistemas. As regiões marítimas, fundamentais para a sustentabilidade biológica, também são espinhas dorsais de economias, ancorando setores como a pesca, transporte marítimo, e, ainda, operações de exploração de recursos naturais (SOLAN; ASPDEN; PATERSON, 2012). Este último, especialmente a exploração de petróleo *offshore*, carrega consigo um ônus considerável, materializado por meio de derramamentos de óleo que perpassam interseções de danos ambientais, prejuízos econômicos e consequências sociais (OGBUKA *et al.*, 2022).

Em um cenário global onde os oceanos constituem elementos para a biodiversidade e para atividades humanas essenciais, a formulação de mecanismos voltados ao monitoramento e à gestão destas vastas extensões aquáticas torna-se imperativa. Diferentes tecnologias e métodos têm sido incorporados à prática de monitoramento de oceanos numa escala mundial, incluindo a utilização de imagens de satélite e sistemas dedicados à coleta de dados marinhos, proporcionando assim ferramentas para uma administração oceânica mais esclarecida e estratégica (VO *et al.*, 2021).

No que concerne à América Latina e, particularmente, ao Brasil, as particularidades e desafios em relação aos mares assumem contornos únicos. A expressão "Amazônia Azul" surge como uma representação da extensa e rica faixa marítima brasileira, a qual além de ser um reservatório de biodiversidade, é um ativo econômico estratégico, figurando no centro de políticas e debates voltados para sua exploração sustentável e proteção (SOARES *et al.*, 2017). A paridade entre preservar e utilizar de forma eficiente esta porção azul do território evidencia-se por meio de práticas e políticas que visam a monitorização e mitigação de ameaças potenciais, como os já mencionados derramamentos de óleo.

A vigilância marítima, quando apoiada pelo sensoriamento remoto, emerge como uma estratégia saliente para amparar essa proteção, atuando como um dissuasor de atividades ilícitas, como exploração ilegal e pirataria. Sistemas equipados com Radar de Abertura Sintética (*Synthetic Aperture Radar - SAR*) têm desempenhado um papel integral no sensoriamento remoto terrestre por mais de três décadas, encontrando aplicabilidade em áreas como geociências, alterações climáticas (MOREIRA *et al.*, 2013) e na resposta a acidentes

ambientais relacionados a derramamentos de óleo (CANTORNA *et al.*, 2019; SOLBERG, 2012). Adicionalmente, a técnica SAR se estabeleceu como uma abordagem utilizada na vigilância marítima (BRUSCH *et al.*, 2010; RANE; SANGILI, 2020).

Os sistemas SAR têm facultado imagens oceânicas de alta resolução, propiciando a supervisão operacional de embarcações, com destaque para sistemas como o de Monitoramento do Oceano (*Ocean Monitoring System - OMW*), o SAR de Demonstração do Alasca (*Alaska SAR Demonstration - AKDEMO*), o sistema do Centro Comum de Pesquisa da Comunidade Europeia (*Joint Research Centre - JRC*), o sistema *MaST do Qinetiq* (CRISP, 2004), e o sistema *Copernicus* da Agência Espacial Europeia (ESA) (POTIN *et al.*, 2019).

Esta dissertação, portanto, propõe-se a desenvolver um algoritmo de monitoramento marítimo, eficiente e robusto, detectando possíveis manchas de óleo e embarcações de forma automática com uso de Inteligência Artificial (IA), por meio de Rede de Aprendizado Profundo. Dessa forma, a estruturação subsequente deste trabalho busca, inicialmente, situar o leitor no contexto global dos oceanos e desafios advindos de derramamentos de óleo (Seção 1.1), transitar pelas tecnologias e métodos de monitoramento marítimo em voga no cenário mundial (Seção 1.2), e aprofundar-se na peculiaridade e relevância da Amazônia Azul no espectro marítimo brasileiro e latino-americano (Seção 1.3). A clareza dos propósitos desta pesquisa e os caminhos pelos quais ela se desenvolverá serão delineados na Seção 1.4 e 1.5, respectivamente.

1.1 Contexto global dos oceanos e derramamentos de óleo

Os oceanos, que abrangem 70% da superfície terrestre, são vitais para a manutenção da vida no planeta (ORGANIZAÇÃO DAS NAÇÕES UNIDAS, 2022). Eles atuam como reguladores climáticos, absorvendo grandes quantidades de dióxido de carbono e liberando oxigênio, essencial para a sobrevivência de inúmeras espécies. Além disso, os oceanos são a espinha dorsal de muitas economias globais, proporcionando alimentos, empregos e formando a base para setores como a pesca, transporte marítimo e turismo.

No entanto, a integridade dos oceanos está sob ameaça constante devido a várias atividades humanas. Derramamentos de óleo, em particular, têm sido uma fonte recorrente de degradação ambiental. Incidentes como o do *Exxon Valdez*, que despejou cerca de 11 milhões de galões de óleo cru no Golfo do Alasca (ENCYCLOPAEDIA BRITANNICA, 2023), e o *Deepwater Horizon*, que resultou no vazamento de aproximadamente 4,9 milhões de barris de óleo no Golfo do México (BBC BRASIL, 2010), são testemunhos da magnitude do problema.

1.1.1 Impactos ambientais, econômicas e sociais

Os derramamentos de óleo apresentam consequências profundas e multifacetadas que se estendem muito além do que é imediatamente visível. Segundo Cole *et al.* (2011), a contaminação pode persistir no ambiente por décadas, comprometendo a reprodução e crescimento de organismos marinhos, desde os microscópicos até grandes mamíferos marinhos. Esta contaminação tem o potencial de perturbar ecossistemas delicados, com zonas úmidas, manguezais e recifes de corais, todos vitais para a biodiversidade marinha, mostrando-se particularmente vulneráveis. O óleo derramado pode cobrir e asfixiar organismos, causando desequilíbrios ecológicos de longo prazo e perturbando cadeias alimentares. Do ponto de vista econômico, as ramificações são igualmente severas. A pesca e o turismo, pilares fundamentais para muitas comunidades costeiras, enfrentam adversidades significativas. Segundo Newman *et al.* (2015), há também a desvalorização de propriedades costeiras e os custos substanciais associados à limpeza e recuperação após tais incidentes. No aspecto social, as consequências são igualmente perturbadoras. Além dos impactos diretos na saúde humana devido à exposição ao óleo, comunidades inteiras podem sofrer com deslocamentos, perda de empregos e uma ruptura significativa em seus modos de vida tradicionais.

1.1.2 Desafios globais de derramamentos de óleo

A prevenção e resposta a derramamentos de óleo são grandes desafios. Globalmente, é imperativo fortalecer regulamentações e padrões de segurança para exploração e transporte de petróleo. Investimentos em pesquisa e desenvolvimento são necessários para criar tecnologias mais eficazes de prevenção, detecção e limpeza de derramamentos. A cooperação internacional é vital, pois os impactos de um derramamento podem transcender fronteiras, afetando ecossistemas e economias em uma escala global.

1.2 Tecnologias e métodos de monitoramento marítimo mundial

O monitoramento marítimo é uma componente essencial para a gestão e proteção dos oceanos, especialmente quando se trata de detectar derramamentos de óleo e monitorar embarcações. Tradicionalmente, o monitoramento marítimo é realizado por diversas técnicas,

desde as visuais realizadas por patrulhas oceânicas por navios e aeronaves, até as realizadas em regiões litorâneas pelas autoridades, organizações e comunidades.

Com o surgimento de satélites, aliado a necessidade de monitoramento em grandes áreas, tem dependido de tecnologias como radar e satélites (PATROUMPAS *et al.*, 2017; PITSIKALIS *et al.*, 2019). Estes sistemas permitem a detecção de navios e em alguns casos, derramamentos de óleo ou outras substâncias no oceano. Diversas técnicas surgiram ao longo dos últimos anos na área de detecção e classificação de alvos com uso de imagens do sensoriamento remoto orbital, ilustrado na Figura 1.1.

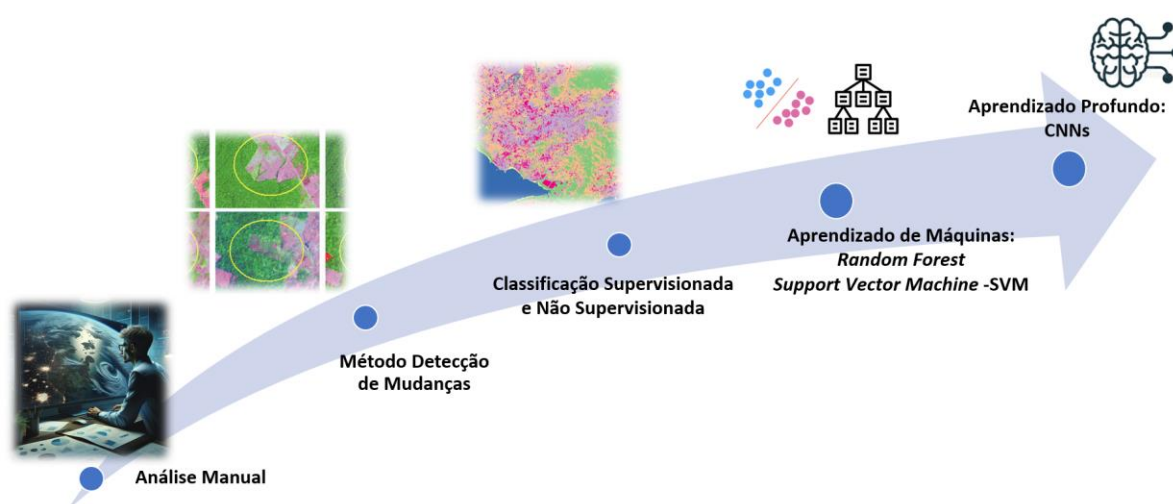


Figura 1.1 – Evolução das técnicas de detecção de alvos em imagens de sensoriamento remoto orbital.

Os radares, especialmente o Radar de Abertura Sintética, são amplamente utilizados para detectar derramamentos de óleo, pois podem operar em qualquer condição climática e fornecer imagens de alta resolução da superfície do mar (DEL FRATE *et al.*, 2000). Satélites equipados com sensores radares, ópticos e infravermelhos desempenham um papel significativo, permitindo uma visão ampla e contínua das áreas marítimas (SOLDI *et al.*, 2021).

O cenário tecnológico está em constante evolução. Segundo Vasconcelos *et al.* (2020), atualmente, observa-se uma tendência crescente na adoção de Inteligência Artificial (IA) com uso do Aprendizado de Máquina para analisar dados de satélite e detectar anomalias, como derramamentos de óleo.

Dentro do Aprendizado de Máquinas, as Redes Neurais Convolucionais (CNNs) possuem destaque na detecção de objetos em imagens, e em particular a rede U-Net, utilizada por diversos pesquisadores atualmente em trabalhos de detecção de alvos marítimos em imagens SAR (CHEN; WANG, 2022; SHABAN *et al.*, 2021; KRESTENITIS *et al.*, 2019).

1.3 Relevância da América Latina e o Brasil no cenário marítimo

A América Latina, com sua vasta extensão costeira e riqueza em biodiversidade marinha, desempenha um papel significativo no cenário marítimo global. O Brasil, em particular, com sua extensa costa de mais de 7.000 km, não só é um gigante em termos de biodiversidade marinha, mas também é uma potência econômica na região, com portos movimentados e uma indústria pesqueira robusta.

O Brasil é um dos grandes países em transporte marítimo na América Latina, com portos como Santos e Paranaguá sendo alguns dos mais movimentados do continente e não está livre de enfrentar problemas ambientais, tal como pesca predatória e incidentes de derramamentos de óleo (FAZCOMEX, 2023). Um exemplo marcante foi o derramamento que afetou vastas regiões do Nordeste em 2019 (DA FONSECA; OLIVEIRA, 2021), causando danos ecológicos e socioeconômicos significativos.

1.3.1 A Amazônia Azul: Significado e importância

O Brasil é dono de uma faixa litorânea de grande extensão, denominada Amazônia Azul, como pode ser observado na Figura 1.1, que cobre uma imensa área de 4,5 milhões de quilômetros quadrados. Esta notável área marinha, tão fundamental para o país, abriga uma diversidade biológica excepcional e é rica em recursos naturais valiosos como petróleo, gás natural e diversas espécies pesqueiras (MARINHA DO BRASIL, 2022).

A Amazônia Azul recebe esse nome por sua semelhança com a Floresta Amazônica, tanto em termos de sua vasta extensão quanto pela diversidade biológica que apresenta. A fauna e a flora marinha presentes nesta região são extraordinárias, o que a torna um patrimônio natural de imenso valor para o país e o mundo (SOARES *et al.*, 2017).

AMAZÔNIA AZUL

A Amazônia Azul inclui o Mar Territorial, a Plataforma Continental, a Zona Econômica Exclusiva e as águas interiores brasileiras

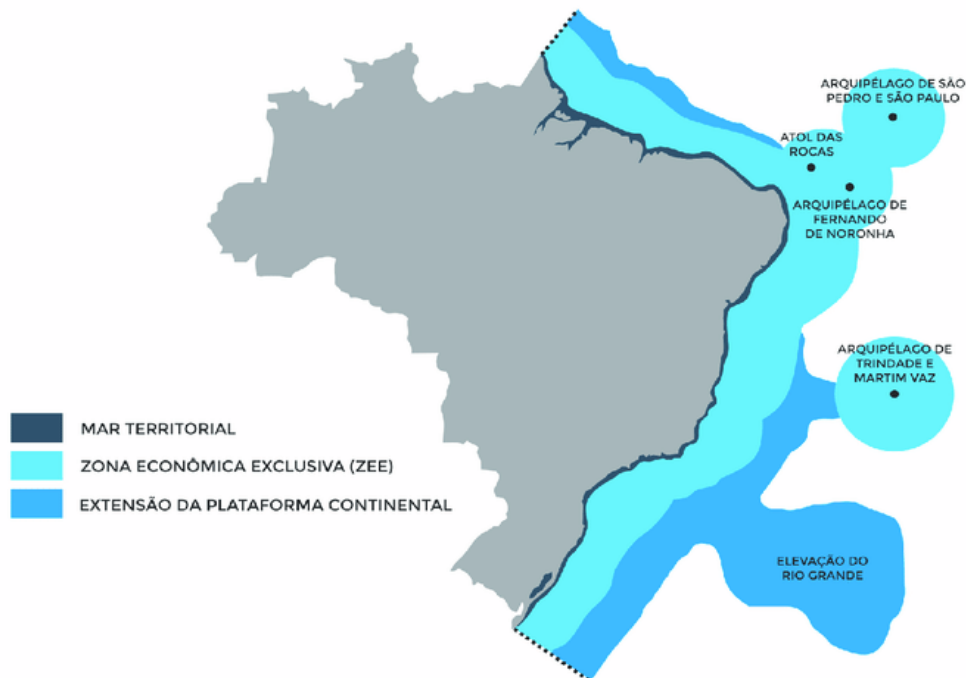


Figura 1.2 – Área oceânica que compõe a Amazônia Azul: em azul claro, as áreas sob jurisdição nacional e em azul escuro as áreas solicitadas para ampliação do limite exterior da plataforma continental, que estão sob análise na ONU (GOMES E SALDANHA-CORRÊA, 2021).

1.3.2 Relevância da Amazônia Azul para o Brasil

Na região da Amazônia Azul se encontram as importantes reservas do pré-sal, um recurso geológico com alto potencial para a produção de petróleo e gás (MARINHA DO BRASIL, 2019). Estas reservas, localizadas em camadas profundas abaixo do leito marinho, representam uma valiosa fonte de recursos energéticos para o Brasil. A exploração responsável e eficiente desses recursos tem o potencial de impulsionar a economia, criar empregos e contribuir para a segurança energética do país. Diversos portos estratégicos estão localizados ao longo desta vasta faixa litorânea, facilitando a importação e exportação de bens. Portos como Santos (o maior da América Latina), Rio de Janeiro, Paranaguá, Itajaí e Rio Grande desempenham um papel vital na economia brasileira, movimentando milhões de toneladas de cargas todos os anos.

Estes portos facilitam o comércio de commodities como soja, minério de ferro, petróleo, carne e café, que representam uma parcela significativa das exportações do Brasil (FAZCOMEX, 2023). Da mesma forma, são pontos de entrada para uma ampla gama de importações, incluindo maquinários, equipamentos eletrônicos, produtos químicos, veículos, entre outros.

A pesca é outra atividade econômica na Amazônia Azul. A diversidade marinha da região suporta uma indústria pesqueira próspera, que fornece alimento, emprego e renda para milhares de brasileiros. A pesca comercial, artesanal e esportiva é praticada ao longo da costa, e algumas espécies pescadas, como camarão, lagosta e atum, são altamente valorizadas nos mercados nacional e internacional. Estima-se que essa área marítima seja responsável por 75% da produção de gás, 85% da produção de petróleo e 45% da produção de pescado do Brasil (MARINHA DO BRASIL, 2019). Esses recursos desempenham um papel estratégico no desenvolvimento econômico e na segurança energética do país.

No entanto, a Amazônia Azul também enfrenta desafios. Ações ilegais, como pesca predatória, tráfico de drogas, contrabando e poluição marinha por descarte inadequado de resíduos ou derramamentos de óleo, são ameaças constantes à região (MARQUES, 2020). Essas atividades não apenas prejudicam a economia e o meio ambiente, mas também ameaçam a segurança marítima. Por isso, é imprescindível que haja investimentos em monitoramento, fiscalização e preservação da Amazônia Azul, equilibrando a exploração dos recursos naturais com a proteção e sustentabilidade desta região vital para o Brasil.

1.3.3 Desafios de monitoramento e proteção da Amazônia Azul

A Amazônia Azul, com sua vasta extensão e rica biodiversidade representa uma importante fronteira para o desenvolvimento socioeconômico do Brasil. No entanto, essa região também apresenta desafios significativos quando se trata de monitoramento e proteção. O primeiro desafio se refere ao tamanho da área que precisa ser monitorada. Com uma extensão de mais de 4,5 milhões de quilômetros quadrados (MARINHA DO BRASIL, 2022), a Amazônia Azul é maior que muitos países, e monitorar essa área vasta requer recursos consideráveis, tanto humanos quanto tecnológicos.

O segundo desafio é a diversidade das ameaças potenciais à Amazônia Azul. Estas incluem a pesca ilegal, a poluição por derramamentos de óleo e outros resíduos, a degradação do habitat marinho e a exploração não regulamentada de recursos minerais e energéticos. Além disso, a região é palco de atividades de tráfico, contrabando e outras formas de crime

organizado (MARQUES, 2020). A complexidade e a diversidade dessas ameaças exigem estratégias de monitoramento e proteção que possam se adaptar a uma variedade de cenários.

O terceiro desafio é o equilíbrio entre o desenvolvimento econômico e a proteção ambiental. A Amazônia Azul abriga recursos valiosos, como petróleo e gás natural, que são vitais para a economia brasileira. Ao mesmo tempo, a região é um dos principais refúgios de biodiversidade marinha do mundo e desempenha um papel fundamental na regulação do clima global (DDS ONLINE, 2023). Assim, qualquer estratégia de monitoramento e proteção deve levar em conta não apenas a necessidade de proteger esses recursos naturais, mas também a importância de promover o desenvolvimento econômico sustentável. Este é um desafio complexo que exige uma abordagem equilibrada e multifacetada.

1.3.4 Comparação com outras regiões marítimas

A Amazônia Azul, embora única em sua extensão e biodiversidade, pode ser comparada a outras regiões marítimas significativas ao redor do mundo em termos de desafios e importância estratégica. Por exemplo, o Mar da China Meridional, rico em biodiversidade e recursos naturais, é outro território marítimo que enfrenta desafios semelhantes de monitoramento, proteção e equilíbrio entre desenvolvimento e conservação (BBC NEWS, 2023).

O Mar do Norte, situado entre o Reino Unido e a Europa continental, é outro exemplo. Esta região, rica em petróleo e gás, enfrenta desafios de exploração sustentável e proteção da biodiversidade marinha. Além disso, o Mar do Norte é uma das rotas marítimas mais movimentadas do mundo, aumentando a necessidade de monitoramento eficaz e gestão de tráfego marítimo (SALIBA; FRANTZI; VAN BEUKERING, 2022).

O Mar Mediterrâneo, por sua vez, é uma região que enfrenta desafios de degradação ambiental, pesca excessiva e migração irregular. Sua posição estratégica entre a Europa, África e Ásia o torna uma região de grande importância geopolítica (SCOULLOS; FERRAGINA, 2010) assim como a Amazônia Azul.

Ao comparar a Amazônia Azul com essas regiões, fica claro que, embora cada região tenha suas peculiaridades, existem desafios comuns enfrentados em escala global. A necessidade de equilibrar desenvolvimento econômico com proteção ambiental, combater atividades ilegais e garantir a segurança marítima são questões universais.

1.4 Objetivo principal e metas específicas

As necessidades operacionais de um sistema que possa auxiliar à tomada de decisões e contribuir para uma resposta rápida no combate e mitigação de possíveis casos de derramamentos de óleo, reduzindo assim seus impactos ambientais, e contribuindo na localização de embarcações suspeitas, remetem ao objetivo principal desse trabalho:

Confecção de um algoritmo eficiente e robusto capaz de detectar autonomamente manchas de óleo e embarcações em imagens SAR por meio de rede de aprendizado profundo.

Para alcançar esse objetivo, metas específicas foram traçadas:

- Aquisição e Preparação dos conjuntos de dados (*Dataset*);
- Definição e Modificações da arquitetura de aprendizado profundo U-Net;
- Realização de Treinamentos e Validações das redes; e
- Confecção e Aplicação do algoritmo.

1.5 Organização da Dissertação

Esta dissertação é composta de capítulos subsequentes, com início pelos Conceitos Teóricos, detalhados no Capítulo 2, que propõe um entendimento sucinto dos fundamentos teóricos dos principais conceitos ao objeto de estudo. Prossegue-se, no Capítulo 3, com a exposição da Metodologia, desde a aquisição e tratamento dos conjuntos de dados e descrição dos recursos computacionais utilizados, assim como os métodos e estratégias adotados para o desenvolvimento do algoritmo de detecção. No Capítulo 4, encontram-se os Resultados e Discussões. Por fim, o Capítulo 5 finaliza com as Conclusões, sintetizando as contribuições da pesquisa e apontando para possíveis trabalhos futuros na área.

2 Conceitos Teóricos

Este capítulo visa estabelecer uma base teórica consistente, introduzindo e explorando conceitos fundamentais para a adequada contextualização e compreensão da pesquisa desenvolvida. Inicialmente, delinea-se a polarimetria e as matrizes de espalhamento, cruciais para o entendimento das interações de ondas eletromagnéticas com alvos naturais e artificiais. Em sequência, analisa-se o Sensor SAR, enfatizando características e aplicações dos Sensores Orbitais SAR, e especificamente do Sentinel-1, abordando a relevância do retroespalhamento na detecção de alvos e na mitigação de falsos positivos. Posteriormente, a discussão adentra o domínio das Redes Neurais Convolucionais (CNNs), com uma abordagem sobre as aplicações em algoritmos de detecção, bem como a escolha da arquitetura U-Net, que utiliza da técnica de segmentação semântica. O capítulo culmina abordando os indicadores empregados para avaliação, essenciais para a validação e interpretação dos resultados obtidos ao longo do estudo.

2.1 Polarimetria e matrizes de espalhamento

A polarimetria SAR é uma área da ciência que se baseia na elipsometria e se dedica ao estudo da aquisição, processamento e análise do estado de polarização de um campo eletromagnético na faixa de comprimento das micro-ondas (BOERNER, 2007). Por meio da polarimetria, é possível desdobrar os mecanismos de espalhamento que são sensíveis à forma, orientação e propriedades dielétricas dos alvos presentes em uma cena imageada (MOREIRA *et al.*, 2013), sendo um aspecto fundamental do sensoriamento remoto por radar, proporcionando uma riqueza de informações sobre as propriedades e a estrutura da superfície da Terra, e envolve a análise da polarização do sinal do radar, que pode variar dependendo do tipo de superfície que reflete o sinal (ISLAM; RICO-RAMIREZ, 2014).

A onda eletromagnética emitida por um sistema SAR pode ser representada pelo vetor do campo elétrico $E(R,t)$, onde R denota a posição e t o tempo. Esse vetor pode ser modelado pela equação da onda plana:

$$E(R, t) = E_0 e^{j(\omega t - \beta R + \phi)} = E_0 e^{j(\phi)} e^{j(\omega t - \beta R)} \quad (2.1)$$

em que E_0 é a amplitude, ω é a frequência angular ($2\pi f$ ou $2\pi c/\lambda$), β é a constante de fase ou número de onda ($\beta = 2\pi/\lambda$) e ϕ é a fase (RICHARDS, 2009).

Na polarimetria SAR, a descrição do estado de polarização da onda é realizada por meio de três parâmetros principais: amplitude, fase e polarização.

A polarização é determinada pela direção do campo elétrico em relação ao plano de propagação da onda. Normalmente, descreve-se a polarização pela forma que o vetor do campo elétrico traça no plano perpendicular ao eixo de propagação. Nesse contexto, utiliza-se a convenção de designar a direção horizontal (H) para o plano paralelo ao solo e a direção vertical (V) para o plano perpendicular ao solo.

No imageamento SAR, a polarização é estabelecida pela configuração da antena do radar e pode diferir entre a transmissão (Tx) e a recepção (Rx). O sistema linear ortogonal é comumente utilizado, resultando nas possíveis combinações de polarização: HH (transmissão horizontal, recepção horizontal), HV (transmissão horizontal, recepção vertical), VH (transmissão vertical, recepção horizontal) e VV (transmissão vertical, recepção vertical). A primeira letra na notação indica a polarização de transmissão, enquanto a segunda letra indica a polarização de recepção. Quando a polarização é idêntica para a transmissão e a recepção, obtém-se uma imagem co-polarizada (*co-polarized, like-polarized, copol*). Por outro lado, quando as polarizações de transmissão e recepção são diferentes, temos uma imagem *cross* polarizada (*cross-polarized, cross-pol*).

Essas configurações de polarização têm impacto na interação da onda eletromagnética com os alvos, permitindo separar mecanismos de espalhamento sensíveis à forma, orientação e propriedades dielétricas dos objetos presentes na cena imageada. (BOERNER, 2007).

Os sistemas podem ser classificados de acordo com a polarização utilizada na emissão e recepção da onda eletromagnética. A evolução dos satélites SAR levou ao desenvolvimento de diferentes modos de operação polarimétrica. Os primeiros satélites SAR eram do tipo *single pol*, onde a transmissão e a recepção eram realizadas em uma única polarização, sendo comum utilizar a polarização horizontal (HH) ou vertical (VV). Atualmente, os satélites SAR também possuem modos de operação *dual pol* coerente, nos quais a transmissão ocorre em uma polarização do eixo ortogonal e a recepção é feita em ambas as direções ortogonais. Isso resulta em combinações de polarizações como HH e HV, ou VV e VH.

Outro modo de operação é o *dual pol* incoerente, onde a transmissão e recepção ocorrem nos canais copolares, como HH e VV. Nesse caso, não há coerência de fase entre os sinais transmitidos e recebidos.

Por fim, existe o modo *full pol* ou *quad pol*, em que a transmissão e a recepção são realizadas em ambas as polarizações ortogonais (HH, HV, VV e VH). Essa configuração permite gravar os dados na matriz de Sinclair, também conhecida como matriz de espalhamento, que fornece informações detalhadas sobre a polarização e permite uma análise mais completa das propriedades dos alvos:

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (2.2)$$

Esses diferentes modos de operação polarimétrica nos sistemas SAR oferecem uma variedade de opções para coletar dados polarimétricos e possibilitam a extração de informações valiosas sobre a estrutura e as propriedades dos objetos presentes na cena imageada.

A matriz de espalhamento é um conceito fundamental que permite caracterizar completamente o comportamento de espalhamento de um alvo. É uma matriz 2x2 complexa que descreve o relacionamento entre os campos elétricos transmitidos e recebidos na presença de um alvo, e seu uso permite a obtenção de dados mais detalhados e precisos, em comparação com os radares de polarização simples (FREEMAN, DURDEN, 1993). As matrizes são utilizadas em várias aplicações de sensoriamento remoto por radar, incluindo o mapeamento da cobertura do solo, detecção e classificação de alvos. Além disso, sua análise também pode ser útil para identificar e entender os mecanismos de espalhamento predominantes em diferentes tipos de superfície (POTTIER *et al.*, 2009).

A polarimetria e as matrizes de espalhamento são ferramentas essenciais na análise de dados de sensoriamento remoto por radar, permitindo uma melhor compreensão das propriedades físicas da superfície da Terra. Com a crescente disponibilidade de dados de radar polarimétrico, tais como os fornecidos pelas missões Sentinel-1 da Agência Espacial Europeia (ESA) e ALOS PALSAR da Agência de Exploração Aeroespacial do Japão (JAXA), o uso destas ferramentas estão destinados a crescer ainda mais no futuro (YAMAGUCHI *et al.*, 2011).

2.2 Sensor SAR

O radar SAR é um sensor amplamente utilizado na detecção e medição de objetos de interesse, operando na faixa de micro-ondas do espectro eletromagnético. Esse sensor baseia-

se no princípio do retroespalhamento, onde o parte da energia do pulso emitido pela antena é refletido pelo objeto e captado novamente (*backscatter*), possibilitando a medição da distância entre eles.

Entre os sensores orbitais SAR existentes, destacam-se os seguintes listados na Tabela 2.1:

Tabela 2.1 – Principais sensores orbitais SAR.

Sensor	Banda (Frequência) de Trabalho
TerraSAR-X e COSMO-SkyMed	Banda X
Sentinel-1 e RADARSAT	Banda C
ALOS PALSAR e UAVSAR	Banda L
RADARSAT-2	Banda Ku

O satélite Sentinel-1, parte integral do programa Copernicus da ESA, ilustrado na Figura 2.1, serve como um exemplo prático do uso dessa tecnologia. Equipado com uma antena SAR planar, o Sentinel-1 opera na banda C do espectro de micro-ondas, uma escolha que favorece a penetração através das nuvens e a capacidade de capturar imagens sob diversas condições meteorológicas, inclusive durante a noite.

Além disso, o Sentinel-1 se destaca por sua capacidade de aquisição de imagens com diferentes modos de polarização, como VH e VV, o que amplia significativamente a gama de aplicações. Este satélite também possui uma configuração de antena que permite o mapeamento de grandes áreas com alta resolução, uma característica para monitoramento ambiental, avaliação de desastres naturais e observação de mudanças em ambientes terrestres e marítimos. A flexibilidade do Sentinel-1 em termos de modos de aquisição (como *stripmap*, interferometria e varredura ampla) e sua habilidade de operar tanto em modos de resolução mais fina quanto de cobertura ampla, tornam-no uma ferramenta extremamente versátil de observação de mudanças na superfície terrestre e marítima.



Figura 2.1 – Ilustração do satélite com sensor SAR Sentinel-1. Imagem extraída de (EUROPEAN SPACE AGENCY, 2023).

O tempo entre a transmissão e a recepção é mensurado para se calcular essa distância (R), denominada como *slant range* (JACKSON; APEL, 2004; MOREIRA *et al.*, 2013; TOMIYASU, 1978).

A resolução espacial em *range* (δr), que é a distância mínima na qual é possível distinguir dois objetos, está diretamente relacionada à duração do pulso (τ). Em fórmula, podemos expressar essa relação da seguinte maneira:

$$\delta_r = \frac{c\tau}{2} \quad (2.3)$$

onde c é a velocidade da luz e o fator 2 é utilizado, pois a onda percorre a distância mínima tanto no caminho de ida (transmissão) quanto no caminho de volta (recepção) (JACKSON; APEL, 2004; RICHARDS, 2009).

O Radar SAR é um sistema de radar que utiliza uma técnica de imageamento onde pulsos são emitidos na direção perpendicular ao deslocamento da plataforma (azimute), e os dados de amplitude e fase desses pulsos são armazenados. O efeito *Doppler* é aproveitado para processar esses dados e gerar uma antena sintética virtual, que é proporcional à velocidade de deslocamento da plataforma (V) e ao tempo de abertura da antena, também conhecido como largura de banda. A resolução espacial em azimute (δa) representa a distância mínima necessária para obter a distinção angular entre dois espalhadores.

Em fórmula, a relação é expressa como:

$$\delta_a = \frac{L}{2} \quad (2.4)$$

onde L representa o tamanho da antena física.

A geometria básica de aquisição de um sistema SAR é ilustrada na Figura 2.2:




Figura 2.2 – Geometria básica de aquisição de um sistema SAR.

Adaptado de (OUCHI, 2013).

É possível observar a abertura sintética da antena, que é obtida pelo processamento do sinal de vários pulsos correspondentes a uma única posição. O deslocamento da plataforma com velocidade V na direção x (azimute) é representado. O tempo de abertura sintética é denotado como T .

Na Figura 2.2, é evidenciado que o pulso é modulado em *chirp*, o qual possui uma duração τ e se propaga na velocidade da luz (c), desconsiderando os efeitos do meio atmosférico. A propagação ocorre na direção *slant range*, a qual é perpendicular ao movimento da plataforma e oblíqua em relação ao solo. Essa geometria de aquisição permite capturar informações detalhadas sobre a superfície terrestre, possibilitando a formação de imagens SAR com alta resolução espacial e a identificação de diversas características e alvos.

O ângulo de incidência θ_i (*incident angle*), é definido como o ângulo formado entre o plano *slant-range* (plano de propagação do pulso) e a normal à superfície imageada. No caso em que a topografia local é considerada em vez da curvatura da Terra, utiliza-se o ângulo de incidência local θ_{i_local} . É importante destacar que o ângulo de incidência varia de acordo com a distância da plataforma em relação ao alvo. Especificamente, à medida que a distância aumenta do *near range* (faixa próxima) para o *far range* (faixa distante), o ângulo de

incidência também aumenta. Isso ocorre devido à geometria de aquisição do SAR, em que a plataforma está se afastando do alvo à medida que se desloca ao longo da trajetória de imageamento. Conseqüentemente, o ângulo de incidência aumenta progressivamente. Esse efeito do ângulo de incidência variável ao longo da faixa de imageamento é importante para a interpretação e correção das imagens SAR, pois pode afetar a intensidade do sinal refletido e a aparência dos alvos na imagem final (JACKSON; APEL, 2004; RICHARDS, 2009). Portanto, é necessário considerar essa variação angular ao realizar análises e interpretações precisas das imagens SAR.

O *near range* é o ponto da superfície imageada que está mais próximo da plataforma de aquisição, sendo representado pela coordenada (0,0) na Figura 2.2. Em contraste, o *far range* é o ponto mais distante da plataforma na superfície imageada. A faixa de imageamento, conhecida como *swath*, é delimitada em largura pela distância entre o *near range* e o *far range*. As limitações técnicas do sensor, em particular a Frequência de Repetição de Pulsos (FRP) associada ao modo de imageamento, afetam diretamente o tamanho do *swath* (MOREIRA *et al.*, 2013). Em sistemas monoestáticos, nos quais a antena transmissora é a mesma que a receptora, o *far range* é limitado pela FRP. Esse fato implica que imagens polarimétricas completas (*full* polarimétricas) abrangem faixas de imageamento menores do que imagens com apenas uma ou duas polarizações (*single* ou *dual pol*). Portanto, a capacidade de cobertura da superfície imageada pelo radar SAR é diretamente influenciada pelas especificações técnicas do sensor, como a FRP o modo de imageamento ou até a capacidade de armazenamento de dados (memória RAM), e isso afeta o tamanho do *swath* e a disponibilidade das informações polarimétricas (JACKSON; APEL, 2004; MOREIRA *et al.*, 2013)

Ground-range é a distância de um objeto medida na direção perpendicular à trajetória da plataforma de aquisição (direção *y* na Figura 2.2). Em outras palavras, é a projeção da distância *slant range* no solo. Enquanto a distância *slant range* representa a distância ao longo da direção oblíqua entre a plataforma e o objeto, a distância *ground-range* fornece a medida da distância no solo, considerando a componente perpendicular ao movimento da plataforma. Essa projeção é realizada levando em conta o ângulo de incidência e a topografia local.

A utilização do *ground-range* é importante para análises e interpretações da imagem SAR, pois facilita a interpretação dos dados de distâncias e localizações dos objetos em relação à superfície terrestre. É uma medida essencial para aplicações geoespaciais, como mapeamento, análise de terreno e monitoramento ambiental. (EUROPEAN SPACE AGENCY, 2023).

O produto do radar imageador é a imagem SAR, que é representada por uma matriz bidimensional. Essa matriz correlaciona a distância em *range* nas colunas e a progressão do sensor em azimute nas linhas. Cada célula da matriz contém um valor complexo que é resultado do processamento do sinal bruto. O valor complexo de cada célula da imagem SAR é composto pela amplitude (valor absoluto) e pela fase (ângulo) correspondentes. Essa representação complexa fornece informações detalhadas sobre a resposta do alvo, incluindo sua intensidade e posição espacial.

Assim, a imagem SAR é uma representação visual da cena imageada, onde cada *pixel* contém informações sobre a amplitude e a fase resultantes do processamento do sinal de retorno do radar. Essa imagem é utilizada para análises e interpretações, permitindo a identificação de alvos, a caracterização de superfícies e o mapeamento de diferentes características da área imageada.

A imagem SAR, quando utiliza toda a largura de banda disponível no processamento, é denominada imagem SLC (*Single Look Complex*). A banda, seja em azimute, *range* ou em ambas as direções, pode ser dividida em n partes (n *looks*) para realizar a compressão dos pulsos, resultando em sub-imagens que são combinadas para formar a imagem final. Esse processo é conhecido como imagem *Multi-Look* (YANG *et al.*, 2018).

O objetivo principal dessa abordagem é reduzir o efeito de interferência conhecido como *speckle*, que é um ruído granular presente nas imagens SAR decorrente das interferências construtivas e destrutivas das ondas refletidas. No entanto, a utilização do *Multi-Look* para reduzir o *Speckle* acarreta uma diminuição na resolução espacial da imagem.

Os dados da imagem SLC são geralmente gravados no formato complexo Z , onde I_n representa a parte real (*in phase*) e Q representa a parte complexa (*quadrature*). Essa representação complexa permite armazenar as informações de amplitude e fase do sinal de retorno do radar, possibilitando a realização de análises e processamentos adicionais.

$$Z = I_n + Qi \quad (2.5)$$

A amplitude A do sinal é dada pelo módulo de Z , ou seja:

$$A = \sqrt{I_n^2 + Q^2} \quad (2.6)$$

A potência ou intensidade I é o quadrado da amplitude:

$$I = A^2 = In^2 + Q^2 \quad (2.7)$$

A fase do sinal ϕ é dada por:

$$\phi = \arctg \left(\frac{Q}{In} \right) \quad (2.8)$$

Portanto, a escolha entre a imagem SLC e a imagem *Multi-Look* envolve um compromisso entre a redução do efeito *Speckle* e a resolução espacial desejada, dependendo das necessidades e aplicações específicas de cada imagem SAR.

A imagem SLC pode passar por processos adicionais de calibração e geocodificação, que visam melhorar a qualidade e a precisão da relação *pixel* com a posição geográfica real. Esses processos ajudam a corrigir distorções geométricas e radiométricas, permitindo uma interpretação mais precisa dos dados.

Dentre os principais elementos que influenciam a formação da imagem SAR, estão o próprio sensor, a geometria de aquisição e o alvo. Esses elementos têm um impacto direto na performance de algoritmos de Reconhecimento Automático de Alvos (ATR) (XUE, SINK e POWER (2003).

Do sensor, é importante destacar as resoluções em azimute (δa) e em *ground* (δg), que é a resolução em range projetada no solo. Quanto menor for a área de uma célula de resolução, mais detalhada será a imagem resultante, permitindo a extração de contornos e medidas mais precisas dos alvos. Isso possibilita o levantamento de diversos atributos que podem ser úteis para a classificação dos alvos (LIN; SONG; YANG, 2018). No entanto, é importante considerar que o *pixel spacing* de uma imagem SAR nem sempre corresponde à célula de resolução do sensor. O *pixel spacing* refere-se ao tamanho da área do terreno representada por um pixel na imagem. Portanto, se for maior do que a resolução espacial do sensor, haverá uma perda na resolução espacial permitida pelo sensor (MOREIRA *et al.*, 2013).

O comprimento de onda eletromagnética (λ) é outra característica essencial do sensor SAR, pois está diretamente relacionado à capacidade de penetração nos alvos (DE MORAES, 2002). Quanto maior o comprimento de onda, maior é a capacidade de penetração da onda eletromagnética. Além disso, ondas de comprimento maior sofrem menos absorção pela atmosfera. Os radares SAR operam em uma faixa de comprimento de onda entre 1 mm e 1 m, que é subdividida em diferentes bandas (VHF, P, L, S, C, X, Ka, K e Ku) para facilitar o

estudo e a aplicação dos sistemas. Os sensores SAR orbitais geralmente utilizam as bandas L, S, C e X, enquanto os radares aero embarcados podem fazer uso das bandas VHF, P, Ka e Ku (FALQUETO, 2019).

Em relação à geometria de aquisição, o ângulo de incidência é a principal característica, variando com a distância em range, e tem um efeito direto na forma como a onda incidente é refletida pelos alvos, levando em consideração as Leis de Snell (LORENZZETTI, 2015; MARINO; VELOTTO; NUNZIATA, 2017). As alterações causadas pelo ângulo de incidência podem interferir na capacidade de reconhecimento dos algoritmos, visto que um mesmo alvo pode apresentar uma resposta diferente dependendo de sua posição em relação à plataforma. Exemplificando, numa topografia plana, a resposta relativa à estrutura vertical de alvos mais próximos da plataforma (*near range*) será de menor intensidade do que a de alvos mais distantes, mesmo que tenham a mesma altura.

A seção transversal de radar (RCS) ou sigma (σ) é uma característica a ser considerada quando se trata de alvos. Existem três principais fatores que têm influência direta sobre a RCS.

O primeiro fator é a rugosidade. A rugosidade é medida levando em consideração o relevo da área, o comprimento de onda e o ângulo de incidência. Em uma escala micro, a rugosidade afeta a tonalidade da célula de resolução, enquanto em uma escala macro, ela influencia a textura da imagem resultante. De maneira geral, quanto maior for a rugosidade da área, maior será o valor de σ .

O segundo fator é a permissividade elétrica. Essa constante física descreve como um campo elétrico interage com um meio e afeta diretamente a reflexão da onda eletromagnética que incide no alvo. A permissividade elétrica é um elemento importante na determinação da RCS, pois influencia a forma como o alvo reflete a energia eletromagnética.

O terceiro fator é a geometria. Tanto a forma do alvo em si quanto a sua disposição no terreno, também conhecido como ângulo de aspecto, têm um impacto significativo na dispersão da onda eletromagnética. A geometria do alvo determina a maneira como a onda se espalha e interage com o objeto, resultando em diferentes valores de RCS.

Esses três aspectos são fundamentais para compreender e calcular a RCS de um determinado alvo (DYBDAL, 1987).

A potência (intensidade) recebida, que é proporcional à RCS dos objetos imageados, é discretizada de acordo com a resolução radiométrica do sensor, ou seja, a quantidade de *bits* (níveis de cinza), e é registrada em um nível digital (ND). Após o processamento da imagem por meio de algoritmos de calibração radiométrica, normalmente é obtida a imagem em

sigma-zero (σ_0), que representa a RCS por unidade de área do terreno imageado e é expressa em decibéis (dB). Esse processo permite a comparação de imagens obtidas por diferentes sensores, em regiões distintas e em momentos diferentes (SCHMIDT *et al.*, 2020).

É importante ressaltar que uma célula de resolução SAR ou um *pixel* é composto por diversos espalhadores determinísticos distribuídos aleatoriamente, tornando o processo de interação da onda estocástico (FALQUETO, 2019). Como o sistema SAR é coerente, ocorre interferência construtiva e destrutiva causada pela reflexão dos diferentes espalhadores elementares da célula de resolução, resultando em uma forte variação nos valores de *backscattering* entre pixels vizinhos. Esse efeito particular das imagens SAR é conhecido como *speckle* (DUTRA *et al.*, 2003).

O *speckle* pode dificultar o processo de segmentação em algoritmos que se concentram na detecção de bordas. No caso do reconhecimento de alvos, esse efeito pode interferir no desempenho, dependendo de como os atributos são extraídos da imagem.

A Figura 2.3 ilustra explicitamente os impactos provocados pelo *speckle* em imagens. Observa-se, na imagem à esquerda, que o efeito *speckle* causa ruídos que se manifestam visualmente em padrões preto e branco, originando um efeito conhecido como *salt and pepper* (sal e pimenta). Esse fenômeno degrada a qualidade da imagem e pode obstaculizar o treinamento eficiente de algoritmos de detecção de alvos. Contrariamente, a imagem à direita, submetida a um processamento mediante filtro *speckle*, exibe uma superfície mais suave. Tal tratamento aprimora a distinção entre os tons de fundo e os alvos, salientando particularmente as bordas e, conseqüentemente, possibilitando uma análise visual e computacional mais clara e menos suscetível a erros atribuíveis ao ruído *speckle*.




Figura 2.3 – Imagem SAR com mancha de óleo (região mais escura ao centro das imagens) demonstrando o efeito degradante do *speckle*: (a) imagem SAR original, (b) imagem SAR com filtro *speckle*.

Portanto, a análise e a interpretação das imagens SAR levam em consideração uma série de características relacionadas ao sensor, à geometria de aquisição e aos alvos. Essas características influenciam diretamente o desempenho dos algoritmos e devem ser cuidadosamente consideradas ao realizar análises e extração de informações das imagens SAR.

2.2.1 Sensores orbitais SAR - Sentinel-1

A missão Sentinel-1 é uma iniciativa da Agência Espacial Europeia que foi lançada com o objetivo de fornecer dados de radar de abertura sintética contínuos e confiáveis para uma série de aplicações, incluindo monitoramento ambiental, manejo de recursos e ajuda humanitária, sendo composta por uma constelação de dois satélites, Sentinel-1A e Sentinel-1B, que foram lançados respectivamente em 2014 e 2016 e devido a problemas operacionais em 2021 no Sentinel-1B, atualmente apenas o Sentinel-1A continua em funcionamento. Estes satélites operam em uma órbita polar, proporcionando cobertura global e capacidade de revisita frequente, que é especialmente importante para o monitoramento de fenômenos dinâmicos, como o deslocamento do terreno e o estado dos oceanos (TORRES *et al.*, 2012).

Os satélites Sentinel-1 carregam um radar de abertura sintética em banda C, que é particularmente útil para aplicações de observação da Terra devido à sua capacidade de penetrar nuvens e fornecer imagens dia e noite. Além disso, é relativamente imune à interferência da atmosfera, permitindo a coleta de dados precisos sob uma ampla gama de condições climáticas (GEUDTNER *et al.*, 2021).

Os instrumentos Sentinel-1 suportam diferentes modos de operação, oferecendo flexibilidade em termos de polarização e produtos gerados. A polarização pode ser simples, com opções de HH (*Horizontal Transmit, Horizontal Receive*) ou VV (*Vertical Transmit, Vertical Receive*), ou polarização dupla, com opções de HH+HV ou VV+VH. Essa funcionalidade é alcançada através de uma cadeia de transmissão comutável para H ou V e duas cadeias de recepção paralelas para a polarização H e V.

Os produtos derivados desses modos são categorizados como SM (*Stripmap*), IW (*Interferometric Wide Swath*), EW (*Extra Wide*), e WV (*Wave*). O modo SM é adequado para aquisição de dados em pequenas partes e, sob demanda, para eventos extraordinários que exigem gerenciamento de emergência. O modo IW oferece uma ampla faixa interferométrica e suporta polarização dupla VV+VH em áreas terrestres. O modo EW é principalmente utilizado para monitoramento costeiro de áreas extensas, incluindo derramamentos de óleo e

monitoramento de gelo marinho. O modo WV é restrito a polarização simples, oferecendo apenas a opção HH ou VV, sendo ideal para aquisição de dados em oceano aberto. Os modos são alternados e operam sob demanda da ESA.

A escolha do modo operacional principal, o modo IW, atende aos requisitos de serviço mais recentes, evita conflitos de polarização e preserva o desempenho de revisita. Além disso, essa escolha simplifica o planejamento da missão, reduzindo custos operacionais e permitindo a criação de um arquivo de dados consistente em longo prazo.

Para cada um dos modos mencionados, é possível gerar produtos em diferentes níveis de processamento, incluindo SAR Nível-0, Nível-1 SLC (*Single Look Complex*), Nível-1 GRD (*Ground Range Detected*) e Nível-2 OCN (*Ocean*). Esses diferentes níveis de processamento oferecem diversas opções de análise e aplicação dos dados SAR, de acordo com as necessidades específicas de cada estudo. Na Figura 2.4 pode-se verificar uma exemplificação de funcionamento dos modos com suas características.




Figura 2.4 – Modos dos produtos dos satélites Sentinel 1 (EUROPEAN SPACE AGENCY, 2023).

A missão tem produzido um grande volume de dados desde o seu lançamento, contribuindo significativamente para a compreensão do nosso planeta. Esses dados têm sido utilizados em uma variedade de aplicações, incluindo o monitoramento da cobertura do solo, a observação das mudanças no uso da terra, a detecção de derramamentos de petróleo e o monitoramento da atividade sísmica, entre outras (DAVIDSON *et al.*, 2009; PHIRI *et al.*, 2020). Representa um marco importante no campo da observação da Terra por satélite, demonstrando o potencial do sensoriamento remoto Radar para fornecer *insights* valiosos sobre o nosso planeta e seus processos dinâmicos.

2.2.2 Sensoriamento Remoto por imagens de Radar

O sensoriamento remoto através de imagens de radar se manifesta como uma ferramenta insubstituível e intrínseca no entendimento e interpretação da superfície terrestre, oferecendo uma matriz robusta e confiável de dados, mesmo sob condições atmosféricas desafiadoras, segundo Lillesand, Kiefer e Chipman (2014). Esta capacidade singular é atribuída à operacionalidade dos sistemas de radar na região do espectro eletromagnético denominada micro-ondas, notoriamente capazes de penetrar nuvens e fornecer dados ininterruptamente, independentemente do ciclo diurno ou das condições climáticas, conforme ilustrado na Figura 2.5.




Figura 2.5 – Comparação entre a imagem ótica (a) e SAR (b) de uma mesma região, obtidas em horários próximos, demonstra a independência das imagens SAR em relação às condições climáticas.

A aplicabilidade dos produtos derivados do sensoriamento remoto por radar permeia diversas disciplinas e contextos, proporcionando *insights* inovadores e críticos em cada aplicação. Em geologia, os dados obtidos são imperativos para o mapeamento detalhado de características estruturais geológicas, como falhas e dobras, fornecendo uma visão intrínseca da dinâmica terrestre e de processos tectônicos (AHMADI; PEKKAN, 2021).

Atravessando os domínios da hidrologia, o sensoriamento por radar se torna um recurso fundamental para o mapeamento e monitoramento de áreas úmidas, ao passo que também oferece uma visão dinâmica do movimento superficial da água, essencial para a compreensão das tendências hidrológicas e para a gestão de recursos hídricos (JENSEN *et al.*, 2018).

No cenário crítico de gestão de desastres, os dados derivados do sensoriamento remoto por radar não apenas desempenham um papel fundamental no mapeamento de inundações, mas também se revelam ferramentas críticas para a detecção de derramamentos de óleo (CONCEIÇÃO *et al.*, 2021; FINGAS, BROWN, 2017; KRESTENITIS *et al.*, 2019) e de embarcações (CHEN, LI, 2019; LI *et al.*, 2022; MAO *et al.*, 2020). Neste contexto, o radar facilita a implementação de medidas de mitigação, permitindo uma resposta mais rápida e informada durante eventos críticos.

Já no monitoramento ambiental, onde a atenção é frequentemente voltada para fenômenos como desmatamento e alterações na cobertura do solo, o radar serve como um observador contínuo, provendo dados que são cruciais para a construção de estratégias de conservação e para o entendimento da interação entre atividades humanas e ecossistemas naturais (KASISCHKE, MELACK, DOBSON, 2007).

Portanto, o sensoriamento remoto por imagens de radar, ao agregar profundidade e uma perspectiva dinâmica à coleta de dados, emerge como um pilar no avanço do conhecimento e nas estratégias práticas em diversos campos da ciência e da gestão ambiental. Seu papel é não apenas fundamental, mas também continuamente evolutivo, adaptando-se e alinhando-se com tecnologias emergentes e requisitos analíticos progressivamente refinados.

2.2.3 Retroespalhamento dos alvos, do *Background* e dos Falsos positivos

O retroespalhamento (*backscattering*) é um conceito relevante no sensoriamento remoto por radar de abertura sintética. É o processo pelo qual o sinal de radar é refletido de volta para o sensor após atingir a superfície da Terra (ULABY; MOORE; FUNG, 1986).

Os padrões de retroespalhamento podem variar significativamente dependendo das propriedades da superfície que reflete o sinal. Por exemplo, superfícies planas e lisas, como corpos d'água, tendem a refletir o sinal de radar para longe do sensor, resultando em um sinal mais fraco. Por outro lado, superfícies ásperas ou com características complexas, como florestas ou áreas urbanas, podem resultar em um sinal de mais forte (RICHARDS, 2009).

Além disso, a análise de retroespalhamento também é crítica na interpretação e classificação de imagens SAR. Diferentes tipos de alvos podem apresentar diferentes padrões de retroespalhamento, e a compreensão desses padrões pode ajudar a identificar e classificar os alvos nas imagens SAR (LEE; POTTIER, 2017). O sinal também é influenciado pela polarização do sinal de radar. Os radares polarimétricos, que transmitem e recebem sinais em várias polarizações, podem fornecer informações mais detalhadas sobre o retroespalhamento e ajudar a melhorar a interpretação e a classificação das imagens SAR (CLOUDE; POTTIER, 1996).

Os efeitos do retroespalhamento são elementos cruciais a serem considerados na detecção de manchas de óleo, embarcações, background (oceano) e falsos positivos. Cada um desses elementos possui características de espalhamento distintas que influenciam a formação da imagem SAR. Abaixo estão detalhados os efeitos do retroespalhamento de cada tipo de alvo, do background e dos falsos positivos:

1. **Manchas de óleo (alvos):** As manchas de óleo têm propriedades únicas de retroespalhamento relacionadas à sua composição química e física, predominando a reflexão especular, onde o sinal emitido não retorna para o sensor. Essas propriedades resultam em um sinal de radar que difere do espalhamento da superfície do oceano, com manchas de óleo produzindo espalhamento mais suave ou menos estruturado em comparação com o fundo marinho (DEL FRATE *et al.*, 2000). A presença de óleo na superfície do mar pode alterar as propriedades de espalhamento, resultando em um sinal de radar com características distintas em relação a outras áreas do oceano (BELLOUL; THORPE, 1992).

2. **Embarcações (alvos):** As embarcações, geralmente compostas por materiais metálicos, também possuem características de retroespalhamento específicas. Devido às suas formas e composição, as embarcações podem gerar um espalhamento de radar que difere tanto do background do oceano quanto das manchas de óleo. O retroespalhamento de radar de um navio é influenciado por vários fatores, incluindo reflexão única de superfícies metálicas, reflexão dupla de interações mar-navio e múltiplas interações (volumétricas) entre a onda eletromagnética e estruturas mar-navio. Essa combinação única de mecanismos de espalhamento afeta tanto as partes polarizadas quanto as não polarizadas da onda espalhada,

criando um padrão de espalhamento estruturado com reflexões fortes e uma assinatura distintiva de reflexão única e dupla dos sinais (ADIL *et al.*, 2022).

3. **Oceano (*Background*):** O *background*, que representa o oceano em si, exibe um comportamento de retroespalhamento predominante. Normalmente, o espalhamento do *background* marítimo é governado pelo mecanismo de reflexão única e especular. Isso resulta em uma resposta de radar mais uniforme e menos estruturada em comparação aos alvos de interesse, como manchas de óleo e embarcações. A compreensão das características do espalhamento do *background* é importante para distinguir alvos de interesse do ambiente circundante.

O comportamento especular do oceano como *background* é particularmente sensível ao estado do mar. Ventos com velocidades abaixo de 1,5 m/s (3kt) não provocam alterações significativas, mas ventos entre 1,5 m/s (3kt) e 10 m/s (20kt), comuns em regiões marítimas, resultam no espalhamento superficial conhecido como efeito *Bragg*. Esse efeito, altamente coerente, reforça o sinal de retorno devido à presença de ondas capilares e pequenas ondas uniformemente espaçadas em range. No processamento de imagens SAR, esse efeito pode ser considerado *clutter* (JACKSON, APEL, 2004; PAES, 2009), e alvos de interesse, como manchas de óleo, podem atenuar esse efeito, facilitando a sua identificação. O retroespalhamento superficial relacionado ao efeito de *Bragg* é influenciado pelo ângulo de incidência e comprimento de onda, sendo mais pronunciado para polarizações VV em comparação com HH ou HV.

4. **Falsos positivos (*confusers*):** Falsos positivos ou falsos alarmes são elementos que podem ser erroneamente identificados como alvos de interesse. Eles são um problema comum em sistemas de detecção de alvos e podem surgir devido a vários fatores, como interferência eletromagnética, condições ambientais ou objetos com propriedades de dispersão semelhantes aos alvos desejados (ISHII; SAYAMA; MIZUTANI, 2011). Os falsos positivos podem apresentar uma resposta de retroespalhamento que se assemelha aos alvos de interesse, tornando sua distinção um desafio.

Discriminar falsos positivos de alvos reais é uma tarefa desafiadora, pois eles podem apresentar uma resposta de retroespalhamento que se assemelha aos alvos de interesse. Para minimizar a ocorrência de falsos alarmes, é fundamental analisar e entender cuidadosamente as características desses elementos (GEMME; DELLEPIANE; VERNAZZA, 2015; XIAO; DONG; GONG, 2023).

Na detecção das manchas de óleo, os falsos positivos são gerados por diversos fatores adicionais. Áreas próximas do continente, que estão abrigadas do vento e possuem

características diferentes de mar aberto, podem gerar reflexões que podem ser confundidas com manchas de óleo. Além disso, cardumes de peixes e agregações de organismos planctônicos na superfície do oceano também podem criar reflexões que se assemelham a manchas de óleo. Outros elementos, como detritos flutuantes, algas ou detritos vegetais, podem igualmente resultar em falsas detecções.

Na detecção de embarcações em imagens SAR, também é necessário lidar com os falsos positivos. Podem ocorrer devido a vários fatores, como a presença de estruturas costeiras, como portos, docas e píeres, que podem gerar reflexões de radar semelhantes às embarcações. Além disso, objetos flutuantes, como detritos marinhos ou vegetação flutuante, podem ser confundidos com embarcações. Outras fontes de falsas detecções incluem ilhas artificiais, plataformas de petróleo, boias de sinalização.

A distinção entre grandes embarcações e plataformas de petróleo apresenta desafios significativos para os algoritmos de detecção de alvos. Ambos os tipos de alvos possuem semelhanças em seus padrões de retroespalhamento, tornando a tarefa de distingui-los bastante complexa. A principal diferença está na presença de espalhamento volumétrico mais proeminente em plataformas de petróleo, enquanto as embarcações apresentam uma proporção maior de reflexões do tipo *double bounce*, devido à estrutura do casco e à superestrutura elevada e complexa. Este trabalho limita-se a exploração de alvos do tipo embarcações e manchas de óleo, estando as plataformas marítimas incluídas dentro dos alvos do tipo embarcações, podendo serem rapidamente omitidas com a inclusão das coordenadas delas no algoritmo, pois em maioria, essas plataformas possuem posição fixa. A compreensão dessas diferenças de retroespalhamento entre embarcações e plataformas de petróleo é fundamental para o desenvolvimento de algoritmos mais eficientes e precisos.

O desenvolvimento de algoritmos de detecção precisa levar em consideração a análise cuidadosa desses elementos para minimizar a ocorrência de falsos alarmes (QUAN; CHOI; CHO, 2020).

A Figura 2.6 ilustra a dispersão das ondas de radar nos diferentes alvos abordados neste trabalho, incluindo a superfície oceânica, através dos principais modos de reflexão: reflexão única, reflexão dupla e reflexão volumétrica. No entanto, é importante observar que o espalhamento predominante no mar é geralmente caracterizado pela reflexão única e especular. Na imagem SAR, a superfície oceânica pode apresentar diversas características causadas pelas condições climáticas, químicas e físicas do ambiente, como rugosidade, brilho e contraste.

Por outro lado, em uma mancha de óleo, o predomínio é da reflexão especular. Isso significa que a maioria do sinal de radar incidente não retorna ao sensor, resultando em tons mais escuros nas imagens SAR. Em contraste, embarcações possuem um padrão de retroespalhamento mais complexo, com múltiplos modos de reflexão. Nesse caso, a maioria do sinal é refletida de volta ao sensor, criando pontos brilhantes na imagem SAR que podem se assemelhar a formatos estelares.

Essas características de retroespalhamento nos diferentes alvos são importantes para a interpretação e análise das imagens SAR, permitindo a distinção entre a superfície oceânica, manchas de óleo e embarcações.

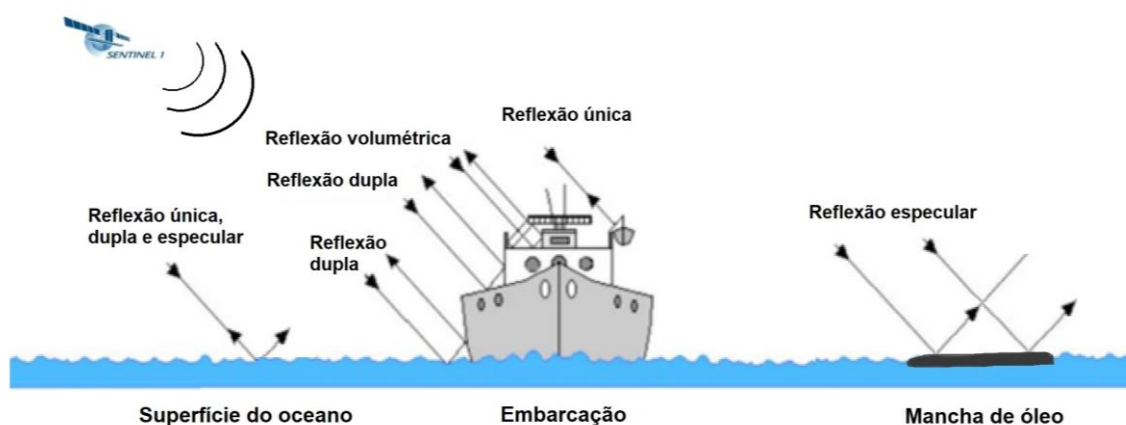


Figura 2.6 – Mecanismos de espalhamento da superfície do oceano e alvos.

Adaptado de (FALQUETO, 2019).

2.3 Aprendizado Profundo (*Deep Learning*)

Técnicas de aprendizado profundo têm se destacado nos últimos anos nos estudos de pesquisas para detecção de alvos oceânicos (GAO *et al.*, 2019). Em especial, o uso das técnicas em imagens SAR tem aumentado (SHARIFZADEH *et al.*, 2019) e permitido avanços no reconhecimento de objetos (HUANG *et al.*, 2017).

O aprendizado profundo são redes neurais que organizam os neurônios em diversas camadas (NGUYEN *et al.*, 2019; KUBAT, 2017). São exemplos: redes neurais profundas (DNN, *Deep Neural Network*), redes neurais convolucionais (CNN, *Convolutional Neural Network*), redes neurais recorrentes (RNN, *Recurrent Neural Network*) e rede adversativa generativa (GAN, *Generative Adversarial Network*) (NGUYEN *et al.*, 2019).

A popularização dessas técnicas, é devido a sua acurada capacidade na detecção de objetos, classificação de alvos em imagens, segmentação semântica e processamento de linguagem natural (WANG *et al.*, 2018).

No campo dinâmico do aprendizado profundo, o design da arquitetura e a otimização das redes neurais desempenham um papel importante na capacidade dos modelos de interpretar e prever com precisão a partir de dados complexos. Elementos fundamentais como *overfitting*, funções de ativação, algoritmos de otimização e técnicas de regularização constituem a partes dos processos de aprendizado. Estes conceitos não só definem a estrutura e o comportamento das redes neurais, mas também guiam a sua adaptação e desempenho ao longo do tempo. Entre as características, algumas destacam-se:

Overfitting: Ocorre quando um modelo de aprendizado de máquina aprende os detalhes e o ruído nos dados de treinamento a ponto de prejudicar o desempenho do modelo em novos dados. Isso significa que o modelo fica muito bem ajustado aos dados de treinamento e perde a capacidade de generalizar para dados não vistos.

Função de Ativação: As funções de ativação são fundamentais em redes neurais, pois ajudam a determinar a saída de um nó (neurônio) dado um conjunto de entradas. Elas introduzem não-linearidades no modelo, o que é essencial para aprender e representar dados complexos.

Função de Ativação ReLU: A função de ativação ReLU (*Rectified Linear Unit*) é uma das funções de ativação mais comumente usadas em redes neurais. Ela é definida como $y = \max(0, x)$, onde x é a entrada para o neurônio. A ReLU é popular devido à sua simplicidade computacional e porque ajuda a mitigar o problema do desvanecimento do gradiente em redes profundas.

Logits: Em aprendizado de máquina, especialmente em tarefas de classificação, os *logits* são as saídas do modelo antes da aplicação da função de ativação final, como a *softmax* em problemas de classificação. Eles podem ser interpretados como as pontuações brutas que são transformadas em probabilidades.

Algoritmo Adam: É um algoritmo de otimização usado para atualizar os pesos da rede neural no processo de treinamento. Ele é popular devido à sua eficiência computacional e à sua capacidade de ajustar a taxa de aprendizado automaticamente para diferentes parâmetros.

Regularização Dropout: É uma técnica de regularização utilizada para prevenir o *overfitting* em redes neurais. Funciona "desligando" aleatoriamente alguns neurônios durante o treinamento, o que ajuda a tornar o modelo mais robusto e menos dependente de qualquer único neurônio.

Taxa de Aprendizado: Um hiperparâmetro que controla o quanto atualizamos os pesos da rede neural em resposta ao gradiente do erro. Uma taxa muito alta pode fazer com que o modelo não convirja, enquanto uma taxa muito baixa pode levar a um processo de treinamento muito lento.

Épocas: É uma passagem completa através do conjunto de dados de treinamento. O número de épocas em treinamento é um hiperparâmetro que define quantas vezes o algoritmo de aprendizado trabalhará através do conjunto de dados de treinamento completo.

2.3.1 Redes Neurais Convolucionais (CNNs)

As Redes Neurais Convolucionais (CNNs do inglês *Convolutional Neural Networks*) são uma classe de modelos de aprendizado profundo (*Deep Learning*) que têm sido amplamente aplicados em tarefas de visão computacional, tais como classificação de imagens, detecção de objetos e segmentação semântica. Na Figura 2.7, são ilustradas algumas das principais redes CNNs utilizadas para detecção de objetos em imagens.

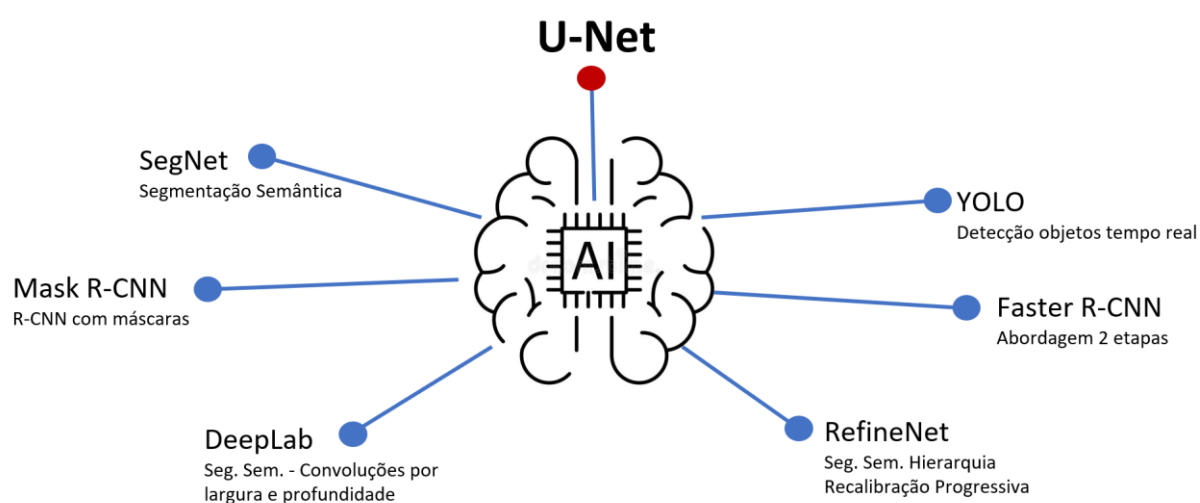


Figura 2.7 – Principais redes CNNs para detecção de objetos em imagens.

As CNNs, representam um importante avanço na área de aprendizado de máquina, especialmente no campo do reconhecimento de imagens (LECUN *et al.*, 1998). Elas são inspiradas na estrutura biológica do córtex visual de animais e são especialmente adaptadas para processar dados que têm uma estrutura de grade topológica, como uma imagem, que pode ser vista como uma grade de pixels (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

As CNNs possuem uma série de camadas de convolução que processam partes de uma imagem, filtrando os dados de entrada através de pequenos neurônios locais, cujos pesos são compartilhados em toda a imagem. Isso permite que a rede aprenda a detectar características locais, como bordas e texturas, independentemente de onde na imagem essas características ocorrem (GOODFELLOW; BENGIO; COURVILLE, 2016). Têm sido aplicadas com sucesso a uma série de tarefas de aprendizado profundo, incluindo reconhecimento de imagem, análise de vídeo, classificação de texto e até mesmo geração de texto. Foi uma CNN que alcançou o melhor desempenho no desafio de classificação de imagem, o *ImageNet* de 2012, uma competição de referência na comunidade de aprendizado de máquina (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

Recentemente foram aplicadas no processamento e interpretação de imagens de sensoriamento remoto, onde demonstraram um excelente desempenho na classificação de imagens de alta resolução (FALQUETO *et al.*, 2019; ZHU *et al.*, 2017).

2.3.2 Algoritmos de detecção

A exploração dos algoritmos de detecção representa uma faceta contemporânea do estudo computacional, permeando uma pluralidade de domínios, desde aplicações em visão computacional, identificação biométrica, até monitoramento ambiental via sensoriamento remoto. Os algoritmos de detecção buscam, intrinsecamente, automatizar o processo de identificação e localização de padrões ou objetos específicos em dados - comumente imagens ou sequências temporais. Seu desenvolvimento envolve, muitas vezes, uma simbiose entre técnicas clássicas de processamento de imagem e avanços no campo de aprendizado de máquina, com destaque para as Redes Neurais Convolucionais (CNNs).

O espectro de aplicabilidade desses algoritmos é vasto e se estende desde a medicina, com aplicações em diagnósticos automatizados (PICCIALLI *et al.*, 2020), até o setor de segurança, no reconhecimento automático de atividades anômalas em videovigilância (SULTANI; CHEN; SHAH, 2018). Em cada contexto, a detecção é moldada para atender especificidades e superar desafios inerentes ao tipo de dado e objetivo da análise, promovendo constante evolução e adaptação das técnicas empregadas.

Transitando para o escopo ambiental e marítimo, o uso de algoritmos de detecção em imagens SAR reveste-se de singular importância, dada a demanda por monitoramento constante e preciso de recursos hídricos para identificação de ocorrências anômalas, como derramamentos de óleo, e rastreamento de embarcações. A atenção para esse contexto é crucial

para a orquestração de respostas rápidas a incidentes ambientais e para a eficaz gestão de tráfego marítimo (CONCEIÇÃO *et al.*, 2021).

As imagens SAR, com sua habilidade de capturar informações sob variadas condições atmosféricas e iluminação, são instrumentos poderosos para o monitoramento oceânico. Entretanto, a detecção de manchas de óleo e embarcações nas mencionadas imagens carrega consigo desafios acentuados, impostos pela variabilidade na aparência desses alvos e pela presença de ruído e artefatos que podem confundir os algoritmos de detecção (HUANG; PAN; LEI, 2017).

A diferenciação entre manchas de óleo, que podem apresentar-se de maneira difusa e inconsistente, e embarcações, que ainda que mais pontuais e característicos, também proporcionam desafios devido a fatores como tamanho, material, e angulação em relação ao sensor, requer uma abordagem algorítmica que concilia robustez e flexibilidade. Modelos baseados em CNNs, como VGG-Net (SIMONYAN; ZISSERMAN, 2014), AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2017) e, de maneira destacada, U-Net em sua forma original (KRESTENITIS *et al.*, 2019), têm sido empregados com êxito na detecção e classificação de manchas de óleo e embarcações em imagens SAR, demonstrando capacidade superior na minimização de falsos positivos e aumento da precisão de detecção quando comparados a métodos tradicionais (WANG *et al.*, 2020).

2.3.3 Segmentação semântica

A segmentação semântica é uma tarefa de visão computacional que consiste em atribuir um rótulo semântico a cada *pixel* de uma imagem, permitindo a identificação e localização precisas de objetos e características (GARCIA- GARCIA *et al.*, 2017). É uma abordagem que dada a rotulação de cada *pixel* permite destacar “regiões de interesse” (LONG; SHELHAMER; DARRELL, 2015).

Em contraste com a detecção de objetos, que fornece rótulos de classe e limites em formato de caixa para objetos individuais, a segmentação semântica fornece uma compreensão muito mais detalhada da cena, ao segmentar e classificar todos os *pixels* de uma imagem.

Long; Shelhamer; Derrell, (2015) introduziram uma das primeiras redes neurais convolucionais de segmentação semântica chamada *Fully Convolutional Networks* (FCNs). FCNs utilizam camadas convolucionais ao longo de toda a rede, ao invés de camadas totalmente conectadas, o que permite a produção de mapas de características espacialmente

densos. Para conseguir isso, FCNs empregam uma operação chamada *upsample* para ampliar a resolução do mapa de características.

Desde a introdução das FCNs, surgiram muitas outras arquiteturas de redes neurais convolucionais para a segmentação semântica, como U-Net (RONNEBERGER; FISCHER; BROX, 2015), SegNet (BADRINARAYANAN; KENDALL; CIPOLLA, 2017) e *DeepLab* (CHEN *et al.*, 2018). Estes modelos, além de utilizarem técnicas avançadas como convoluções dilatadas, conexões de salto e convoluções transpostas, foram amplamente aplicados e mostraram um desempenho excepcional em diversas tarefas de segmentação semântica.

2.3.4 Arquitetura U-Net

O desenvolvimento de algoritmos robustos e eficientes para detecção de manchas de óleo e embarcações em imagens SAR é um tópico de pesquisa significativo. Pesquisas científicas recentes demonstram utilização da rede U-Net no âmbito da detecção de embarcações e principalmente de manchas de óleo, com bons resultados (CHEN; WANG, 2022; MAHMOUD *et al.*, 2023; SHABAN *et al.*, 2021).

A U-Net é uma arquitetura de CNN especialmente projetada para segmentação semântica (RONNEBERGER; FISCHER; BROX, 2015). Apresenta formato em “U” e uma estrutura de codificador-decodificador com conexões de salto entre as camadas correspondentes, como ilustrado na Figura 2.7.

A utilização da rede U-Net na detecção de manchas de óleo e embarcações em imagens SAR é devido à sua capacidade de combinar informações de contexto e localização, e obter resultados promissores em alvos que não possuem formato pré-definido, como as manchas de óleo.




Figura 2.8 – Arquitetura da rede U-Net original (RONNEBERGER; FISCHER; BROX, 2015).

A utilização da arquitetura U-Net mostra-se promissora para lidar com o desafio da detecção de derramamentos de óleo e embarcações devido às características específicas dessa arquitetura. A estrutura de *encoder-decoder* da U-Net permite que o modelo capture informações contextuais em diferentes escalas espaciais, o que é fundamental para a detecção precisa de objetos de interesse em imagens de satélite (CHEN; WANG, 2022; MAHMOUD *et al.*, 2023; KRESTENITIS *et al.*, 2019; SHABAN *et al.*, 2021).

A capacidade de aprendizado de características em diferentes escalas espaciais é particularmente relevante na detecção de derramamentos de óleo, pois essas manchas podem variar em tamanho e forma. A U-Net é capaz de capturar tanto detalhes finos quanto contextos mais amplos, o que possibilita a identificação de manchas de óleo em diferentes cenários e condições.

Além disso, a arquitetura U-Net apresenta uma vantagem importante em relação a abordagens mais simples, como a segmentação baseada em limiar. Enquanto a segmentação baseada em limiar é limitada na capacidade de lidar com variações de contraste e ruído, a U-Net é capaz de aprender a partir de exemplos rotulados e generalizar para casos não vistos durante o treinamento. Isso aumenta a robustez do sistema e melhora sua capacidade de lidar com condições adversas e variações nas imagens de satélite (PATTON *et al.*, 2021).

Outra consideração relevante é a capacidade da U-Net de lidar com um número limitado de dados rotulados. A obtenção de um conjunto de treinamento rotulado grande e diversificado pode ser uma tarefa difícil e demorada. A U-Net, por sua vez, permite um

treinamento eficaz mesmo com uma quantidade relativamente pequena de dados rotulados, o que é especialmente relevante em cenários onde a disponibilidade de dados pode ser restrita (SIDDIQUE *et al.*, 2021).

No entanto, é importante ressaltar que a utilização da arquitetura U-Net também apresenta alguns desafios. Um deles é o treinamento adequado do modelo, que requer uma cuidadosa definição dos hiperparâmetros e a seleção de uma função de perda apropriada. Para equilibrar a capacidade do modelo de aprender detalhes finos e complexos com a necessidade de evitar o sobreajuste e a generalização inadequada, este estudo se concentrará em aplicar modificações sobre a U-Net original (ZHOU *et al.*, 2022).

Além disso, a qualidade e a representatividade do conjunto de treinamento são fatores críticos para o desempenho do modelo. É necessário garantir que o conjunto de treinamento contenha exemplos variados e representativos das classes de interesse, a fim de que o modelo aprenda a detectar com precisão as manchas de óleo e as embarcações (RAJARAMAN *et al.*, 2021).

2.4 Indicadores utilizados para avaliação

A avaliação de modelos de aprendizado de máquina requer a utilização de métricas apropriadas para obter uma representação fiel da capacidade preditiva de um modelo. Entre as métricas mais comuns utilizadas em problemas de classificação e segmentação estão a acurácia, a precisão, a *loss* (função de perda) e o Índice de Jaccard (também conhecido como IoU - *Intersection over Union*) (GARCIA- GARCIA *et al.*, 2017; GIRARD-ARDHUIN *et al.*, 2005; LE; NGUYEN, 2022; POWERS, 2010). Dentre as métricas, as que possuem maior importância para trabalhos relacionados à segmentação semântica com uso de redes neurais, destacam-se *loss* e IoU. A função de perda é fundamental para o treinamento da rede neural, indicando o quão bem o modelo está realizando a tarefa de segmentação. Já o IoU é uma métrica de avaliação que mede a sobreposição entre a área prevista pela rede neural e a área real do objeto, sendo amplamente usada para avaliar a precisão do modelo em segmentação semântica. Além disso, a avaliação qualitativa de resultados de detecção pode ser útil para identificar áreas de melhoria, como a redução de falsos positivos ou aprimoramento da segmentação de manchas de óleo complexas.

A acurácia é uma medida intuitiva que fornece a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões. Essa métrica é calculada dividindo o número de

previsões corretas (verdadeiros positivos e verdadeiros negativos) pelo número total de previsões realizadas pelo modelo:

$$\text{Acurácia} = \frac{\text{Verdadeiros Positivos} + \text{Verdadeiros Negativos}}{\text{Total de previsões}} \quad (2.9)$$

A precisão é uma métrica útil em situações em que os falsos positivos são considerados mais prejudiciais que os falsos negativos (POWERS, 2010). Ela mede a proporção de previsões positivas que são realmente corretas. A precisão é calculada dividindo o número de verdadeiros positivos pelo total de positivos previstos pelo modelo (soma dos verdadeiros positivos e falsos positivos):

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}} \quad (2.10)$$

Loss (perda) refere-se à diferença entre a previsão do modelo e os valores reais. Em outras palavras, a função de perda quantifica o quão bem o modelo está performando em relação ao objetivo de otimização. Uma função de perda é utilizada para treinar a rede neural, através do ajuste dos pesos para minimizar a perda, o que, por sua vez, tenta fazer o modelo aprender a padrão subjacente nos dados (LE; NGUYEN, 2022). Exemplos comuns de funções de perda incluem "*mean squared error*" para tarefas de regressão e "*BCE with Logits Loss*" para tarefas de classificação, este último utilizado neste estudo.

$$\text{BCEWithLogitsLoss}(x, y) = -y \cdot \log\left(\frac{1}{1+e^{-x}}\right) - (1 - y) \cdot \log\left(1 - \frac{1}{1+e^{-x}}\right) \quad (2.11)$$

onde x são os logits (outputs do modelo que não são normalizados para uma probabilidade), y são os rótulos binários verdadeiros (0 ou 1), e por fim e o Número de Euler.

O IoU é uma métrica frequentemente utilizada para avaliar a qualidade de um modelo de segmentação. Ela mede a proporção da interseção entre a área da previsão e a área da verdade terrestre em relação à união dessas duas áreas. Quanto maior o valor do IoU, maior é a sobreposição entre a previsão e a verdade terrestre, indicando uma segmentação mais precisa (GARCIA- GARCIA *et al.*, 2017). A fórmula para calcular o IoU é:

$$\text{IoU} = \frac{\text{Área de Intersecção}}{\text{Área de União}} \quad (2.12)$$

Essas métricas são amplamente utilizadas para avaliar o desempenho de modelos em diferentes tarefas, como classificação, detecção de objetos e segmentação. Cada uma delas tem suas próprias características e pode ser apropriada em diferentes contextos, dependendo dos objetivos e das necessidades.

3 Metodologia

Este capítulo detalha a metodologia utilizada no desenvolvimento de um algoritmo para detecção de manchas de óleo e embarcações com base em imagens de Radar de Abertura Sintética (SAR). O algoritmo se fundamenta em *Deep Learning*, uma subcategoria de aprendizado de máquina que utiliza redes neurais profundas, emulando o comportamento de neurônios humanos. A arquitetura selecionada para este propósito é uma adaptação da U-Net, modificada especificamente para identificar os alvos deste estudo nas imagens SAR.

A metodologia é estruturada em etapas, iniciando pela primeira etapa, "Banco de Dados (*Dataset*)", onde os *datasets* são adquiridos, organizados e as imagens SAR são processadas na segunda etapa. A terceira etapa "Definição da Arquitetura e Modificações" adapta a arquitetura original U-Net às necessidades do estudo. Posteriormente, na quarta etapa denominada "Treinamentos e Validações", os modelos - que são algoritmos computacionais projetados para reconhecer padrões e realizar previsões com base em dados - são treinados e validados, verificando-se as métricas dos modelos treinados. Na quinta e última etapa "Implementação do Algoritmo" os modelos são testados com implementação de um algoritmo sequencial de detecção, com uso de imagens recentes do satélite Sentinel-1, visando a avaliar a aplicabilidade do algoritmo.

Uma representação visual das etapas metodológicas é ilustrada na Figura 3.1.



Figura 3.1 – Metodologia da pesquisa.

3.1 Etapa 1: Banco de dados (*Dataset*)

Para o desenvolvimento eficaz de um algoritmo de detecção utilizando *Deep Learning*, é importante a utilização de um conjunto de dados volumoso, contendo imagens que representam os alvos de interesse (HE *et al.*, 2016). Neste estudo, foram utilizados dois *datasets* públicos de imagens SAR contando alvos do tipo “manchas de óleo” e “embarcações”, bem como rótulos indicando a localização desses alvos — um elemento essencial para a etapa de treinamento do algoritmo.

Os *datasets* utilizados foram desenvolvidos e disponibilizados por (CONCEIÇÃO *et al.*, 2021) e por (KRESTENITIS *et al.*, 2019). Em ambos os *datasets*, as imagens contidas se originam dos satélites Sentinel 1A e 1B da Agência Espacial Europeia (ESA), com a presença de alvos (manchas de óleo e embarcações). A veracidade de campo dos alvos foi estabelecida pelos autores dos conjuntos de dados, baseando-se em registros de acidentes ambientais,

proporcionando assim uma referência confiável. Amostras das imagens de cada *dataset* são apresentadas nas Figuras 3.2 e 3.3.




Figura 3.2 - Exemplos de imagens SAR do *dataset* do autor (KRESTENITIS *et al.*, 2019).




Figura 3.3 - Exemplos de imagens SAR do *dataset* do autor (CONCEIÇÃO *et al.*, 2021).

Cada conjunto de dados foi estabelecido e utilizado de forma individual neste trabalho, ou seja, para detecção exclusivamente de um alvo. A escolha dos datasets para cada tipo de alvo deve-se as diferenças nas características metodológicas de criação do *dataset* por cada autor, seja no formato, resolução e tamanho das imagens, que poderia causar incompatibilidade ou perda de qualidade nos treinamentos e pela quantidade de alvos catalogados em cada *dataset*. A principal diferença observada foi no formato dos arquivos das imagens, estando um no formato decibel (dB) e outro no formato *Joint Photographic Experts Group* (JPEG). As imagens no formato dB apresentam uma amplitude de valores significativamente maior em comparação às imagens no formato JPEG (ANUSHA; BHARATHI, 2019). Esta extensiva faixa dinâmica oferece uma riqueza de detalhes que é particularmente benéfica para o treinamento de detecção de manchas de óleo. Em ambientes onde nuances sutis podem ser cruciais para discernir entre uma mancha de óleo autêntica e um falso positivo, uma amplitude maior facilita a distinção. Adicionalmente, essa amplitude dinâmica pode contribuir para modelos mais precisos, possibilitando a geração de índices de probabilidade mais refinados, otimizando assim a eficácia do sistema de detecção. Sendo assim, por conveniência, foi utilizado para treinamento do modelo de “manchas de óleo” o *dataset* com formato em dB (CONCEIÇÃO *et al.*, 2021), e no modelo de “embarcações” o *dataset* com formato JPEG, de (KRESTENITIS *et al.*, 2019), visto que alvos do tipo embarcações possuem características peculiares e distintas dos demais alvos, não havendo prejuízos no treinamento o uso de imagens nesse formato (JPEG). Os detalhes de cada *dataset* de dados são fornecidos na Tabela 3.1.

Tabela 3.1 – Características dos *datasets*.

Nome do <i>dataset</i>	Quantidade de imagens (Un)	Resolução das imagens (pixels)	Tamanho do <i>dataset</i> (Mb)	Formato das imagens
CONCEIÇÃO <i>et al.</i> , 2021	2.148	256x256	454	Decibel (dB)
KRESTENITIS <i>et al.</i> , 2019	1.112	1250x650	386	JPEG

Além dos *datasets* adquiridos dos autores, foi conduzida uma pesquisa própria abrangendo imagens SAR em âmbito global dos últimos 5 anos, provenientes dos satélites Sentinel-1, com presença de manchas de óleo de acidentes ambientais publicamente reportados e de embarcações. Este processo visou à elaboração de um *dataset* próprio e inédito, destinado a avaliações subsequentes do algoritmo de detecção desenvolvido e

implementado neste estudo. As imagens foram submetidas às mesmas etapas de pré-processamento e preparação que as imagens dos conjuntos de dados dos autores (CONCEIÇÃO *et al.*, 2021) (KRESTENITIS *et al.*, 2019).

3.2 Etapa 2: Processamento das imagens

As imagens dos *datasets* passaram por técnicas de processamento digital de imagens SAR com a finalidade melhorar a qualidade visual. Estes procedimentos buscam aumentar a eficiência nos treinamentos dos modelos de detecção (RICHARDS, 2009). Foram realizadas as seguintes etapas de pré-processamento:

1. Normalização e Calibração Radiométrica: A normalização radiométrica é essencial para reduzir a variação nas intensidades das imagens SAR, ajustando-as para uma escala consistente (EL HAJJ *et al.*, 2016). Esta escala consistente refere-se à padronização dos valores de intensidade do radar, de modo que representem de forma uniforme as características físicas observadas, independentemente das variações nas condições de aquisição ou nas características do sensor. Isso permite comparações mais precisas e confiáveis entre diferentes imagens SAR, fundamental para análises detalhadas e monitoramento ao longo do tempo. Isso facilita a comparação entre diferentes imagens e melhora a estabilidade do treinamento;

2. Filtragem e Remoção de Ruídos: Técnicas de filtragem, com uso da filtragem *speckle*, são aplicadas para reduzir os ruídos presentes nas imagens SAR. Isso melhora a clareza das características alvo e minimiza artefatos indesejados que poderiam afetar a precisão das detecções (CHOI; JEONG, 2019); e

3. Georreferenciamento e Correção Geométrica: O georreferenciamento e a correção geométrica garantem que as imagens sejam espacialmente precisas e coerentes com informações geográficas. Esses processos eliminam distorções geométricas e melhoram a sobreposição entre diferentes imagens (TOMAŠTÍK *et al.*, 2019). As distorções geométricas nas imagens podem ser causadas por vários fatores, incluindo variações na altitude e velocidade da plataforma de sensoriamento, irregularidades topográficas do terreno, variações atmosféricas e o ângulo de inclinação do sensor. Estes fatores podem levar a erros de localização e forma dos objetos na imagem, afetando a precisão na sobreposição e na interpretação dos dados.

Outra operação muito importante realizada nas imagens foi a criação de rótulos (*labels*), que são máscaras binárias definidas a partir das localizações dos alvos, como pode ser observado nas Figuras 3.2 e 3.3.




Figura 3.4 - Exemplos de imagens com alvos com manchas de óleo (a) e embarcações (b) com seus respectivos rótulos (c) e (d), determinando a localização dos alvos. Azul: Mancha de óleo; Marrom: Embarcações.




Figura 3.5 - Exemplos de imagens SAR com falsos positivo (a) e (b) e seus respectivos rótulos (c) e (d). Azul: Mancha de óleo; Vermelho: Falso positivo; Verde: Continente.

Os rótulos, frequentemente referidos como máscaras binárias, são meticulosamente gerados a partir de anotações manuais para indicar a localização precisa dos alvos de interesse em cada imagem. Cada classe de alvo é associada a um número digital específico, que serve como sua identidade. Geralmente, utiliza-se tons de cinza ou cores RGB para marcar esses alvos nos rótulos.

Neste estudo, o foco recai sobre dois alvos principais: “manchas de óleo” e “embarcações”. Cada conjunto de dados abrange um desses alvos. A especificação dos rótulos para esses alvos é detalhada na Tabela 3.2. É relevante destacar que quaisquer outros alvos identificados nas imagens são categorizados como "fundo". Tal abordagem foi escolhida por

conveniência e visando simplificar o treinamento dos algoritmos em uma perspectiva binária, diferenciando os alvos de interesse do contexto geral.

Tabela 3.2 – Identificação dos rótulos (máscaras binárias) dos *datasets*.

Classe do Alvo	<i>Dataset</i>	ND (Número Digital) da classe do alvo
Mancha de Óleo	<i>Sentinel-1 SAR Image Dataset</i> ¹	1
Embarcação	<i>Oil Spill Dataset</i> ²	3
Fundo	<i>Sentinel-1 SAR Image Dataset</i> ¹ e <i>Oil Spill Dataset</i> ²	0

¹ CONCEIÇÃO *et al.*, 2021; ² KRESTENITIS *et al.*, 2019

Por fim, foram aplicadas algumas técnicas de aumento de dados (Horizontal, Vertical, Rotação, Redimensionamento), conhecidas como "*data augmentation*" (SHORTEN; KHOSHGOFTAAR, 2019), utilizada em aprendizado de máquina e visão computacional para ampliar a quantidade de dados. Ela envolve a aplicação de várias transformações nas imagens originais, como rotações, reflexões e variações de escala, criando variações das imagens existentes. Isso permite ao modelo aprender e generalizar melhor, especialmente em situações com conjuntos de dados limitados. No âmbito dos estudos dos autores (CONCEIÇÃO *et al.*, 2021) e (KRESTENITIS *et al.*, 2019) e nesta pesquisa, tais técnicas foram aplicadas a todas as imagens dos conjuntos de dados durante os treinamentos, ampliando a quantidade de informações e a diversidade dos alvos. Embora o aumento de dados seja uma estratégia eficaz para melhorar a generalização do modelo, é importante notar que seu uso excessivo ou inadequado pode, em alguns casos, levar a *overfitting*. O *overfitting* ocorre quando um modelo aprende padrões específicos dos dados de treinamento tão bem que se torna menos eficaz em prever dados não vistos. Para evitar isso, deve-se equilibrar a quantidade e o tipo de aumento de dados aplicado, garantindo que o modelo não se torne excessivamente ajustado às características ampliadas, mas sim aprenda a generalizar a partir de uma variedade representativa de características."

3.3 Etapa 3: Arquitetura U-Net e modificações

A arquitetura do modelo é uma parte primordial do desenvolvimento do algoritmo de detecção. Como mencionado na Seção 2.2.3, a arquitetura escolhida para este estudo foi a U-Net, que é especialmente adequada para este problema devido à sua capacidade de capturar características em escalas variadas e tem se destacado em várias tarefas de segmentação de

imagens com uso de *Deep Learning* nos últimos anos, devido à sua codificação-decodificação e à sua característica de conexões de salto que permitem que a rede aprenda representações mais ricas e detalhadas (RONNEBERGER; FISCHER; BROX, 2015).

O modelo U-Net é composto por uma sequência de camadas convolucionais, camadas de *max pooling* e camadas de *up-sampling*. As camadas convolucionais aprendem uma representação de características das imagens, enquanto as camadas de *max pooling* reduzem a dimensionalidade das imagens. As camadas de *up-sampling* aumentam a dimensionalidade das imagens para permitir a segmentação em nível de *pixel*.

Inicialmente a rede U-Net foi implementada na forma original proposta por Ronneberger, Fischer e Brox (2015), com o objetivo de replicar e comparar os resultados com a pesquisa de Krestenitis (2019), cujo dataset foi utilizado neste estudo. Na reprodução dos resultados, observou-se uma correspondência próxima com os achados de Krestenitis *et al.* (2019), apesar de ligeiras variações. Essas flutuações podem ser atribuídas a diferenças intrínsecas nos processos de treinamento e a variações computacionais. Esta comparação serviu para validar a implementação da rede U-Net original e permitir a realização das modificações e adensamento do banco de dados que serão apresentadas mais à frente.

Para configuração da U-Net, utilizou-se a função de ativação ReLU (*Rectified Linear Unit*) nas camadas convolucionais. A ReLU transforma qualquer valor de entrada negativo em zero e mantém qualquer valor positivo inalterado. Esta característica permite ao modelo aprender representações não-lineares de maneira eficiente, evitando o risco de saturação. Os valores de saída (*logits*), que são os valores brutos e não normalizados produzidos pela rede neural, são então passados por uma função de ativação *softmax*, que os converte em probabilidades. A *softmax* normaliza os *logits* para que seus valores estejam entre 0 e 1, com uma soma total de 1, tornando-os assim interpretáveis como probabilidades, o que é fundamental para tarefas de classificação multiclasse.

A função de perda utilizada nos treinamentos foi a “Perda de Entropia Cruzada Binária com *Logits* (*BCE with Logits Loss*). Esta função de perda é adequada para problemas de classificação binária e tem sido amplamente utilizada na segmentação de imagens (SUDRE *et al.*, 2017). Explicando brevemente o funcionamento da função de perda, “Entropia Cruzada” (*Cross-Entropy*) é uma métrica de desempenho utilizada em problemas de classificação. Para a classificação binária, usa-se a entropia cruzada binária e *logits* são as saídas do modelo antes da aplicação de uma função de ativação, como a função sigmoide em problemas de classificação binária. A expressão "com *logits*", significa que a função espera que seja

fornecido essas saídas diretas (sem função de ativação aplicada) e ela mesma se encarregará de aplicar a função sigmoide e calcular a perda.

Adicionalmente, empregou-se a técnica de balanceamento de classes para gerenciar o desequilíbrio de classes nos dados de treinamento, atribuindo pesos ampliados aos pixels associados à classe minoritária.

Para otimizar os pesos da rede, o algoritmo *Adam* foi adicionado na rede, que é um método de otimização estocástica que combina os benefícios dos algoritmos *AdaGrad* e *RMSProp*. O *Adam* é conhecido por sua eficiência computacional e pela necessidade mínima de ajuste manual dos hiperparâmetros (KINGMA; BA, 2014).

Implementou-se a técnica de *early stopping* para evitar a chance de ocorrência do sobre ajuste do modelo (*overfitting*). Essa técnica monitora o “erro de validação” durante o treinamento, podendo interromper o treinamento quando esse erro para de melhorar durante uma sequência de épocas pré-definidas (PRECHELT, 2002).

Com o intuito de obter melhores resultados, foram realizadas alterações adicionais na rede U-Net, visando sua adaptabilidade às características específicas das imagens SAR e à questão da detecção de derramamento de óleo e embarcações. As modificações consistem em:

1. Uso de Blocos Residuais: Inseridos blocos residuais no modelo U-Net. Cada bloco residual contém duas camadas convolucionais seguidas por uma camada de ReLU e uma de *dropout*. Além disso, temos uma conexão de atalho ou conexão residual que permite que a entrada original seja somada à saída das camadas convolucionais. Esta modificação é usada para combater o problema de desaparecimento do gradiente que pode ocorrer durante o treinamento de redes profundas;

2. Inclusão de Regularização L2: Para evitar o *overfitting* (*sobreajuste*) e melhorar a generalização do nosso modelo, foi adicionada uma regularização L2 na nossa função de perda. A força da regularização é controlada pelo hiperparâmetro *lambda_reg*;

3. Adaptação da última camada convolucional: Na rede U-Net original, a última camada é uma camada convolucional de 1x1 que mapeia cada componente do vetor de 64 componentes resultante em uma imagem desejada de 2 classes. Neste contexto, ajustou-se essa camada para gerar um mapa de segmentação binário (óleo x não óleo e embarcação x não embarcação); e

4. Função de perda e Otimização: No treinamento, utilizou-se a função de perda de entropia cruzada binária com *logits* (*BCEWithLogitsLoss*) e o otimizador *Adam*.

Na Tabela 3.3, são informados os principais parâmetros utilizados na rede.

Tabela 3.3 – Principais parâmetros da rede U-NET com modificações.

Parâmetro	Valor/Descrição
Arquitetura	U-Net modificada
Profundidade da rede (camadas)	40
Função de ativação	ReLU (<i>Rectified Linear Unit</i>)
Regularização	<i>Dropout</i> (0.5)
Função de perda	<i>BCE with Logits Loss</i>
Otimizador	<i>Adam</i>
Taxa de aprendizado	0.000005
Tamanho do lote	4
Épocas	100
Aumento de dados	Horizontal, Vertical, Rotação, Redimensionamento
Métricas de avaliação	Acurácia, Precisão, <i>Recall</i> e IoU

Estas modificações foram implementadas para adaptar a rede U-Net ao problema específico abordado neste trabalho, visando aprimorar sua performance e capacidade de generalização apresentados posteriormente na seção de resultados, onde se comparará a rede modificada com a versão original utilizada pelas referências citadas.

3.4 Etapa 4: Treinamentos e Validações

O ambiente computacional e as ferramentas usada no desenvolvimento do trabalho são:

Ambiente Computacional:

- Processador: *Intel Core i9*;
- Sistema Operacional: *Windows 11*;
- Memória RAM: 64GB;
- Armazenamento: 1TB SSD; e
- GPU: *NVIDIA GTX1650* com 4GB.

Ferramentas de Desenvolvimento:

- Linguagem de Programação: *Python 3.9*;
- Ambiente Interativo: *Jupyter Notebook*;

-Biblioteca de *Deep Learning: PyTorch* (PASZKE *et al.*, 2019), e
-Plataforma de Processamento de Imagens SAR: *Sentinel Application Platform* (SNAP).

O desenvolvimento e implementação dos algoritmos foram realizados utilizando a linguagem de programação *Python* em ambiente *Jupyter Notebook*. Essa combinação de ferramentas fornece um ambiente interativo e flexível para o desenvolvimento e experimentação (KLUYVER *et al.*, 2016). Adicionalmente, a escolha da biblioteca *PyTorch* (PASZKE *et al.*, 2019) foi motivada pela sua eficiência em realizar cálculos tensoriais em GPUs, além de ser repleta de ferramentas e recursos prontos para o design, implementação e treinamento de redes neurais.

Após a implementação da arquitetura adaptada da U-Net, dois modelos distintos foram treinados: o primeiro com o conjunto de dados proposto por Conceição *et al.* (2021), voltado à detecção de manchas de óleo, e o segundo com o conjunto de dados de Krestenitis *et al.* (2019), direcionado à detecção de embarcações. Essa estratégia de treinamento individualizado foi adotada pelas seguintes razões:

1. Especialização de Tarefas: Cada modelo especializou-se em sua tarefa de detecção correspondente. Ao treinar cada modelo de maneira direcionada, maximiza-se a capacidade de cada um aprender e generalizar a partir dos padrões únicos presentes em sua respectiva classe de alvo;

2. Eficiência de Treinamento: Ao treinar os modelos separadamente, otimiza-se o treinamento para cada tipo de alvo. Isso significa que o ajuste dos parâmetros de treinamento pode ser realizado para melhor atender às necessidades específicas de detecção de manchas de óleo e posteriormente para embarcações, sem comprometer a eficácia de um pelo outro.

3. Economia de Recursos: Treinar dois modelos separados permite aplicar cada um apenas quando necessário. Esta abordagem individualizada economiza recursos computacionais.

Por fim, a decisão de utilizar modelos de treinamento independentes para detecção de "manchas de óleo" e "embarcações", ao invés de treinar ambos os alvos simultaneamente em um único modelo, também foi motivada pela metodologia de detecção sequencial dos alvos do algoritmo implementado, cuja abordagem será mais detalhadamente discutida na subseção subsequente.

Os tempos de treinamento para ambos os modelos foram comparáveis, refletindo a adoção de arquiteturas similares para cada algoritmo. O modelo focado em manchas de óleo

demandou 8 horas de treinamento, ao passo que o destinado à detecção de embarcações consumiu 7 horas.

Durante o treinamento, os modelos foram instruídos a associar imagens SAR a seus respectivos alvos e rótulos de identificação. A métrica *Intersection over Union* (REZATOFIGHI *et al.*, 2019) foi adotada para avaliar a precisão da segmentação durante o treinamento.

Uma vez que um modelo é treinado, ele precisa ser avaliado e validado para determinar o seu desempenho. Para isso, os conjuntos de dados são divididos na proporção 90% para treinamento e 10% para validação, do total das imagens do banco de dados, conforme utilizado pelo autor do *dataset* (KRESTENITIS *et al.*, 2019). Esta abordagem de separar um conjunto de dados é uma prática padrão em aprendizado de máquina para avaliar a capacidade de generalização de um modelo em dados não vistos.

3.5 Etapa 5: Implementação do algoritmo

Após as fases de treinamentos e validações dos modelos destinados à detecção de manchas de óleo e embarcações, elaborou-se um script de implementação do algoritmo de detecção de manchas de óleo e embarcações, para aplicação prática. O script adotado é baseado numa abordagem sequencial detalhado na Figura 3.4.

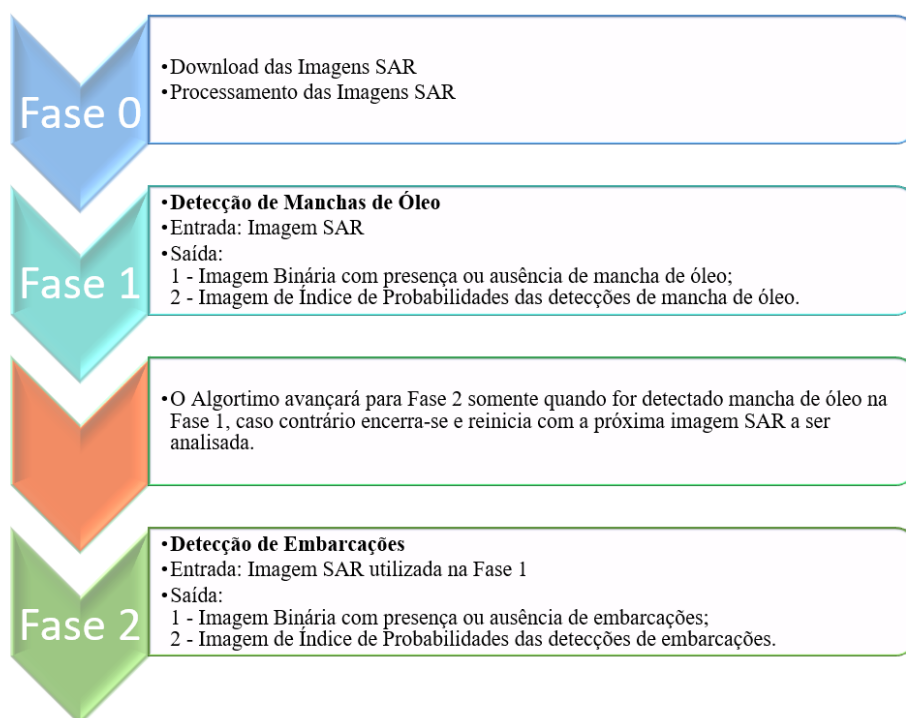


Figura 3.6 – Script do algoritmo de detecção.

Para avaliação do algoritmo, selecionaram-se 5 (cinco) imagens SAR no formato dB, distintas daquelas utilizadas no conjunto de treinamento. Estas passaram pelos mesmos procedimentos de processamentos adotados para as imagens dos *datasets* de treinamentos. As imagens, adquiridas do portal da ESA (Sentinel-1), datam dos últimos cinco anos. Dentre elas, algumas retratam manchas de óleo resultantes de incidentes ambientais amplamente divulgados nesse período. Adicionalmente, algumas imagens exibem embarcações próximas a essas manchas de óleo. A Figura 3.5 ilustra as imagens empregadas. A utilização desse conjunto de dados visa a uma avaliação prática e atualizada da eficácia do algoritmo em cenários realísticos.




Figura 3.7 – Imagens SAR utilizadas na aplicação prática do algoritmo: (a) litoral Nordeste brasileiro (Rio Grande do Norte, 2019); (b) litoral Paulista (porto de Santos, 2023); (c) Mar Vermelho, 2020; (d) litoral Nordeste brasileiro (Bahia, 2019); (e) Mar Mediterrâneo, 2018.

Nas imagens SAR utilizadas e apresentadas na Figura 3.5, as imagens (a), (c), (d) e (e) evidenciam a presença de manchas de óleo (tons escuros) e nas imagens (a), (c) e (e) também exibem embarcações (pontos claros destacados nas figuras). A imagem (d) não há presença de embarcações, somente de uma mancha de óleo localizada na região esquerda da imagem. Por outro lado, a imagem (b) destaca diversas embarcações, mas não indica a presença de

manchas de óleo. No entanto, há um efeito visual nessa imagem que se assemelha ao retroespalhamento típico de manchas de óleo, o que pode conduzir a detecções de falsos positivos.

3.5.1 Fase 1: Detecção de manchas de óleo

O algoritmo desenvolvido opera em duas fases distintas. A primeira, voltada para a detecção de manchas de óleo, analisa cada imagem em busca da presença desses alvos, gerando dois formatos de saída:

- **Imagem de Índice de Probabilidades:** Esta saída apresenta uma escala cromática que indica a probabilidade, variando de 0% a 100%, de identificação dos alvos. A representação em probabilidades facilita a distinção entre detecções autênticas e possíveis falsos positivos.

- **Imagem Binária:** Neste formato, a cor vermelha denota a detecção de alvos com probabilidade superior a 90%, enquanto o azul sinaliza a ausência de detecção.

Após essa análise inicial, as imagens que indicam a presença de manchas de óleo são encaminhadas para a Fase 2, que se concentra na Detecção de Embarcações.

Se, na Fase 1, as imagens não evidenciarem manchas de óleo, o processo é finalizado. Tal estratégia otimiza a eficiência do algoritmo, evitando o consumo desnecessário de recursos computacionais em análises de imagens desprovidas de manchas de óleo.

3.5.2 Fase 2: Detecção de embarcações

Nesta etapa, as imagens são submetidas a um processo de detecção análogo ao da Fase 1, porém com o intuito de identificar embarcações. O objetivo é rastrear possíveis navios ou barcos que poderiam estar relacionados ao derramamento de óleo. Os resultados gerados nesta fase são similares aos da etapa anterior, compreendendo uma imagem de Índice de Probabilidades e uma Imagem Binária.

É importante salientar que a identificação de embarcações nas imagens não é assegurada. Os satélites, devido ao seu tempo de revisita, não proporcionam monitoramento contínuo, o que significa que a captura das imagens pode não coincidir com o exato momento do vazamento de óleo. Em situações como essa, torna-se essencial a análise de um conjunto mais extenso de imagens, especialmente aquelas temporalmente próximas à detecção da mancha de óleo.

Além disso, é válido destacar a limitação imposta pela resolução espacial das imagens provenientes dos satélites Sentinel-1. Embarcações de menor porte, com dimensões inferiores a 20 metros, podem não ser adequadamente detectadas devido a essa restrição.

Ao final desta fase, obtém-se uma detecção completa de manchas de óleo e possíveis embarcações presentes na imagem analisada.

3.5.3 Análise da estratégia metodológica

A estratégia metodológica sequencial implementada demonstra uma abordagem na alocação de recursos computacionais ao priorizar a detecção de embarcações somente em imagens que exibem evidências de manchas de óleo, buscando maximizar a eficiência do processo, minimizando a análise de dados que possam não ser relevantes para o objetivo principal da pesquisa. Esta abordagem, ao reduzir a quantidade de dados processados, otimiza o tempo necessário para identificar embarcações que possam estar associadas a tais derramamentos. É importante ressaltar que, em um contexto de monitoramento marítimo, a rapidez e precisão na detecção são determinantes para a tomada de decisões em busca de minimizar os impactos ambientais e localizar possíveis suspeitos.

As limitações inerentes às imagens de satélite, como o tempo de revisita e a resolução espacial, são alguns pontos que devem ser avaliados com maior atenção, visto que pode impactar diretamente em alguns resultados. Portanto, a metodologia proposta, ao mesmo tempo que oferece avanços para o monitoramento marítimo, também ressalta a necessidade de uma avaliação contínua e crítica dos dados e resultados gerados, sempre que possível por análise humana dos resultados positivos, principalmente de manchas de óleo.

4 Resultados e Discussões

Este capítulo apresenta e discute os resultados obtidos pelo modelo de aprendizado profundo baseado em U-Net para a detecção de manchas de óleo e embarcações em imagens SAR, e está organizado em subseções para um melhor entendimento. Primeiramente são abordados os resultados obtidos nos treinamentos dos modelos e na sequência os resultados da aplicação prática do algoritmo de detecção desenvolvido. As subseções finais deste capítulo, discorrerão sobre as discussões dos resultados dos treinamentos e da aplicação prática e por fim, discussão da comparação deste algoritmo desenvolvido com os algoritmos de referências.

4.1 Resultado dos Treinamentos

Nesta subseção, detalharemos os resultados alcançados durante o treinamento dos modelos destinados à detecção de manchas de óleo e embarcações. Utilizamos uma estratégia sequencial, treinando os modelos de forma independente, mas sob a mesma arquitetura U-Net. Inicialmente, o foco foi direcionado ao modelo de detecção de manchas de óleo, seguido pelo de detecção de embarcações.

A validação de um modelo reside em sua performance prática, e é capturada pelas curvas de desempenho. Estas curvas, que podem incorporar métricas como IoU, precisão, entre outras, oferecem uma avaliação quantitativa do desempenho do modelo em tarefas de detecção. Enquanto a curva de aprendizado destaca a capacidade de se adaptar aos dados, a curva de desempenho reflete sua eficácia prática na tarefa de detecção. A análise conjunta das curvas de aprendizado e desempenho proporciona uma visão holística da robustez e eficácia dos modelos treinados.

O desempenho durante o treinamento é um aspecto decisivo a ser considerado na avaliação do treinamento. Durante os treinamentos foram monitoradas algumas métricas, entre elas a perda de treinamento, a perda de validação e IoU. A perda de treinamento representa a discrepância entre as predições do modelo e as máscaras binárias correspondentes para o conjunto de treinamento, enquanto a perda de validação é calculada da mesma forma, mas para o conjunto de validação.

As curvas de aprendizado desempenham um papel fundamental na avaliação da evolução do treinamento. Estas curvas, que representam a perda de treinamento e validação ao longo das épocas, fornecem *insights* valiosos sobre a eficácia do modelo. A perda de

treinamento reflete a capacidade de se ajustar aos dados de treinamento, enquanto a perda de validação indica sua habilidade de generalizar para conjuntos de dados não vistos anteriormente. Uma tendência decrescente na curva de perda sugere que o modelo está convergindo e se ajustando adequadamente às nuances das imagens SAR e seus respectivos alvos.

Os gráficos que serão apresentados fornecem informações das métricas em função do número de épocas para cada modelo. O eixo horizontal representa o número de épocas e o eixo vertical representa os valores das métricas.

A análise do desempenho do treinamento permite avaliar a capacidade dos modelos em aprender os padrões relevantes para a detecção das manchas de óleo e embarcações. A diminuição da perda ao longo das épocas indica que os modelos estão se ajustando aos dados de treinamento e melhorando suas habilidades de predição. No entanto, é importante observar o equilíbrio entre a diminuição da perda de treinamento e a perda de validação, pois um grande desvio entre essas duas curvas pode indicar *overfitting* do modelo.

Os resultados obtidos demonstraram bons valores de precisão e acurácia para ambos os modelos. O de detecção de manchas de óleo alcançou uma precisão média de 86% e uma acurácia média de 94%, enquanto o de detecção de embarcações obteve uma precisão média de 89% e uma acurácia média de 99%. Esses resultados indicam que os modelos são capazes de realizar detecções precisas e corretas das respectivas classes de interesse.

No que diz respeito ao coeficiente IoU, que mede a sobreposição entre as previsões dos modelos e a verdade de campo, observamos valores satisfatórios. O de detecção de manchas de óleo alcançou um coeficiente IoU médio de 67,51 enquanto o de detecção de embarcações obteve um coeficiente IoU médio de 76,23. Esses valores refletem uma correspondência aceitável entre as detecções feitas pelos modelos e a realidade das imagens.

Na Tabela 4.1 são apresentados todos os resultados obtidos nas métricas de avaliação.

Tabela 4.1 – Métricas obtidas nos treinamentos dos modelos.

Modelo	Acurácia	Precisão	IoU
Modelo de Mancha de Óleo	94,35%	86,85%	67,51
Modelo de Embarcações	99,12%	89,49%	76,23

Em geral, os resultados do desempenho do treinamento são encorajadores, com uma melhoria contínua na capacidade dos modelos de realizar detecções precisas. Isso é um indicativo de um treinamento eficiente e bem-sucedido. A próxima seção discutirá a avaliação

dos modelos em um conjunto de dados de teste independente para verificar o desempenho em cenários reais.

4.1.1 Modelo de manchas de óleo

Nos resultados obtidos pelo treinamento do modelo de detecção de manchas de óleo, a análise das curvas de aprendizado, representada na Figura 4.1, revelou uma tendência consistente de diminuição da perda tanto no treinamento quanto na validação ao longo das épocas. Esta tendência é um indicativo positivo de que o modelo está aprendendo e adaptando-se aos dados. No entanto, uma observação mais detalhada da curva de validação mostra flutuações sutis em comparação com a curva de treinamento. Esta discrepância sugere um possível sobreajuste do modelo aos dados de treinamento, o que pode ser atribuído à complexidade e variabilidade das manchas de óleo em termos de forma, tamanho e intensidade, ou também estar relacionado com o uso da técnica de *data augmentation*.

A Figura 4.2 ilustra a curva de desempenho do modelo, utilizando a métrica IoU ao longo das épocas. O IoU, uma métrica utilizada para avaliar a precisão das predições em tarefas de segmentação, apresentou uma tendência ascendente. Isso indica uma melhoria na concordância entre as predições do modelo e a verdade de campo. Contudo, semelhante ao observado na curva de aprendizado, há flutuações no IoU, o que evidencia os desafios inerentes na detecção de manchas de óleo.




Figura 4.1 – Curva de aprendizado do treinamento do modelo de detecção de manchas de óleo. (Gráfico da perda de treinamento e validação em função do número de épocas para o modelo de detecção de manchas de óleo).

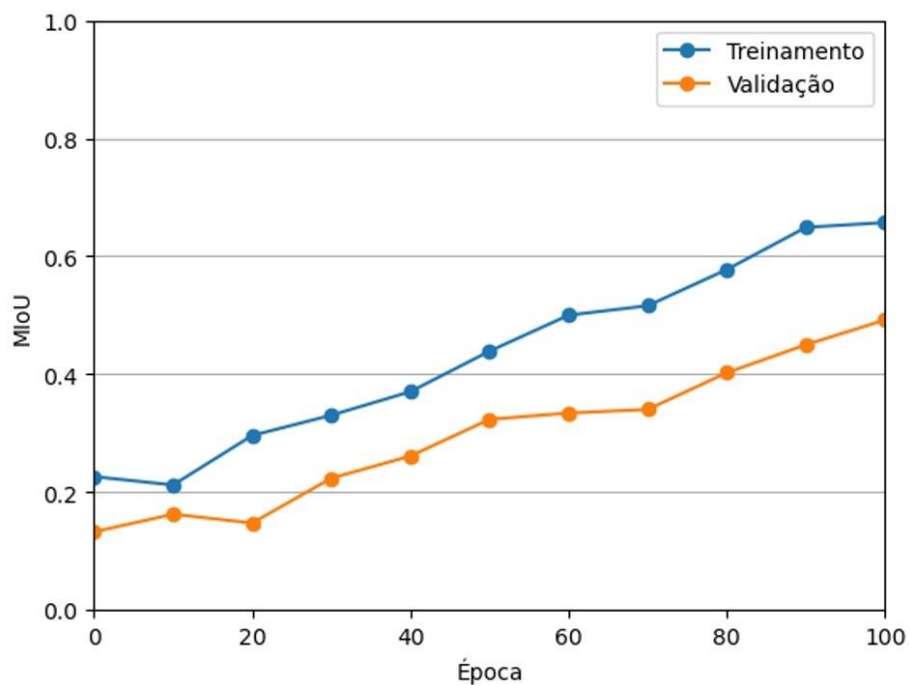


Figura 4.2 – Curva de desempenho do treinamento do modelo de detecção de manchas de óleo. (Gráfico do IoU em função do número de épocas para o modelo de detecção de manchas de óleo)

4.1.2 Modelo de embarcações

Os resultados obtidos no treinamento do modelo de detecção de embarcações mostraram uma performance comparável àquela do modelo de detecção de manchas de óleo. A análise das curvas de aprendizado, conforme ilustrado na Figura 4.3, revelou uma diminuição consistente da perda nos conjuntos de treinamento e validação ao longo das épocas, de maneira similar ao observado no treinamento para detecção de manchas de óleo. Esse padrão indica que o modelo está aprendendo e se ajustando adequadamente aos dados, embora apresente certas dificuldades, possivelmente devido à ocorrência de falsos positivos.

A uniformidade e consistência das características das embarcações, tais como formato, tamanho e orientação, representam uma vantagem que pode levar a melhores resultados na detecção, em comparação com as manchas de óleo, que apresentam maior variabilidade e padrões menos previsíveis. Além disso, as embarcações, sendo objetos com estruturas definidas, tendem a possuir contornos e características mais distintos, facilitando a identificação pelo modelo. No entanto, na segmentação de imagens, embarcações podem ser confundidas com elementos como pequenas ilhas ou partes de continentes, entre outros objetos na superfície oceânica.

A Figura 4.4, por sua vez, destaca a curva de desempenho do modelo utilizando a métrica IoU ao longo das épocas. O IoU mostrou uma evolução positiva e sutilmente melhor do que a observada para a detecção de manchas de óleo. Isso reforça a ideia de que a tarefa de detecção de embarcações, embora desafiadora, pode ser mais simplificada do que as manchas de óleo.

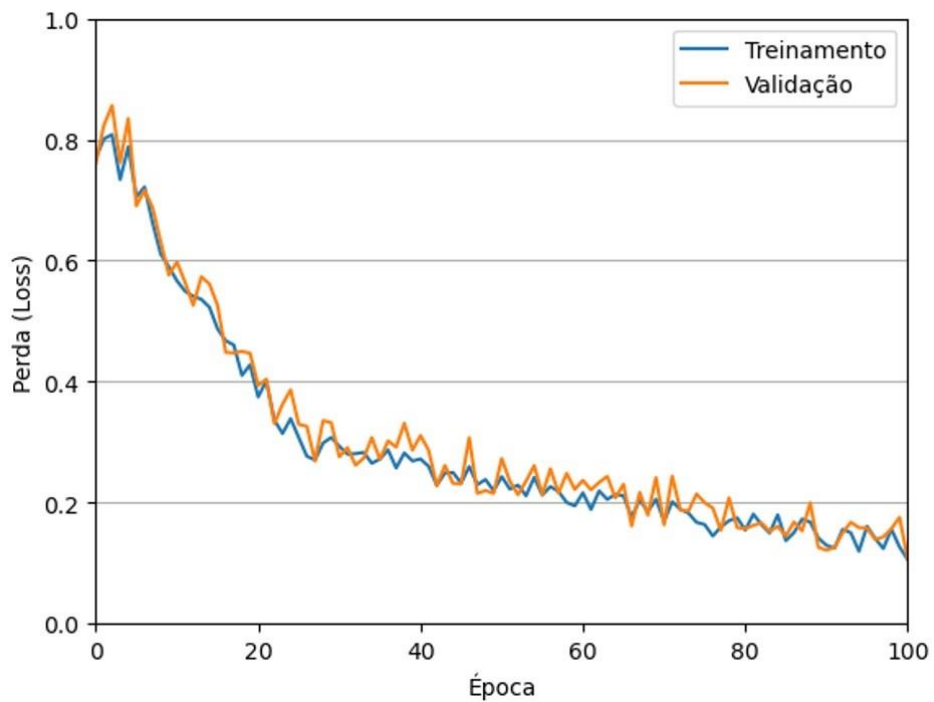


Figura 4.3 – Curva de aprendizado do treinamento do modelo de detecção de embarcações. (Gráfico da perda de treinamento e validação em função do número de épocas para o modelo de detecção de manchas de óleo)

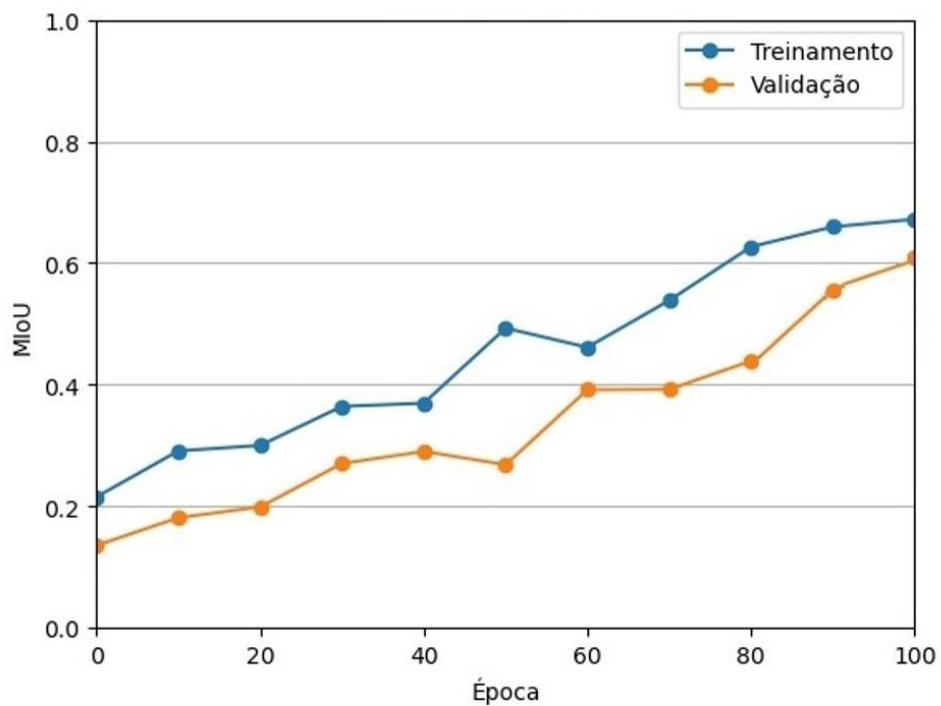


Figura 4.4 – Curva de desempenho do treinamento do modelo de detecção de embarcações. (Gráfico da IoU em função do número de épocas para o modelo de detecção de manchas de óleo)

4.2 Resultados da aplicação prática do algoritmo

Os resultados oriundos da aplicação do algoritmo de detecção de manchas de óleo (Fase 1) e embarcações (Fase 2) são apresentados em dois formatos distintos de imagens. Primeiramente no formato probabilístico, no qual as detecções são representadas por uma escala cromática que indica a probabilidade de identificação dos alvos. Nesta escala, a cor azul simboliza a menor probabilidade, progredindo em intensidade através de tons de azul, verde e amarelo, culminando na cor vermelha, que denota a maior probabilidade. Posteriormente, os resultados são exibidos em formato binário: regiões com probabilidade superior a 90% de identificação de óleo ou embarcação são destacadas em vermelho, enquanto as demais áreas são representadas em azul.

Na Figura 4.5, encontram-se os resultados referentes a todas as imagens SAR empregadas na aplicação prática (conforme Figura 3.5), no formato probabilístico. A Figura 4.6 ilustra os resultados no formato binário para a Fase 1. Por fim a Figura 4.7 é a representação dos resultados após a Fase 2 (detecção de embarcações) nos formatos probabilístico e binário.

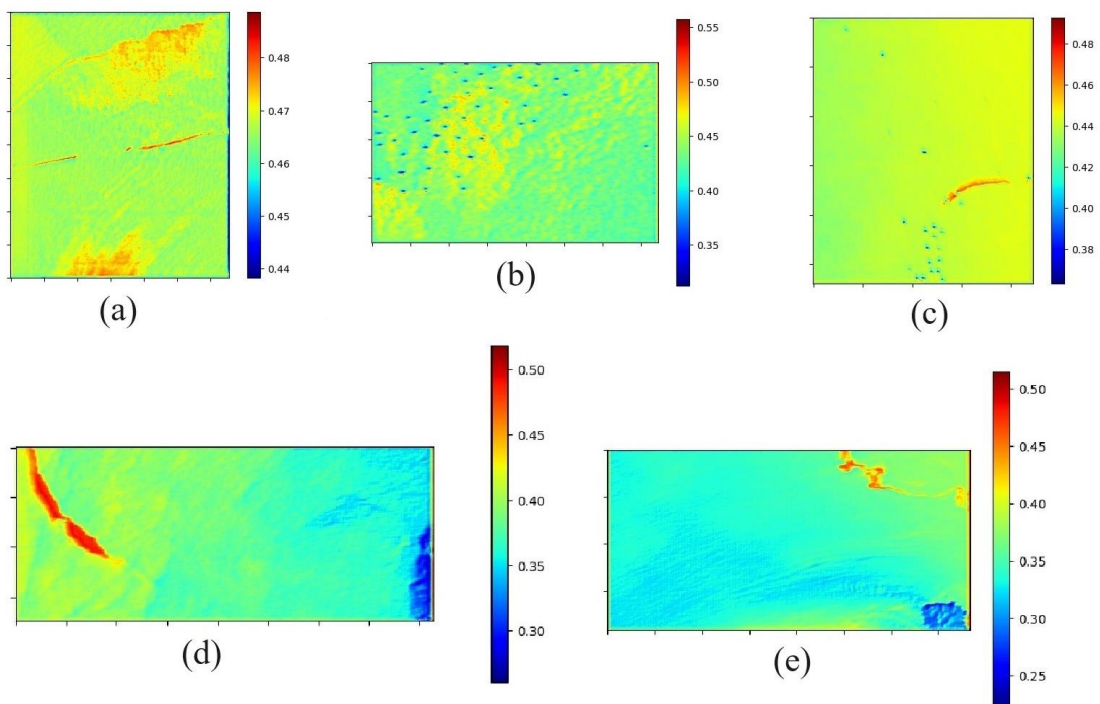


Figura 4.5 – Representação dos resultados após a Fase 1 (detecção de manchas de óleo) no formato probabilístico. As áreas em tons de vermelho indicam maior probabilidade de presença de manchas de óleo, enquanto as regiões em azul sugerem menor probabilidade.




Figura 4.6 – Representação dos resultados após a Fase 1 (detecção de manchas de óleo) no formato binário, destacando apenas as detecções com probabilidade superior a 90%. As áreas em vermelho correspondem às manchas de óleo identificadas pelo modelo, enquanto as regiões em azul indicam áreas não detectadas como manchas. Observa-se que somente nas imagens (a), (c), (d) e (e) houve a identificação de manchas de óleo.

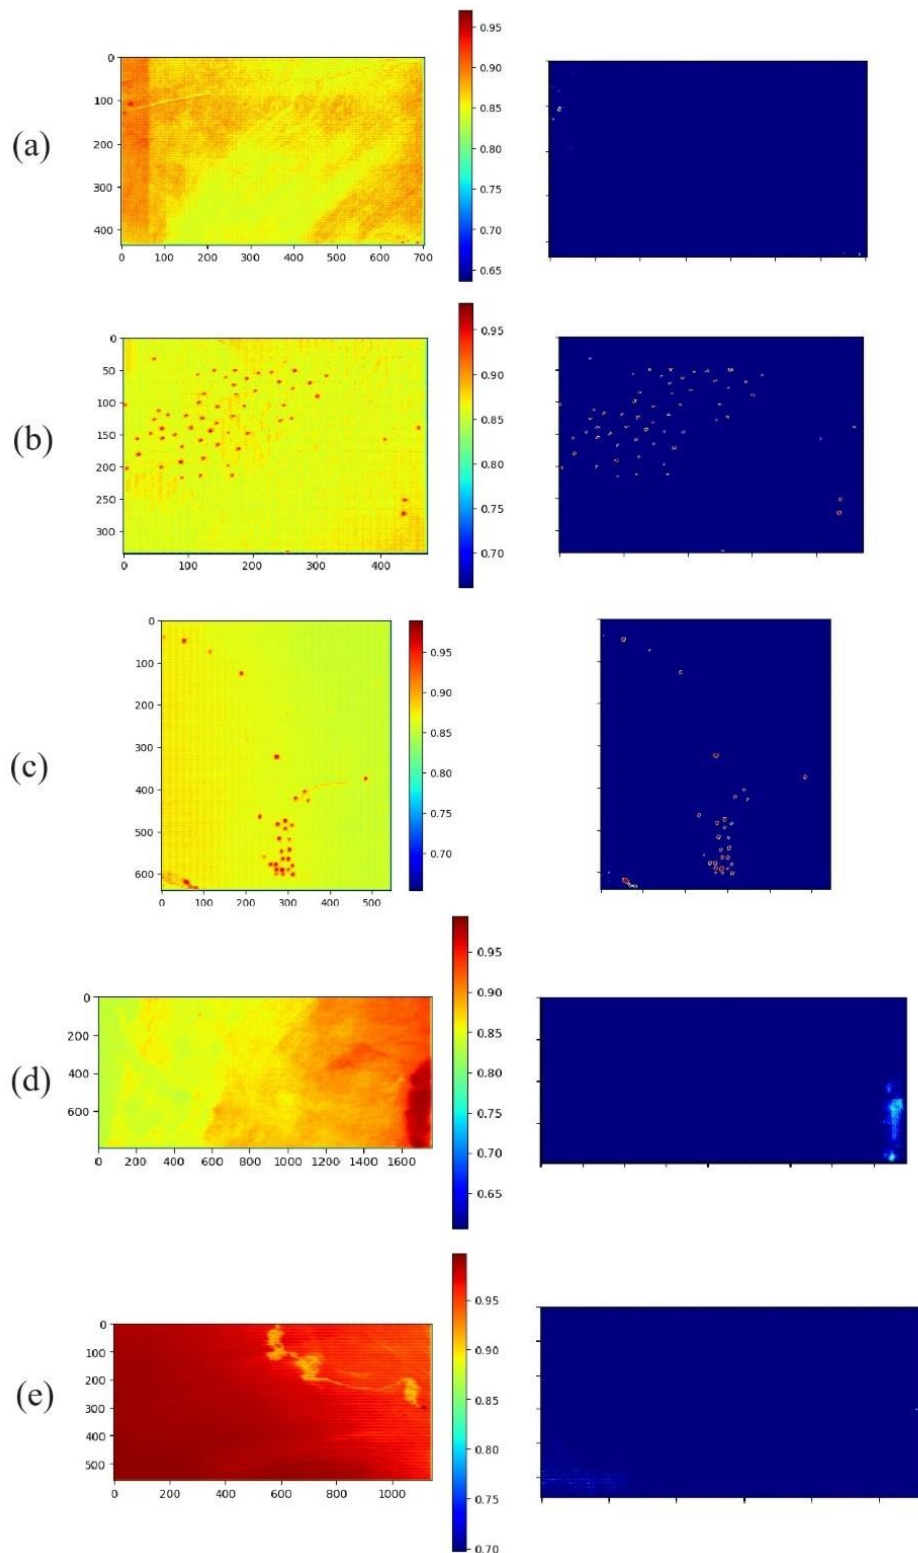


Figura 4.7 – Representação dos resultados após a Fase 2 (detecção de embarcações) nos formatos probabilístico e binário. Observa-se que somente nas imagens (a), (b), (c) houve a identificação clara de embarcações. Na imagem (e) a detecção ocorreu de maneira menos intensa, e na imagem (d) nada foi identificado.

4.3 Discussão sobre os Treinamentos

Ao analisar e comparar os resultados dos treinamentos dos modelos, especialmente em relação às métricas, observa-se que o modelo de detecção de embarcações exibiu um desempenho ligeiramente superior. Esta vantagem pode ser atribuída à natureza mais estruturada e uniforme das embarcações, em contraste com a variabilidade e complexidade das manchas de óleo. As manchas de óleo, com suas formas, tamanhos e intensidades variados, representam um desafio maior para a rede. Isso fica evidente nas flutuações observadas tanto nas curvas de aprendizado quanto na métrica IoU, indicando a complexidade da tarefa de detectar e segmentar essas manchas.

Por outro lado, as embarcações, com contornos mais distintos e características consistentes, apresentam-se como alvos mais "amigáveis" para a rede, possibilitando resultados de desempenho mais consistentes.

Uma alteração realizada na rede U-Net original, foi a definição da função de perda “*BCE with Logits Loss*”, que se mostrou mais adequada e possibilitou ao modelo produzir segmentações que se aproximaram da verdade de campo, obtendo resultados melhores que algumas referências (KRESTENITIS *et al.*, 2019; SHABAN *et al.*, 2021) demonstrados na Tabela 4.2.

Os modelos demonstraram um desempenho encorajador, refletido pelas métricas finais de precisão, acurácia, IoU, e nos resultados práticos obtidos que serão apresentados na Subseção seguinte.

4.4 Discussão sobre a aplicação prática dos algoritmos

A estratégia metodológica adotada, que consiste em primeiramente detectar manchas de óleo e, em seguida, identificar embarcações, com uso de duas redes treinadas separadamente, uma para cada alvo, resulta em uma otimização e economia de recursos computacionais em comparação com uma abordagem que utiliza uma única rede neural para identificar ambos os alvos simultaneamente. Durante a fase de implementação e teste da rede, notou-se uma complexidade e dificuldade aumentadas nos treinamentos que visavam detectar ambos os alvos. Especificamente, a incidência de *overfitting* foi mais frequente nesse cenário, indicando um aprendizado excessivo das peculiaridades dos dados de treinamento em detrimento da capacidade de generalização. Uma das possíveis causas pode estar no balanceamento das classes utilizadas.

Por outro lado, ao focar o treinamento em um único alvo por vez apresentou resultados mais promissores. Além disso, ao direcionar a detecção de embarcações exclusivamente para imagens que já demonstravam sinais de derramamentos de óleo, a metodologia evitou o processamento desnecessário de imagens sem relevância para o objetivo da pesquisa, maximizando assim a eficiência e a eficácia do estudo. Essa abordagem demonstrou não apenas ser eficiente em termos computacionais, mas também mais efetiva na obtenção de resultados para aplicações práticas no monitoramento ambiental marítimo.

A aplicação prática do algoritmo nas 5 imagens SAR analisadas obteve bons resultados. A detecção de manchas de óleo (Fase 1) acusou a presença em todas as imagens, com exceção da imagem (b). Nessa imagem é possível verificar que o efeito causado pelos falsos positivos sensibilizou o modelo, gerando resultados com média chance de probabilidade (tons amarelos e alaranjados), mas após gerar o produto binário, não ficou caracterizado como manchas de óleo. Na imagem (a) ocorreu uma sensibilização um pouco mais acentuada de regiões ao norte e sul da imagem, indicando a presença de mancha de óleo que também não ficou caracterizado na imagem binária. Nota-se que nesta imagem, a mancha de óleo localizada ao centro obteve resultado probabilístico maior que as regiões de falsos positivos. Nas demais imagens, a detecção de manchas de óleo comportou-se de maneira esperada, indicando as manchas de óleo presentes corretamente.

Na sequência, todas as 5 imagens foram analisadas pelo modelo de embarcações (Fase 2) para fins didáticos, até mesmo a imagem (b) que não acusou mancha de óleo. Os resultados desta fase, indicaram a presença de embarcações nas imagens (a), (b), (c) e de maneira menos intensa, de uma única embarcação na imagem (e). Observa-se que nas 3 primeiras imagens, as embarcações foram detectadas claramente, com bom resultado visual, sendo possível obter até o número de alvos em cada imagem. Na imagem (d), não foi detectado nenhum alvo, agindo de maneira correta.

Os desfechos obtidos corroboram a robustez do algoritmo de identificação de derramamentos de óleo, propondo uma metodologia ágil e acurada para a supervisão dessas ocorrências.

4.5 Discussão sobre a comparação dos resultados obtidos com algoritmos de Referência

Nesta subseção, realizamos uma comparação dos resultados obtidos pelo nosso modelo de detecção de manchas de óleo com os achados de estudos anteriores que serviram

como referências para este trabalho, especificamente os conduzidos por Krestenitis *et al.* (2019) e Shaban *et al.* (2021). A Tabela 4.2 apresenta os principais resultados obtidos de forma a comparar com os resultados.

Tabela 4.2 – Comparação dos resultados do modelo de manchas de óleo do método proposto com U-Net original e com trabalhos de referência utilizando arquitetura U-Net.

Métrica	Método Proposto	U-Net (este trabalho)	Krestenitis <i>et al.</i>, 2019	Shaban <i>et al.</i>, 2021
Acurácia	94,35%	91,52%	nd	92%
Precisão	86,85%	83,47%	nd	84%
IoU	67,51%	64,68%	64,97%	nd

*nd = dados não disponíveis

Os resultados comparativos apresentados na Tabela 4.2, demonstram que a abordagem realizada neste trabalho, juntamente com as modificações da rede, proporcionou resultados sensivelmente melhores em comparação com alguns trabalhos que utilizam a mesma arquitetura como base para a detecção de manchas de óleo. A utilização de rede neural convolucional U-Net, permitiu que o modelo aprendesse de forma automática os atributos relevantes das imagens, sem a necessidade de extrair manualmente esses atributos. Isso reduz a dependência de características específicas do domínio e simplifica o processo de treinamento e implementação do sistema de detecção. As modificações implementadas, dentre elas, os ajustes dos hiperparâmetros, proporcionaram melhores resultados, juntamente com o uso de código de índice de probabilidades na predição.

No que diz respeito ao modelo de detecção de embarcações, treinado separadamente neste estudo e utilizando a mesma arquitetura U-Net modificada empregada no treinamento do modelo de manchas de óleo, observou-se que os resultados alcançados superaram aqueles reportados por Krestenitis *et al.* (2019), conforme evidenciado na Tabela 4.3.

Tabela 4.3 – Comparação dos resultados do modelo de embarcações do método proposto com U-Net original e com trabalhos de referência utilizando arquitetura U-Net.

Métrica	Método Proposto	U-Net (este trabalho)	Krestenitis <i>et al.</i>, 2019
Acurácia	99,12%	84,94%	nd
Precisão	89,49%	71,39%	nd
IoU	76,23%	49,04%	44,93%

*nd = dados não disponíveis

Embora o uso da U-Net para detecção de embarcações não seja tão comum, visto que se trata de uma rede originalmente destinada à segmentação semântica e não especificamente à detecção de objetos (como as redes YOLO - *You Only Look Once*, SSD - *Single Shot Multibox Detector*, e Faster R-CNN - *Faster Regions with Convolutional Neural Network*), os resultados obtidos mostram-se promissores e podem contribuir positivamente para o aprimoramento de sistemas de monitoramento e detecção.

5 Conclusão e Trabalhos Futuros

Na presente dissertação, desenvolveu-se e avaliou-se um algoritmo de detecção de derramamentos de óleo e embarcações utilizando uma abordagem sequencial e baseada em CNN, mais precisamente na arquitetura U-Net, numa versão modificada exclusivamente para este trabalho. Os resultados alcançados para os dados utilizados, detalhados na Seção de Resultados, demonstram um desempenho eficaz e acurado na detecção dos alvos de interesse, comprovando a viabilidade do sistema em fornecer índices de probabilidades para cada alvo detectado nas imagens SAR.

A escolha da arquitetura U-Net, fundamentada em sua eficiência em problemas de segmentação de imagens (RONNEBERGER *et al*, 2015), permitiu a aprendizagem de características em diferentes escalas espaciais. Essa abordagem obteve bons resultados na detecção tanto de manchas de óleo quanto de embarcações.

A especialização das tarefas, com modelos distintos para a detecção de manchas de óleo e embarcações, revelou-se uma boa estratégia, onde cada modelo tornou-se especializado em sua respectiva tarefa, minimizando possíveis confusões de classe e maximizando a capacidade de aprendizado e generalização a partir dos padrões únicos presentes em cada classe de imagem. A sistemática de detecção sequencial, priorizando a detecção de manchas de óleo seguida pela identificação de embarcações, reduziu o custo computacional e o tempo necessário para detecções não essenciais ao objetivo da pesquisa. A flexibilidade do algoritmo desenvolvido permite futuras adaptações para detecções isoladas ou em ordem inversa, com ajustes mínimos no código.

Para futuras direções de pesquisa, sugere-se a exploração de melhorias na rede e nos hiperparâmetros, a ampliação dos conjuntos de dados e a utilização de técnicas de aumento de dados. A avaliação de outras arquiteturas de redes neurais e a integração de métodos de detecção de mudanças para identificar alvos de interesse apresentam-se como oportunidades valiosas. A qualidade e a anotação dos dados de treinamento são fundamentais para o sucesso das técnicas de *Deep Learning* em imagens SAR. A integração de dados multimodais e multiescala, como dados ópticos de satélite e informações oceanográficas, pode aprimorar a precisão dos modelos de *Deep Learning* e reduzir falsos positivos. A combinação de dados SAR de diferentes resoluções espaciais e temporais é uma abordagem promissora para o rastreamento de manchas de óleo ao longo do tempo.

Em conclusão, o sistema de detecção de derramamentos de óleo proposto neste estudo, demonstrou ser uma ferramenta eficiente, alcançando bons resultados, que poderão auxiliar na tomada de decisões e mitigação de possíveis acidentes ambientais. A especialização de tarefas, o aprendizado automático de atributos e a utilização eficiente dos recursos computacionais resultam num algoritmo robusto e eficaz, que não substituirá por completo a análise humana qualificada, mas que poderá contribuir significativamente para o monitoramento marítimo e auxiliar na identificação de eventos ambientais relacionais e de possíveis infratores.

6 Referências

- ADIL, M.; BUONO, A.; NUNZIATA, F.; FERRENTINO, E.; VELOTTO, D.; MIGLIACCIO, M. On the Effects of the Incidence Angle on the L-Band Multi-Polarisation Scattering of a Small Ship. **Remote Sensing**, v. 14, n. 22, p. 5813, 2022.
- AHMADI, H.; P., Emrah. Fault-based geological lineaments extraction using remote sensing and GIS—a review. **Geosciences**, v. 11, n. 5, p. 183, 2021.
- ANUSHA, N.; BHARATHI, B. Change detection and flood water mapping using sentinel-1A synthetic aperture radar images. **Journal of Computational and Theoretical Nanoscience**, v. 16, n. 8, p. 3544-3549, 2019.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE transactions on pattern analysis and machine intelligence**, v. 39, n. 12, p. 2481-2495, 2017.
- BBC BRASIL. **Novos dados indicam que vazamento da BP foi o maior da história**. 2010. https://www.bbc.com/portuguese/noticias/2010/08/100802_vazamento_bp_ac. Acessado em 19 setembro de 2023.
- BBC NEWS. **South China Sea: Why is it strategically important?**. 2023. <https://www.bbc.com/news/world-asia-pacific-13748349>. Acessado em 10 setembro de 2023.
- BELLOUL, M. B.; THORPE, S. A. Acoustic observation of oil slicks at sea. **Journal of Geophysical Research: Oceans**, v. 97, n. C4, p. 5215-5220, 1992.
- BOERNER, W. M. Basics of sar polarimetry i. **Radar Polarimetry and Interferometry. Educational Notes RTO-EN-SET-081bis, Paper**, v. 3, p. 3-40, 2007.
- BRUSCH, S.; LEHNER, S.; FRITZ, T.; SOCCORSI, M.; SOLOVIEV, A.; VAN SCHIE, B. Ship surveillance with TerraSAR-X. **IEEE transactions on geoscience and remote sensing**, v. 49, n. 3, p. 1092-1103, 2010.
- CANTORNA, D.; DAFONTE, C.; IGLESIAS, A.; ARCA Y B. Oil spill segmentation in SAR images using convolutional neural networks. A comparative analysis with clustering and logistic regression algorithms. **Applied Soft Computing**, v. 84, p. 105716, 2019.
- CHEN, L. C.; ZHU, Y.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: **Proceedings of the European conference on computer vision (ECCV)**. 2018. p. 801-818.
- CHEN, Shiyuan; LI, Xiaojiang. A new CFAR algorithm based on variable window for ship target detection in SAR images. **Signal, Image and Video Processing**, v. 13, n. 4, p. 779-786, 2019.

CHEN, Y.; WANG, Z. Marine oil spill detection from SAR images based on attention U-Net model using polarimetric and wind speed information. **International Journal of Environmental Research and Public Health**, v. 19, n. 19, p. 12315, 2022.

CHOI, H.; JEONG, J. Speckle noise reduction technique for SAR images using statistical characteristics of speckle noise and discrete wavelet transform. **Remote Sensing**, v. 11, n. 10, p. 1184, 2019.

CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE transactions on geoscience and remote sensing**, v. 34, n. 2, p. 498-518, 1996.

COLE, M.; LINDEQUE, P.; HALSBAND, C.; GALLOWAY, T. S. Microplastics as contaminants in the marine environment: a review. **Marine pollution bulletin**, v. 62, n. 12, p. 2588-2597, 2011.

CONCEIÇÃO, M. R. A.; DE MENDONÇA, L. F. F.; LENTINI, C. A. D.; DA CUNHA LIMA, A. T.; LOPES, J. M.; DE VANCONCELOS, R. N *et al.* SAR oil Spill detection system through random forest classifiers. **Remote Sensing**, v. 13, n. 11, p. 2044, 2021.

CRISP, D. J. **The state-of-the-art in ship detection in synthetic aperture radar imagery**. 2004.

DA FONSECA, I. L.; OLIVEIRA, W. A. Desastres socioambientais, turismo e resiliência: reflexões sobre o vazamento de óleo na costa do Nordeste do Brasil. **Revista Turismo em Análise**, v. 32, n. 1, p. 120-140, 2021.

DAVIDSON, M.; ATTEMA, E.; SNOEIJ, P; LEVRINI, G. Sentinel-1 Mission Overview and Implementation Status. In: **EGU General Assembly Conference Abstracts**. 2009. p. 13447.

DDS ONLINE. **DDS Amazônia Azul**. 2023. <https://www.ddsonline.com.br/meio-ambiente/dds-amazonia-azul>. Acessado em 19 Setembro de 2023.

DEL FRATE, F; PETROCCHI, A; LICHTENEGGER, J; CALABRESI, G. Neural networks for oil spill detection using ERS-SAR data. **IEEE Transactions on geoscience and remote sensing**, v. 38, n. 5, p. 2282-2287, 2000.

DE MORAES, E. C. **Capítulo 1 fundamentos de sensoriamento remoto**. 2002.

DUTRA, L. V.; MURA, J. C.; FREITAS, C. D. C.; SANTOS, J. D.; ELMIRO, M. T. Processamento de imagens de radar de abertura sintética—princípios e aplicações. In: **Anais do iv workshop em tratamento de imagens, npdi/dcc/icex/ufmg**. 2003.

DYBDAL, R. B. Radar cross section measurements. **Proceedings of the IEEE**, v. 75, n. 4, p. 498-516, 1987.

EL HAJJ, M.; BAGHDADI, N.; ZRIBI, M.; ANGELLIAUME, S. Analysis of Sentinel-1 radiometric stability and quality for land surface applications. **Remote Sensing**, v. 8, n. 5, p. 406, 2016.

ENCYCLOPAEDIA BRITANNICA. **Exxon Valdez oil spill**. 2023.
<https://www.britannica.com/event/Exxon-Valdez-oil-spill>. Acessado em 19 setembro de 2023.

EUROPEAN SPACE AGENCY. **Sentinel-1**. Paris: ESA, 2023. 2023.
<https://sentinel.esa.int/web/sentinel/missions/sentinel-1>. Acessado em 06 junho de 2023.

EUROPEAN SPACE AGENCY. **Sentinel online**. Paris: ESA, 2023. 2023.
<https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-1-sar/products-algorithms/level-1-algorithms/ground-range-detected>. Acessado em 06 julho de 2023.

FALQUETO, L. E.; SÁ, J. A.; PAES, R. L.; PASSARO, A. Oil rig recognition using convolutional neural network on Sentinel-1 SAR images. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 8, p. 1329-1333, 2019.

FALQUETO, L. E. Reconhecimento de alvos artificiais em ambientes complexos por meio de imagens SAR polarimétricas obtidas por plataformas orbitais. Realização de **Instituto Tecnológico de Aeronáutica. Divisão de Ciências e Tecnologias Espaciais**. São José dos Campos: ITA, 2019. 133 p. (DCTA/ITA/DM-055/2019). Disponível em:
http://www.bdita.bibl.ita.br/tesesdigitais/lista_resumo.php?num_tese=76087. Acesso em: 18 jun. 2023.

FAN, Q.; CHEN, F.; CHENG, M.; LOU, S.; XIAO, R.; ZHANG, B. *et al.* Ship detection using a fully convolutional network with compact polarimetric SAR images. **Remote Sensing**, v. 11, n. 18, p. 2171, 2019.

FAZCOMEX. **Exportações no Brasil**. 2023.
<https://www.fazcomex.com.br/exportacao/exportacoes-no-brasil/>. Acessado em 19 setembro de 2023.

FAZCOMEX. **Principais Portos da América Latina**. 2023.
<https://www.fazcomex.com.br/comex/portos-da-america-latina/>. Acessado em 19 setembro de 2023.

FINGAS, M.; BROWN, C. E. A review of oil spill remote sensing. **sensors**, v. 18, n. 1, p. 91, 2017.

FREEMAN, A.; DURDEN, S. L. Three-component scattering model to describe polarimetric SAR data. In: **Radar Polarimetry**. SPIE, 1993. p. 213-224.

GAO, F.; HUANG, T.; SUN, J.; WANG, J.; HUSSAIN, A.; YANG, E. A new algorithm for SAR image target recognition based on an improved deep convolutional neural network. **Cognitive Computation**, v. 11, p. 809-824, 2019.

GARCIA-GARCIA, A.; ORTS-ESCOLANO, S.; OPREA, S.; VILLENA-MARTINEZ, V.; GARCIA-RODRIGUEZ, J. A review on deep learning techniques applied to semantic segmentation. **arXiv preprint arXiv:1704.06857**, 2017.

GEMME, L.; DELLEPIANE, S.; VERNAZZA, G. Azimuth ambiguity spatial correlation composite (ASCC): A novel method for ghost enhancement in SAR images. In: **OCEANS 2015-Genova**. IEEE, 2015. p. 1-5.

GEUDTNER, D.; GEBERT, N.; TOSSAINT, M.; DAVIDSON, M.; HELIERE, F.; TRAVER, I. N. *et al.* Copernicus and ESA SAR missions. In: **2021 IEEE Radar Conference (RadarConf21)**. IEEE, 2021. p. 1-6.

GIRARD-ARDHUIN, F.; MERCIER, G.; COLLARD, F.; GARELLO, R. Operational oil-slick characterization by SAR imagery and synergistic data. **IEEE Journal of Oceanic Engineering**, v. 30, n. 3, p. 487-495, 2005.

GOMES, V.; SALDANHA-CORRÊA, F. A vida no mar. Noções de Oceanografia. São Paulo: **Instituto Oceanográfico**, p. 427-446, 2021.

GOODFELLOW, .I; BENGIO, Y.; COURVILLE, A. **Deep learning**. MIT press, 2016.

HE, K.; ZHANG, X.; REN, S; SUN, J. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 770-778.

HUANG, Z.; PAN, Z.; LEI, B. Transfer learning with deep convolutional neural network for SAR target classification with limited labeled data. **Remote sensing**, v. 9, n. 9, p. 907, 2017.

ISHII, S.; SAYAMA, S.; MIZUTANI, K. **Effect of changes in sea-surface state on statistical characteristics of sea clutter with X-band radar**. 2011.

ISLAM, T.; RICO-RAMIREZ, M. A. An overview of the remote sensing of precipitation with polarimetric radar. **Progress in Physical Geography**, v. 38, n. 1, p. 55-78, 2014.

JACKSON, C. R.; APEL, J. R. **Synthetic aperture radar: marine user's manual**. 2004.

JENSEN, K.; MCDONALD, K.; PODEST, E.; RODRIGUEZ-ALVAREZ, N.; HORNA, V.; STEINER, N. Assessing L-band GNSS-reflectometry and imaging radar for detecting sub-canopy inundation dynamics in a tropical wetlands complex. **Remote Sensing**, v. 10, n. 9, p. 1431, 2018.

KASISCHKE, E. S.; MELACK, J. M.; DOBSON, M. Craig. The use of imaging radars for ecological applications—A review. **Remote sensing of environment**, v. 59, n. 2, p. 141-156, 1997.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.

KLUYVER, T.; RAGAN-KELLEY, B.; PÉREZ, F.; GRANGER, B. E.; BUSSONNIER, M.; FREDERIC, J. *et al.* Jupyter Notebooks—a publishing format for reproducible computational workflows. **Elpub**, v. 2016, p. 87-90, 2016.

KRESTENITIS, M.; ORFANIDIS, G.; IOANNIDIS, K.; AVGERINAKIS, K.; VROCHIDIS, S.; KOMPATSIARIS, I. Oil spill identification from satellite images using deep neural networks. **Remote Sensing**, v. 11, n. 15, p. 1762, 2019.

- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, 2012.
- KUBAT, M.; KUBAT, M. The genetic algorithm. **An Introduction to Machine Learning**, p. 309-329, 2017.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278-2324, 1998.
- LEE, J. S.; POTTIER, E. **Polarimetric radar imaging: from basics to applications**. CRC press, 2017.
- LE, P. B.; NGUYEN, Z. T. ROC curves, loss functions, and distorted probabilities in binary classification. **Mathematics**, v. 10, n. 9, p. 1410, 2022.
- LI, J.; GUO, C.; GOU, S.; CHEN, Y.; WANG, M.; CHEN, J. W. Ship segmentation on high-resolution SAR image by a 3D dilated multiscale U-Net. In: **IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2020. p. 2575-2578.
- LI, J.; XU, C.; SU, H.; GAO, L.; WANG, T. Deep learning for SAR ship detection: Past, present and future. **Remote Sensing**, v. 14, n. 11, p. 2712, 2022.
- LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation**. John Wiley & Sons, 2015.
- LIN, H.; SONG, S.; YANG, J. Ship classification based on MSHOG feature and task-driven dictionary learning with structured incoherent constraints in SAR images. **Remote Sensing**, v. 10, n. 2, p. 190, 2018.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2015. p. 3431-3440.
- LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. Editora Blucher, 2015.
- MAHMOUD, A. S.; MOHAMED, S. A.; EL-KHORIBY, R. A.; ABDELSALAM, H. M.; EL-KHODARY, I. A. Oil Spill Identification based on Dual Attention UNet Model Using Synthetic Aperture Radar Images. **Journal of the Indian Society of Remote Sensing**, v. 51, n. 1, p. 121-133, 2023.
- MAO, Y.; YANG, Y.; MA, Z.; LI, M.; SU, H.; ZHANG, J. Efficient low-cost ship detection for SAR imagery based on simplified U-net. **IEEE Access**, v. 8, p. 69742-69753, 2020.
- MARINHA DO BRASIL. **Comissão Interministerial para os Recursos do Mar**. Amazonia Azul. Brasília, DF: SECIRM. 2022. <https://www.marinha.mil.br/secirm/amazoniaazul>. Acessado em 30 junho de 2023.
- MARINHA DO BRASIL. **O que é Amazônia Azul e por que o Brasil quer se tornar potência militar no Atlântico**. 2019. <https://www.marinha.mil.br/economia-azul/noticias/o->

que-%C3%A9-amaz%C3%B4nia-azul-e-por-que-o-brasil-quer-se-tornar-pot%C3%Aancia-militar-no-atl%C3%A2ntico. Acessado em 19 setembro de 2023.

MARINO, A.; VELOTTO, D.; NUNZIATA, F. Offshore metallic platforms observation using dual-polarimetric TS-X/TD-X satellite imagery: A case study in the Gulf of Mexico. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 10, p. 4376-4386, 2017.

MARQUES, C. **Navios fantasmas na Amazônia Azul: controle e mitigação**. 2020.

MOREIRA, A.; PRATS-IRAOLA, P.; YOUNIS, M.; KRIEGER, G.; HAJNSEK, I.; PAPATHANASSIOU, K. P. A tutorial on synthetic aperture radar. **IEEE Geoscience and remote sensing magazine**, v. 1, n. 1, p. 6-43, 2013.

NEWMAN, S.; WATKINS, E.; FARMER, A.; BRINK, P. T.; SCHWEITZER, J. P. The economics of marine litter. **Marine anthropogenic litter**, p. 367-394, 2015.

NGUYEN, G.; DLUGOLINSKY, S.; BOBÁK, M.; TRAN, V.; LÓPEZ GARCÍA, Á.; HEREDIA, I. *et al.* Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. **Artificial Intelligence Review**, v. 52, p. 77-124, 2019.

NIETO-HIDALGO, M.; GALLEGO, A. J.; GIL, P.; PERTUSA, A. Two-stage convolutional neural network for ship and spill detection using SLAR images. **IEEE Transactions on geoscience and remote sensing**, v. 56, n. 9, p. 5217-5230, 2018.

OGBUKA, J. C.; NWABMUOH, E. E.; OGBO, A. I.; ACHORU, F. E. Offshore oil spill response base and management of deepwater/offshore oil resources in the Nigerian marine waters: a review. **International Journal of Environmental Impacts**, v. 5, n. 1, p. 65-81, 2022.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Os oceanos cobrem mais de 70% da superfície do planeta**. 2022. <https://brasil.un.org/pt-br/185272-os-oceanos-cobrem-mais-de-70-da-superf%C3%ADcie-do-planeta>. Acessado em 19 setembro de 2023.

OUCHI, K. Recent trend and advance of synthetic aperture radar with selected topics. **Remote Sensing**, v. 5, n. 2, p. 716-807, 2013.

PAES, R. L.; LORENZZETTI, J. A.; GHERARDI, D. F. M. **Deteção de alvos na superfície do mar em imagens SAR orbitais: verificação de conceitos**.

PASZKE, A.; GROSS, S.; MASSA, F.; LERER, A.; BRADBURY, J.; CHANAN, G. *et al.* Pytorch: An imperative style, high-performance deep learning library. **Advances in neural information processing systems**, v. 32, 2019.

PATTON, D. M.; HENNING, E. N.; GOULET, R. W.; CARROLL, S. K.; BIGELOW, E. M.; PROVENCHER, B. *et al.* Deep learning-based segmentation of high-resolution computed tomography image data outperforms commonly used automatic bone segmentation methods. **bioRxiv**, p. 2021.07. 27.453890, 2021.

- PATROUMPAS, K.; ALEVIZOS, E.; ARTIKIS, A.; VODAS, M.; PELEKIS, N.; THEODORIDIS, Y. Online event recognition from moving vessel trajectories. **GeoInformatica**, v. 21, p. 389-427, 2017.
- PHIRI, D.; SIMWANDA, M.; SALEKIN, S.; NYIRENDA, V. R.; MURAYAMA, Y.; RANAGALAGE, M. Sentinel-2 data for land cover/use mapping: A review. **Remote Sensing**, v. 12, n. 14, p. 2291, 2020.
- PICCIALLI, F.; CUOMO, S.; CRISCI, D.; PREZIOSO, E.; MEI, G. A deep learning approach for facility patient attendance prediction based on medical booking data. **Scientific Reports**, v. 10, n. 1, p. 14623, 2020.
- PITSIKALIS, M.; ARTIKIS, A.; DREO, R.; RAY, C.; CAMOSSO, E.; JOUSSELME, A. L. Composite event recognition for maritime monitoring. In: **Proceedings of the 13th ACM International Conference on Distributed and Event-based Systems**. 2019. p. 163-174.
- POTIN, P.; ROSICH, B.; MIRANDA, N.; GRIMONT, P.; SHURMER, I.; O'CONNELL, A. *et al.* Copernicus Sentinel-1 constellation mission operations status. In: **IGARSS 2019-2019 IEEE international geoscience and remote sensing symposium**. IEEE, 2019. p. 5385-5388.
- POTTIER, E.; FERRO-FAMIL, L.; ALLAIN, S.; CLOUDE, S.; HAJNSEK, I.; PAPATHANASSIOU, K. *et al.* Overview of the PolSARpro V4. 0 software. The open source toolbox for polarimetric and interferometric polarimetric SAR data processing. In: **2009 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2009. p. IV-936-IV-939.
- POWERS, D. M. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. **arXiv preprint arXiv:2010.16061**, 2020.
- PRECHELT, L. Early stopping-but when?. In: **Neural Networks: Tricks of the trade**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2002. p. 55-69.
- QUAN, X.; CHOI, J. W.; CHO, S. H. A new thresholding method for ir-uwv radar-based detection applications. **Sensors**, v. 20, n. 8, p. 2314, 2020.
- RAJARAMAN, S.; FOLIO, L. R.; DIMPERIO, J.; ALDERSON, P. O.; ANTANI, S. K. Improved semantic segmentation of tuberculosis—consistent findings in chest x-rays using augmented training of modality-specific u-net models with weak localizations. **Diagnostics**, v. 11, n. 4, p. 616, 2021.
- RANE, A.; SANGILI, V. Implementation of improved ship-iceberg classifier using deep learning. **Journal of Intelligent Systems**, v. 29, n. 1, p. 1514-1522, 2019.
- RICHARDS, J. A. **Remote sensing with imaging radar**. Berlin/Heidelberg, Germany: Springer, 2009.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: **Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany,**

October 5-9, 2015, Proceedings, Part III 18. Springer International Publishing, 2015. p. 234-241.

SALIBA, M.; FRANTZI, S.; VAN BEUKERING, P. Shipping spills and plastic pollution: A review of maritime governance in the North Sea. **Marine Pollution Bulletin**, v. 181, p. 113939, 2022.

SCHMIDT, K.; SCHWERDT, M.; MIRANDA, N.; REIMANN, J. Radiometric comparison within the Sentinel-1 SAR constellation over a wide backscatter range. **Remote Sensing**, v. 12, n. 5, p. 854, 2020.

SCOULLOS, M.; FERRAGINA, E. **Environmental and sustainable development in the Mediterranean.** Barcelona: European Institute of the Mediterranean, 2010.

SHABAN, M.; SALIM, R.; ABU KHALIFEH, H.; KHELIFI, A.; SHALABY, A.; EL-MASHAD, S. *et al.* A deep-learning framework for the detection of oil spills from SAR data. **Sensors**, v. 21, n. 7, p. 2351, 2021.

SHARIFZADEH, F.; AKBARIZADEH, G.; SEIFI KAVIAN, Y. Ship classification in SAR images using a new hybrid CNN–MLP classifier. **Journal of the Indian Society of Remote Sensing**, v. 47, p. 551-562, 2019.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. **Journal of big data**, v. 6, n. 1, p. 1-48, 2019.

SIDDIQUE, N.; PAHEDING, S.; ELKIN, C. P.; DEVABHAKTUNI, V. U-net and its variants for medical image segmentation: A review of theory and applications. **IEEE Access**, v. 9, p. 82031-82057, 2021.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SOARES, M. O.; DA CRUZ LOTUFO, T. M.; VIEIRA, L. M.; SALANI, S.; HADJU, E.; MATTHEWS-CASCON, H. *et al.* Brazilian marine animal forests: a new world to discover in the Southwestern Atlantic. **Marine Animal Forests, Springer International Publishing, Cham**, p. 73-110, 2017.

SOLAN, M.; ASPDEN, R. J.; PATERSON, D. M. (Eds.). **Marine biodiversity and ecosystem functioning: frameworks, methodologies, and integration.** Oxford university press, 2012.

SOLBERG, A. H. S. Remote sensing of ocean oil-spill pollution. **Proceedings of the IEEE**, v. 100, n. 10, p. 2931-2945, 2012.

SOLDI, G.; GAGLIONE, D.; FORTI, N.; DI SIMONE, A.; DAFFINÀ, F. C.; BOTTINI, G. *et al.* Space-based global maritime surveillance. Part I: Satellite technologies. **IEEE Aerospace and Electronic Systems Magazine**, v. 36, n. 9, p. 8-28, 2021.

SUDRE, C. H.; LI, W.; VERCAUTEREN, T.; OURSELIN, S.; JORGE CARDOSO, M. Generalised dice overlap as a deep learning loss function for highly unbalanced

segmentations. In: **Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Canada, September 14, Proceedings 3**. Springer International Publishing, 2017. p. 240-248.

SULTANI, W.; CHEN, C.; SHAH, M. Real-world anomaly detection in surveillance videos. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2018. p. 6479-6488.

SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED S.; ANGUELOV, D. *et al.* Going deeper with convolutions. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2015. p. 1-9.

TOMAŠTÍK, J.; MOKROŠ, M.; SUROVÝ, P.; GRZNÁROVÁ, A.; MERGANIČ, J. UAV RTK/PPK method—an optimal solution for mapping inaccessible forested areas?. **Remote sensing**, v. 11, n. 6, p. 721, 2019.

TOMIYASU, K. Tutorial review of synthetic-aperture radar (SAR) with applications to imaging of the ocean surface. **Proceedings of the IEEE**, v. 66, n. 5, p. 563-583, 1978.

TORRES, R.; SNOEIJ, P.; GEUDTNER, D.; BIBBY, D.; DAVIDSON, M.; ATTEMA, E. *et al.* GMES Sentinel-1 mission. **Remote sensing of environment**, v. 120, p. 9-24, 2012.

ULABY, F. T.; MOORE, R. K.; FUNG, A. K. **Microwave remote sensing: Active and passive**. Volume 3-From theory to applications. 1986.

VASCONCELOS, R. N.; LIMA, A. T. C.; LENTINI, C. A.; MIRANDA, G. V.; MENDONÇA, L. F.; SILVA, M. A. *et al.* Oil spill detection and mapping: A 50-year bibliometric analysis. **Remote Sensing**, v. 12, n. 21, p. 3647, 2020.

VO, D. T.; NGUYEN, X. P.; NGUYEN, T. D.; HIDAYAT, R.; HUYNH, T. T.; NGUYEN, D. T. A review on the internet of thing (IoT) technologies in controlling ocean environment. **Energy sources, Part A: Recovery, utilization, and environmental effects**, p. 1-19, 2021.

WANG, C.; PEI, J.; WANG, Z.; HUANG, Y.; WU, J.; YANG, H.; YANG, J. When deep learning meets multi-task learning in sar atr: Simultaneous target recognition and segmentation. **Remote Sensing**, v. 12, n. 23, p. 3863, 2020.

WANG, Y.; WANG, C.; ZHANG, H. Combining a single shot multibox detector with transfer learning for ship detection using sentinel-1 SAR images. **Remote sensing letters**, v. 9, n. 8, p. 780-788, 2018.

XIAO, S.; DONG, H.; GONG, C. A CFAR detection algorithm with variable range gate. In: **International Conference on Signal Processing, Computer Networks, and Communications (SPCNC 2022)**. SPIE, 2023. p. 306-310.

XUE, K.; SINK, S.; POWER, G. J. Effects of SAR parametric variations on the performance of automatic target recognition algorithms. In: **Algorithms for Synthetic Aperture Radar Imagery X**. SPIE, 2003. p. 370-384.

YAMAGUCHI, Y.; SATO, A.; BOERNER, W. M.; SATO, R.; YAMADA, H. Four-component scattering power decomposition with rotation of coherency matrix. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 6, p. 2251-2258, 2011.

YANG, H.; CHEN, S.; XI, F.; LIU, Z. Quadrature compressive sampling SAR imaging. In: **IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2018. p. 5847-5850.

ZHOU, C.; CHAN, H. P.; HADJIISKI, L. M.; CHUGHTAI, A. Recursive training strategy for a deep learning network for segmentation of pathology nuclei with incomplete annotation. **IEEE Access**, v. 10, p. 49337-49346, 2022.

ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G. S.; ZHANG, L.; XU, F.; FRAUNDORFER, F. Deep learning in remote sensing: A comprehensive review and list of resources. **IEEE Geoscience and Remote Sensing Magazine**, v. 5, n. 4, p. 8-36, 2017.

FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO DM	2. DATA 12 de março de 2024	3. REGISTRO N° DCTA/ITA/DM-018/2024	4. N° DE PÁGINAS 97
5. TÍTULO E SUBTÍTULO: Algoritmo de aprendizado profundo para detecção de manchas de óleo e embarcações em imagens de radar de abertura sintética.			
6. AUTOR(ES): Luis Gustavo Ronsani Vito			
INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica – ITA			
8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: Monitoramento; Sensoriamento Remoto; Deep Learning.			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Radar de abertura sintética; Reconhecimento de alvo; Processamento de imagens; Sensoriamento remoto; Aprendizado (inteligência artificial); Algoritmos; Redes neurais; Engenharia eletrônica.			
10. APRESENTAÇÃO: <input checked="" type="checkbox"/> Nacional <input type="checkbox"/> Internacional ITA, São José dos Campos. Curso de Mestrado. Programa de Pós-Graduação em Ciências e Tecnologias Espaciais. Área de Sensores e Atuadores Espaciais. Orientador: Prof. Dr. Ângelo Pássaro. Defesa em 01/03/2024. Publicada em 2024.			
11. RESUMO: Esta dissertação aborda o desenvolvimento de um algoritmo para a detecção de manchas de óleo e embarcações em imagens de Radar de Abertura Sintética (SAR), utilizando uma versão modificada da rede neural U-Net, originalmente proposta por Ronneberger, Fischer e Brox (2015). Este trabalho destaca-se pelo aprimoramento da arquitetura U-Net, por meio de modificações, tais como o uso de blocos residuais, inclusão de regularização L2, adaptação da última camada convolucional, entre outras, visando melhorar os resultados dos estudos de referência no campo de detecção por meio da segmentação semântica de imagens SAR. A pesquisa abrange um conjunto de processos metodológicos, divididos em cinco etapas principais. A primeira etapa envolve a aquisição e construção de bancos de dados (dataset) de imagens SAR, fornecidas pelos satélites Sentinel-1 da Agência Espacial Europeia (ESA) contendo alvos específicos de manchas de óleo e embarcações. A segunda etapa se concentra no processamento dessas imagens SAR, um passo importante para garantir a qualidade e a precisão dos dados para os treinamentos subsequentes. A terceira etapa aborda a implementação de modificações na arquitetura U-Net. Estas alterações visam aumentar a eficácia do modelo em lidar com as complexidades inerentes à detecção de alvos em imagens SAR. A quarta etapa, envolvendo treinamentos e validações dos modelos, é feita de forma individualizada para cada tipo de alvo - manchas de óleo e embarcações. Esta abordagem garante que o algoritmo seja otimizado para identificar cada tipo de alvo de forma individualizada. A etapa final é a confecção do algoritmo de detecção, que opera de forma sequencial. Inicialmente, detecta-se as manchas de óleo e, em seguida, as embarcações, mas apenas nas imagens onde a detecção de manchas de óleo foi confirmada. Esta estratégia sequencial permite uma análise mais focada no alvo a ser detectado. Os resultados obtidos nos treinamentos foram promissores. O modelo para detecção de manchas de óleo apresentou uma Acurácia de 94%, Precisão de 86% e Índice de Jaccard (IoU) de 67,51%. O modelo para detecção de embarcações alcançou uma Acurácia de 99%, Precisão de 89% e IoU de 76,23%. Estes resultados superam algumas abordagens de referência anteriores que fizeram o uso da arquitetura U-Net, como KRESTENITIS <i>et al.</i> (2019) e SHABAN <i>et al.</i> (2021), evidenciando a eficácia das modificações implementadas e da metodologia adotada. O estudo demonstra a viabilidade de combinar sensoriamento remoto SAR com inteligência artificial para enfrentar desafios ambientais contemporâneos. Sugere-se para estudos futuros a pesquisa por melhorias na rede com outras modificações e seus hiperparâmetros, ampliação dos conjuntos de dados e utilização de outras técnicas de aumento de dados, a exploração de outras arquiteturas de redes neurais para avaliar seu desempenho em comparação com a U-Net e a integração de métodos de detecção de mudanças para identificar os alvos.			
12. GRAU DE SIGILO: <input checked="" type="checkbox"/> OSTENSIVO <input type="checkbox"/> RESERVADO <input type="checkbox"/> SECRETO			