

JANAINA DE PAULA RUGGERI

**IDENTIFICAÇÃO DE MANCHAS DE ÓLEO NO MAR  
ATRAVÉS DA DETEÇÃO REMOTA**



**UNIVERSIDADE DO ALGARVE**  
Faculdade de Ciências e Tecnologia

2022

**JANAINA DE PAULA RUGGERI**

**IDENTIFICAÇÃO DE MANCHAS DE ÓLEO NO MAR  
ATRAVÉS DA DETEÇÃO REMOTA**

Dissertação

**Mestrado em Geomática**

**Trabalho efetuado sob a orientação de:  
Professora Doutora Helena Fernandez  
Professor Doutor Fernando Martins**



**UNIVERSIDADE DO ALGARVE**  
Faculdade de Ciências e Tecnologia

2022



## **Identificação de manchas de óleo no mar através da Deteção Remota**

### **Declaração de autoria de trabalho**

Declaro ser a autora deste trabalho, que é original e inédito. Autores e trabalhos consultados estão devidamente citados no texto e constam da listagem de referências incluída.

“Copyright” – Janaina de Paula Ruggeri, UALG, FCT

A Universidade do Algarve reserva para si o direito, em conformidade como disposto no Código do Direito de Autor e dos Direitos Conexos, de arquivar, reproduzir e publicar a obra, independentemente do meio utilizado, bem como de divulgar através de repositórios científicos e de admitir a sua cópia e distribuição para fins meramente educacionais ou de investigação e não comerciais, conquanto seja dado o devido crédito ao autor e editor respetivos.

A Deus,

À minha família pelo apoio  
incondicional, pela paciência,  
compreensão e amor ao longo  
desta etapa.

## **AGRADECIMENTOS**

Este trabalho foi realizado com o contributo de várias pessoas, sem o qual não teria sido possível a sua realização. Por esse motivo, manifesto o meu agradecimento e reconhecimento. Gostaria de deixar, de forma especial, o meu agradecimento a todos os docentes do Mestrado em Geomática, pela forma assumidamente competente e reconhecidamente com que transmitiram e partilharam conhecimentos sobre os temas das necessidades educativas especiais e da comunicação e linguagem.

Em especial aos meus orientadores, o Professor Fernando Martins e a Professora Helena Fernandez, pela paciência, por disponibilizarem o seu apoio, ensinamentos e disponibilidade em momentos-chave e, principalmente, por compartilharem as informações valiosas para a realização do presente estudo.

Aos colegas e amigos do mestrado que com a motivação de sempre me apoiaram na realização deste trabalho. Em especial aos meus amigos Andersson Pontes e Thyago Anthony que me acompanharam nesta importante etapa.

À minha família e amigos, especialmente aos meus pais e minha irmã pelo apoio e incentivo incondicionais demonstrados ao longo destes anos, são a eles quem devo todo o suporte e força de que dispus ao longo desse tempo. Por confiarem e terem sempre palavras de carinho e estímulo, por acreditarem que eu venceria mais esta etapa. Por me impulsionarem e por serem a minha fortaleza. É deles o meu amor e saudade sem tamanho.

## **RESUMO**

Ao longo dos anos, a exploração de reservas de petróleo em plataformas continentais em águas mais profundas tem aumentado. Como consequência o transporte do petróleo bruto e dos seus derivados por navios e oleodutos tem tido também um crescimento, o que acarreta um risco de derrame provocando impactos negativos no ambiente e na população das regiões afetadas. Estes efeitos merecem mais atenção quando ocorrem em áreas de reserva natural e em zonas balneares.

Em virtude das limitações de técnicas convencionais de fiscalização e monitorização da poluição do mar, a Detecção Remota junto com as imagens de satélites são utilizadas para identificação de manchas de óleo sobre a superfície do mar. Por vezes essa identificação torna-se difícil, devido à existência de outros tipos de manchas escuras que não são de óleo, chamadas de falsos alvos. Por isso, é indispensável a aplicação de técnicas de Detecção Remota para discriminar estas manchas.

O objeto de estudo foi um acidente ligado a um derrame de óleo ocorrido em 2019, na região litorânea do nordeste do Brasil, onde o óleo atingiu mais de 130 cidades.

O estudo foi desenvolvido a partir da aquisição, processamento e análise de imagens de RADAR do satélite Sentinel- 1 e aplicando as técnicas de Detecção Remota com ferramentas automáticas e semiautomáticas para extração da mancha de óleo.

Propõe-se neste trabalho de investigação identificar manchas de óleo, distinguir estas em face de outras manchas escuras resultantes de fenómenos naturais ou outros.

**PALAVRAS-CHAVE:** Detecção Remota, Derrame de óleo, RADAR, SAR, Brasil.

## **ABSTRACT**

Over the years, the exploration of oil reserves on continental shelves in deeper waters has increased. As a result, the transport of crude oil and its derivatives by ships and pipelines is also growing, what increase the risk of spill causing negative impacts on the environment and on the population on the affected regions. These effects deserve more attention when they occur in nature reserve areas and in bathing areas.

Due to the limitations of techniques for surveillance and monitoring of the sea surface, remote sensing with satellite images is used to identify oil slicks on the sea surface. This identification is sometimes difficult due to the existence of other types of others black spot that are not oil, called false targets. Therefore, it is essential to apply remote sensing techniques to discriminate these spots.

The object of study was the incident of an oil spill that occurred in 2019, in the coastal region of northeastern Brazil, where the oil reached more than 130 cities.

The study was developed from the acquisition, processing and analysis of RADAR images from the Sentinel-1 satellite and applying remote sensing techniques with automatic and semi-automatic tools.

It is proposed in this research work identify oil spills, discriminate these against other black spots of appearance of natural phenomena or others.

**KEYWORDS:** Remote Sensing, Oil Spill, Identification, RADAR, SAR, Brazil.



## Índice

1. INTRODUÇÃO.....	12
2. REVISÃO BIBLIOGRÁFICA.....	14
2.5.1 Correção radiométrica das imagens SAR.....	20
2.5.2 Correção geométrica das imagens SAR.....	20
2.8.1 Filtragem Espacial .....	28
2.8.2 Segmentação da imagem.....	30
2.8.3 Extração das características.....	31
2.8.4 Classificação.....	31
2.8.5 <i>Change Detection</i> .....	33
2.8.6 Textura .....	34
3. CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	35
4. METODOLOGIA.....	37
4.1.1 Imagens Sentinel - 1.....	38
4.1.2 Dados Meteo-oceanográficos .....	44
4.6.1 <i>Change Detection</i> .....	50
4.6.2 <i>Oil Spill Detection</i> .....	51
4.6.3 Textura GLCM .....	52
4.6.4 Classificação supervisionada pela máxima verossimilhança .....	53
5. RESULTADOS E DISCUSSÃO .....	54
5.4.1 <i>Change Detection</i> .....	67
5.4.2 <i>Oil Spill Detection</i> .....	70
5.4.3 Textura GLCM .....	73
5.3.4 Classificação Supervisada pela Máxima Verossimilhança .....	80
6. CONCLUSÕES.....	83
REFERÊNCIAS BIBLIOGRÁFICAS.....	85

## ÍNDICE DE FIGURAS

Figura 1: Sistema de Detecção Remota .....	15
Figura 2: Mecanismo da aquisição de imagens RADAR.....	18
Figura 3: Polarização do sinal do radar enviado pela antena nos planos horizontal (a) e vertical (b).....	19
Figura 4: Efeitos geométricos das imagens SAR. ....	21
Figura 5: Sentinel 1 A e B .....	22
Figura 6: Modos de aquisição do Sentinel 1 .....	23
Figura 7: Constelação Sentinel 1- Revisão e frequência.....	24
Figura 8: Constelação Sentinel 1-Distribuição espacial da polarização e dos modos de aquisição das imagens .....	24
Figura 9: Reflexão do sinal do Radar em duas superfícies marinhas. Uma livre da presença de óleo e outra não.....	26
Figura 10: Brasil e Região Nordeste .....	35
Figura 11: Fluxograma geral das atividades do trabalho .....	38
Figura 12: 12 de julho de 2019, polarização VV .....	40
Figura 13: 12 de julho de 2019, polarização VH.....	40
Figura 14: 24 de julho de 2019, polarização VV .....	41
Figura 15: 24 de julho de 2019, polarização VH.....	41
Figura 16: 05 de agosto de 2019, polarização VV.....	42
Figura 17: 05 de agosto de 2019, polarização VH.....	42
Figura 18: 22 de setembro de 2019, polarização VV.....	43
Figura 19: 22 de setembro de 2019, polarização VH.....	43
Figura 20: Vento do dia 24/07/2019 .....	47
Figura 21: Concentração de clorofila do dia 24/07/2019.....	47
Figura 22: Altura significativa das ondas, do dia 24/07/2019.....	48
Figura 23: Temperatura da superfície do mar (TSM), do dia 24/07/2019 .....	48
Figura 24: Níveis dos produtos dos modos de aquisição da missão Sentinel-1 .....	50
Figura 25: Processo semiautomático de <i>Change Detection</i> . ....	51
Figura 26: Processo automático com a ferramenta <i>Oil Spill Detection</i> .....	52
Figura 27: Interface do ImageJ plugin GLCM Texture Analyzer .....	53
Figura 28: Imagem original SAR, polarização VV .....	54
Figura 29: <i>Boxcar</i> . ....	55
Figura 30: <i>Frost</i> . ....	56

Figura 31: <i>Gamma Map</i> .....	56
Figura 32: <i>Lee</i> .....	57
Figura 33: <i>Lee Sigma</i> .....	57
Figura 34: Mediana .....	58
Figura 35: <i>Refined Lee</i> .....	58
Figura 36: Multilooking .....	59
Figura 37: Identificação de embarcações N .....	60
Figura 38: Identificação de embarcações SE.....	60
Figura 39: Classes: água, óleo e embarcação/plataforma N.....	61
Figura 40: Classes: água, óleo e embarcação/plataforma SE.....	61
Figura 41: Vento (24/07).....	62
Figura 42: Altura das Ondas (24/07) .....	63
Figura 43: TSM (24/07) .....	64
Figura 44: Concentração de clorofila (24/07) .....	64
Figura 45: Vento (22/09).....	65
Figura 46: Altura das ondas (22/09) .....	66
Figura 47: TSM (22/09) .....	66
Figura 48: Concentração de clorofila (22/09) .....	67
Figura 49: Resultado <i>Change Detection</i> (12/07-24/07).....	68
Figura 50: Resultado <i>Change Detection</i> (05/09-24/07).....	68
Figura 51: Resultado <i>Change Detection</i> (22/09-10/09).....	69
Figura 52: Resultado <i>Change Detection</i> (22/09-04/10).....	70
Figura 53: Resultado <i>Oil Spill detection, Default</i> .....	71
Figura 54: Resultado <i>Oil Spill</i> na deteção da mancha (teste 1).....	71
Figura 55: Resultado <i>Oil Spill</i> , na deteção da mancha (teste 2).....	72
Figura 56: Resultado <i>Oil Spill</i> na deteção da mancha mais a sul.....	73
Figura 57: Imagem SAR (29/07/2019) .....	73
Figura 58: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - 7×7 <i>pixéis</i> , na direção 90°.....	74
Figura 59: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - 15×15 <i>pixéis</i> , na direção 90°.....	75
Figura 60: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - 30 × 30 <i>pixéis</i> na direção 90°.....	76
Figura 61: Resultado da primeira mancha (N) a partir da análise da textura.....	76
Figura 62: Imagem SAR (22/09/2019) .....	77

Figura 63: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - $7 \times 7$ , na direção $90^\circ$ .....	78
Figura 64: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - $7 \times 7$ , na direção $180^\circ$ .....	79
Figura 65: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - $7 \times 7$ , na direção $270^\circ$ .....	79
Figura 66: Resultado final da segunda mancha a partir da análise da textura.....	80
Figura 67: Imagem final a partir da classificação da Máxima Verossimilhança .....	81
Figura 68: Imagem da segunda mancha a partir da classificação da máxima Verossimilhança. ....	81

## ÍNDICE DE TABELAS

Tabela 1: Principais bandas dos sensores radar com seus respectivos comprimentos de onda.....	17
Tabela 2: Parâmetros dos modos de aquisição da missão Sentinel-1 .....	23
Tabela 3: Produtos Sentinel-1 utilizados .....	39
Tabela 4: Data e horas das imagens meteo-oceanográficas.....	44
Tabela 5: Área total das manchas.....	82
Tabela 6: Área detetada Mancha 1 .....	82
Tabela 7: Área detetada Mancha 2 .....	82

## **SÍMBOLOS E ABREVIATURAS**

APRH	- Associação Portuguesa dos Recursos Hídricos
CD	- Change Detection
CMEMS	- Copernicus Marine Service ou Copernicus Marine Environment Monitoring
dB	- Decibéis
DEM	- Modelo Digital de Elevação
DR	- Detecção Remota
ERS	- European Remote Sensing Satellite
ESA	- European Space Agency
EW	- Extra-Wide swath
GLCM	- Gray-Level Co-Occurrence Matrix
GRD	- Ground Range Detected
IBAMA	- Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais.
IBGE	- Instituto Brasileiro de Geografia e Estatística
INPE	- Instituto Nacional de Pesquisas Espaciais
IW	- Interferometric Wide swath
LAPIS	- Laboratório de Análise e Processamento de Imagens de Satélites
RADAR	- Radio Detection And Ranging
RAR	- Real Aperture Radar
SAR	- Synthetic Aperture Radar
SLC	- Single Look Complex
SNAP	- Sentinel Application Platform
SRTM	- Shuttle Radar Topography Mission
SVM	- Vetor de Máquina de Suporte
TSM	- Temperatura da superfície do mar
WGS 84	- World Geodetic System 1984
WV	- Wave

# 1. INTRODUÇÃO

## 1.1 Enquadramento Geral

Os derrames resultantes de descargas intencionais ou não intencionais nas águas oceânicas ou costeiras representam uma grande ameaça para os ecossistemas marinhos. Os efeitos adversos desses derrames nestes ecossistemas são objeto de consideráveis preocupações políticas, ambientais e científicas (IPIECA, 2019). O derrame de óleo no Golfo do México que ocorreu em abril de 2010, resultante de uma explosão na plataforma *British Petroleum Deepwater Horizon*, foi amplamente relatado, com uma estimativa de cinco milhões de barris de petróleo bruto despejados no ecossistema do Golfo (BBC, 2010).

Durante as últimas décadas, o transporte marítimo tem aumentado continuamente e a quantidade de descargas ilegais de petróleo cresceu com o volume do tráfego. Cerca de metade do total de derrames de óleo no ambiente marítimo provêm de descargas operacionais de navios.

As técnicas de Detecção Remota (DR) oferecem a vantagem de se poder observar eventos em áreas remotas e inacessíveis conseguindo-se detetar a localização e a extensão dos derrames de óleo (Vespe *et al.*, 2011). Nos últimos anos tem ocorrido uma evolução nas técnicas de processamento digital para identificar esses fenómenos (Fingas e Brown, 2017).

Métodos para detetar e rastrear os derrames e descargas ilegais de óleo são importantes para melhorar o cumprimento da legislação marinha e para a vigilância e proteção eficiente de ambientes costeiros. Inicialmente a identificação de derrames de óleo foi realizada com base em sensores sensíveis às bandas do visível e do infravermelho. No entanto, estes sensores apresentam desvantagens neste contexto, uma vez que não têm a capacidade de discriminar facilmente a mancha de óleo da superfície do mar circundante e captar informação durante a noite ou em más condições climatéricas (Solberg, 2012, Fingas e Brown, 2017). Essas desvantagens não se aplicam aos sensores de Radar de Abertura Sintética (SAR), que são capazes de fornecer dados à noite e sob condições climáticas adversas, permitindo que a DR por satélite seja a base de uma ferramenta extremamente viável e útil para identificar derrames de óleo em ambiente marinho (Fingas e Brown, 2017).

A técnica *Change Detection* (CD), utilizada em diversas temáticas, nomeadamente na vigilância marítima (Vaiyammal e Raja, 2017) consiste no processo que analisa duas ou mais imagens de satélite adquiridas ao longo da mesma área geográfica em momentos diferentes por forma a encontrar mudanças de padrões que poderão ter ocorrido entre duas épocas distintas.

A análise de textura pode refletir a variação espacial da imagem e pode ser especialmente útil em imagens SAR quando há apenas uma frequência ou uma informação de polarização disponível. O método de matriz de co-ocorrência é empregue para numa primeira fase extrair as características texturais da imagem SAR (entropia, covariância, segundo momento linear, etc.) depois essas características são analisadas e otimizadas para criar o vetor de máquina de suporte (SVM) por forma a discriminar os derrames de óleo de outras manchas semelhantes (Zhang *et al.*, 2008).

## 1.2 Objetivo

Neste trabalho de dissertação, o tema abordado será o acidente ocorrido em julho de 2019 no litoral do Nordeste do Brasil, onde foi identificada uma mancha de óleo com mais de 200 km de extensão, tendo sido avistada pela primeira vez na faixa costeira do estado do Rio Grande do Norte. A referida mancha de óleo deslocou-se em direção a outros estados da mesma região e após dois meses, atingiu os estados do Espírito Santo e Rio de Janeiro, que fazem parte da região Sudeste.

O objetivo deste estudo é identificar a mancha de óleo com base em imagens radar SAR do Satélite Sentinel-1. Aplicar e comparar diversas metodologias de processamento digital de imagem, com abordagens semiautomáticas, para localizar a mancha.

## 1.3 Estrutura da dissertação

O trabalho de investigação encontra-se estruturado em cinco capítulos. No capítulo 1, é realizada uma introdução ao tema e definido o objetivo da dissertação. No capítulo 2, é efetuada uma revisão bibliográfica dos conceitos inerentes às técnicas de processamento digital de imagens de Radar de Abertura Sintética (em inglês: *Synthetic Aperture Radar* - SAR) aplicadas à deteção de manchas de óleo em superfícies oceânicas. No capítulo 3, é apresentado o caso de estudo, onde é feita uma caracterização geral da área onde ocorreu

o derrame. No capítulo 4, são descritos os dados e as metodologias utilizadas. No capítulo 5, são apresentados os resultados de detecção de manchas de óleo com a aplicação das diferentes metodologias de processamento digital de imagem. No capítulo 6 são apresentadas as conclusões do estudo.

## 2. REVISÃO BIBLIOGRÁFICA

Diversos estudos no âmbito do processamento digital de imagens SAR têm sido realizados para melhorar a precisão na detecção de manchas de óleo nos oceanos (Brekke e Solberg, 2005; Solberg *et al.*, 2007; Singha *et al.*, 2013).

Neste capítulo é feita uma breve análise e resumo de todo o conhecimento atual acerca das metodologias de processamento digital de imagem para detetar manchas de óleo.

### 2.1 Detecção Remota

A DR é a ciência que permite extrair dados sobre a superfície da Terra sem estar em contacto direto com o objeto de estudo. A análise dos dados adquiridos dos objetos de estudo obtidos pelos sensores em conjunto com o avanço das tecnologias geoespaciais têm mostrado um impacto crescente numa ampla variedade de áreas. Os avanços nas tecnologias dos sistemas de sensores e da computação digital permitiu evoluir da interpretação de fotografias aéreas para a das imagens de satélite e de estudos locais para globais. Hoje em dia os sistemas de DR permitem não só a elaboração da cartografia de base, mas também temática. Exemplos destas aplicações incluem estudos populacionais, demográficos, planeamento urbano, uso do solo, geológicos, arqueológicos, de energia, agrícolas, monitorização ambiental, de observação da terra e do mar, entre outros. Uma das aplicações marítimas é a monitorização ambiental dos oceanos que engloba a detecção de derrames de óleo no mar.

Um sistema DR é composto por vários componentes, nomeadamente, a fonte de energia que pode ser natural ou artificial (A), as interações entre a radiação e a atmosfera (B) que podem ser a dispersão, a absorção e refração, as interações com os objetos (C) como a reflexão, absorção e transmissão, o registo da energia pelo sensor (D), a transmissão,

recepção e processamento da informação (E), a interpretação e análise dos dados (F) e a modelação do fenómeno estudado e a respetiva aplicação (G) (Figura 1).




Figura 1: Sistema de Detecção Remota  
Fonte: Canada Centre for Remote Sensing, 2019

Os sensores a bordo dos satélites usam o Sol como fonte de iluminação ou fornecem a sua própria fonte de iluminação, medindo a energia que é refletida. Os sensores que usam a energia natural do Sol denominam-se sensores passivos, os que fornecem a sua própria fonte de energia são designados de sensores ativos. A maioria dos sistemas passivos usados na DR operam na banda do visível, do infravermelho próximo, médio e do térmico do espectro eletromagnético. Estes sensores medem a temperatura da superfície terrestre e do mar, propriedades da vegetação, propriedades das nuvens e aerossóis e outras propriedades físicas. A maioria dos sensores passivos não consegue penetrar na densa cobertura de nuvens e, assim, têm limitações para observar áreas como os trópicos, onde a densa cobertura de nuvens é frequente (INPE, 2021).

Os sensores ativos operam na banda de micro-ondas do espectro eletromagnético, o que lhes dá a capacidade de penetrar na atmosfera na maioria das condições.

A resolução desempenha um papel importante na forma como os dados de um sensor podem ser usados. Existem quatro tipos de resolução a serem considerados para qualquer conjunto de dados - radiométrica, espacial, espectral e temporal (INPE, 2021).

A resolução radiométrica é a quantidade de informação de cada pixel, ou seja, o número de bits que representa a energia registada. Quanto maior a resolução radiométrica, mais

valores estarão disponíveis para armazenar informação, proporcionando melhor discriminação mesmo entre as menores diferenças de energia. Por exemplo, para avaliar a qualidade da água do oceano, a resolução radiométrica é necessária para distinguir pequenas diferenças de cor que possam existir (INPE, 2021).

A resolução espacial é definida pelo tamanho de cada pixel numa imagem digital que representa a área da superfície da Terra. Quanto menor for o tamanho real deste pixel, maior será a resolução espacial da imagem, o que significa que maior é a capacidade de captar menores objetos da superfície terrestre (INPE, 2021).

A resolução espectral é a capacidade de um sensor discriminar mais comprimentos de onda. Os sensores classificados como multiespectrais, têm a capacidade de captar entre 3 a 10 bandas. Os sensores que possuem centenas a até milhares de bandas são considerados hiperespectrais. Quanto mais estreita for a faixa de comprimentos de onda captada para uma determinada banda, melhor será a resolução espectral (INPE, 2021).

A resolução temporal refere-se ao tempo que leva um satélite a completar uma órbita e visitar a mesma área de observação (INPE, 2021).

Com a passagem regular sobre os oceanos, os satélites fornecem dados que podem ser usados para monitorizar manchas em diversas regiões do oceano. Imagens obtidas pelo SAR, objeto deste estudo, têm provado ser uma ferramenta adequada para a identificação de manchas de óleo no oceano, pois os instrumentos não dependem de condições climáticas nem da luz solar para adquirir os dados com uma resolução espacial de 10 m (Girard-Ardhuin *et al.*, 2003).

## 2.3 Física do radar

A detecção e a medição de distâncias por rádio (em inglês *Radio Detection and Ranging-RADAR*) é caracterizado como um sensor ativo, uma vez que emite energia eletromagnética que é refletida por um alvo e registada pelo sistema. O RADAR usa comprimentos de onda na faixa dos microondas relativamente longos, que variam aproximadamente entre 1cm a 1m (Tabela 1), o que permite que esses sistemas penetrem nas nuvens, fumos, chuva e vegetação. A profundidade de penetração da onda do radar na superfície terrestre varia com banda escolhida. Além disso, por ser um sistema ativo, pode ser operado de dia ou de noite. As imagens de radar mostram diferentes superfícies

refletores, as mais claras representam as superfícies brilhantes que possuem grande capacidade de reflexão difusa, as escuras da imagem representam superfícies especulares ou que refletem muito pouca ou mesmo nenhuma energia (como por exemplo, as manchas de óleo no oceano). A quantidade de energia refletida que chega ao sensor varia em função do ângulo de incidência, rugosidade da superfície e da humidade do solo. (Moreira *et al.*, 2013).


**Tabela 1: Principais bandas dos sensores radar com seus respectivos comprimentos de onda**  
**Fonte: Moreira, 2013**

Banda	Comprimento de onda	
	(cm)	Frequência (GHz)
Ka	0,8 a 1,1	40 a 26,5
K	1,1 a 1,7	26,5 a 18
Ku	1,7 a 2,4	18 a 12,5
X	2,4 a 3,8	12,5 a 8
C	3,8 a 7,5	8 a 4
S	7,5 a 15	4 a 2
L	15 a 30	2 a 1
P	30 a 100	1 a 0,3

O princípio básico do RADAR consiste no envio de impulsos de radiação eletromagnética, de feixe estreito e de curto período que se propagam à velocidade da luz ( $3 \times 10^8 \text{ ms}^{-1}$ ), na direção da superfície da Terra, cuja energia é refletida pelo alvo na superfície. Estes impulsos são modificados pelo alvo (objeto) de forma que o sinal de retorno (eco) traga características específicas desse objeto. A informação dos objetos captada é transportada através de ondas eletromagnéticas que são definidas pela direção de propagação, amplitude, comprimento de onda ou frequência, polarização e fase.

A posição do objeto na superfície terrestre é determinada pelo cálculo da distância do objeto à antena do sistema, pela medição da diferença de tempo entre o sinal refletido pelo objeto e o sinal emitido pela antena (Meneses e Sano, 2012) (Figura 2). A pequena e retangular antena dos sensores radar é fixada na lateral do avião ou satélite e direcionada perpendicularmente à direção da trajetória. A largura do feixe da antena que determina a largura do lóbulo no terreno é controlada de duas maneiras: pelo tamanho físico da antena, e nesse caso os radares são chamados de radar de abertura real (RAR), ou sintetizando o tamanho real da antena, que são os conhecidos radares de abertura sintética (SAR). O

SAR é mais utilizado por ter uma melhor capacidade de resolução espacial (Meneses e Sano, 2012).



**Figura 2: Mecanismo da aquisição de imagens RADAR**  
Fonte: Moreira, 2013.

No RADAR, o sinal emitido pode ser polarizado, ou seja, o vetor do campo elétrico do pulso eletromagnético emitido pela antena é transmitido no plano vertical (V) ou horizontal (H), em relação ao eixo da antena. A polarização traz informações relacionadas com as orientações dos campos elétrico e magnético da onda eletromagnética.

As características da imagem são definidas por um conjunto de parâmetros como, direção de azimute que é a direção de voo da plataforma, a direção de visada que é a direção de iluminação ao longo da qual o impulso se propaga, na qual as áreas mais próximas e mais distantes da antena são denominadas *near range* e *far range*, respectivamente, o ângulo de depressão, o ângulo de visada e o ângulo de incidência local (estabelecido entre o impulso do radar e a superfície do terreno) (Meneses e Sano, 2012).

## 2.4 Polarização nos sistemas RADAR

A polarização descreve a orientação da componente do campo elétrico de uma onda eletromagnética (Figura 3). Os sistemas RADAR podem ter diferentes configurações de polarização. As mais comuns são as polarizações lineares do tipo HH, VV, HV e VH, onde a primeira letra indica a polarização do impulso emitido e a segunda polarização, do impulso captado pelo sensor.

A profundidade de penetração da onda do radar também depende da polarização escolhida. Além disso, a polarização pode fornecer informações acerca da forma e da orientação dos objetos que fazem parte da superfície. A polarização VV é a mais aconselhada para as superfícies de água e a polarização HH para as superfícies terrestres. (ESA, 2021)




Figura 3: Polarização do sinal do radar enviado pela antena nos planos horizontal (a) e vertical (b)  
Fonte: ESA (2021)

## 2.5 Synthetic Aperture Radar (SAR)

Durante o movimento da plataforma ao longo da linha de voo (direção de azimute), a antena assume diversas posições, ou seja, a abertura sintética é dividida em várias visadas, designadas por *looks* captando assim várias vezes a superfície terrestre. Um objeto posicionado em *near range* é observado menos vezes do que um na posição *far range*. Deste modo a imagem final resulta da composição média das imagens de cada *look*.

Qualquer imagem de um sistema DR possui distorções radiométricas e geométricas. No sistema de RADAR a correção radiométrica consiste em filtrar a imagem por forma a eliminar os erros causados pelo padrão de radiação da antena e pelo ruído *speckle*. A correção geométrica diz respeito à minimização dos erros provocados pela distorção de escala (geometria *slant range*), pelo movimento da plataforma, e pelas dimensões/orientação dos objetos na superfície, nomeadamente, a compressão (*foreshortening*), a sobreposição (*layover*) e o sombreamento (*shadowing*), do relevo (Meneses e Sano, 2012).

### 2.5.1 Correção radiométrica das imagens SAR

Para uma utilização adequada dos dados SAR, as imagens devem ser calibradas, quando são utilizadas várias imagens obtidas com ângulos de inclinação e níveis de brilho diferentes (Koppe *et al.*, 2013). A calibração radiométrica converte os números digitais dos *pixéis* da imagem SAR em valores de retrodispersão radiometricamente calibrados (ESA, 2021).

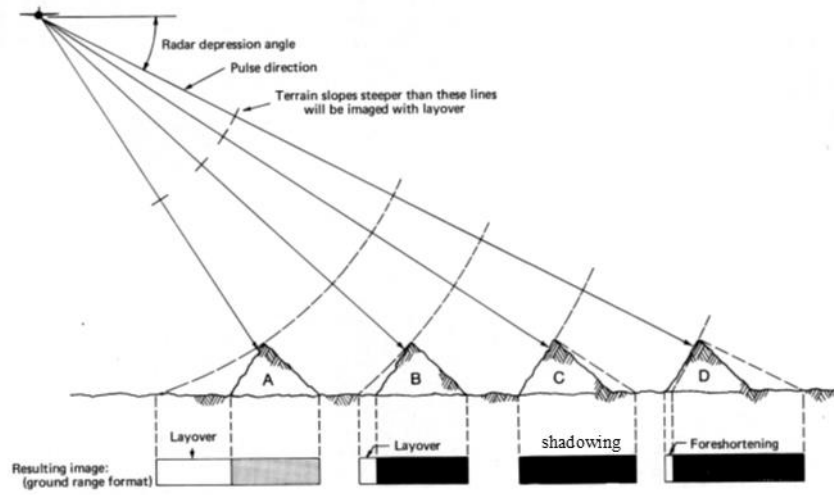
Todas as imagens SAR contêm o ruído *speckle* que degrada a qualidade da imagem e dificulta a sua interpretação. Este ruído traduz-se em mudanças bruscas de nível de cinzento de um pixel para outro, provocando uma aparência granular da imagem. Isto acontece devido à interferência dos múltiplos ecos de dispersão que ocorrem em cada pixel. A redução do ruído *speckle* pode ser conseguida através de *multilooking* ou de um filtro espacial. O processo de *multilooking* refere-se à divisão do feixe de radar em vários subfeixes e cada um dos subfeixes proporciona um *look* independente. Este processo pode ser utilizado para produzir uma imagem em que cada *pixel* que representa a média dos *multilooking* gerados, melhorando a resolução radiométrica (menos ruído), mas diminuindo a resolução espacial da imagem. Os *pixéis* passam a ter uma dimensão quadrada, tendo sido convertida uma geometria oblíqua numa representação horizontal (no terreno). O filtro espacial consiste no movimento de um elemento estruturante (Matriz de Convolução) sobre a imagem, aplicando uma operação, que utiliza os valores dos *pixéis* sob o elemento estruturante substituindo o *pixel* central da imagem pelo novo valor.

Os filtros utilizados para a redução do ruído são os designados por passa-baixa (Meneses e Sano, 2012).

### 2.5.2 Correção geométrica das imagens SAR

Com as variações do relevo e a geometria de aquisição lateral do sensor, as distâncias representadas nas imagens SAR sofrem distorções, aumentando este efeito nos objetos que se encontram mais afastado da vertical do sensor. Na Figura 4 está representada a geometria destas distorções (ESA, 2021). O efeito *foreshortening* deve-se ao facto de os pontos que se encontram acima duma superfície de referência plana e horizontal aparecerem deslocados em direção ao sensor, provocando uma representação comprimida das encostas que estão viradas para o sensor. No caso do ângulo de depressão ser maior que o declive da encosta esta compressão passa a ser uma sobreposição, designada por

*layover*. Nestes casos as imagens dos cumes aparecem sobrepostas às imagens das bases das elevações. O efeito *shadowing* é provocado pela ausência do sinal de retorno das superfícies não iluminadas pelo radar. Então as encostas que encontram orientadas na mesma direção da visada aparecem na imagem como áreas escuras.



**Figura 4: Efeitos geométricos das imagens SAR.**  
 Fonte: Lillesand *et al.* (2015).

Para diminuir estas distorções geométricas são propostas correções de terreno que permitem que a representação geométrica da imagem seja o mais próximo da realidade (ESA, 2021).

Na correção de terreno é utilizado um modelo digital de terreno que permite corrigir os efeitos associados às distorções geométricas, passando de uma geometria *slanrange* (escala distorcida) para uma geometria *groundrange* (escala uniforme) (ESA, 2021).

## 2.6 Sentinel-1

A missão Sentinel-1 foi projetada para obter imagens das zonas terrestres, zonas costeiras e marinhas e rotas de navegação com uma alta resolução temporal. Têm aplicações no âmbito da monitorização de florestas, de água, de solo, da agricultura, de ambientes marítimos e de alterações climáticas, no apoio ao mapeamento de emergência em caso de desastres naturais, na deteção de embarcações no mar, no mapeamento/identificação de derrames de óleo, entre outras (ESA, 2021).

O Sentinel-1 é constituída por uma constelação de dois satélites, Sentinel-1A e Sentinel-1B, com órbitas polares hélio síncronas que partilham o mesmo plano orbital com um desfasamento de  $180^\circ$  (Figura 5). Operam durante o dia e a noite, com um período de repetição, para cada satélite, de 12 dias que correspondem 175 órbitas. Como trabalham em simultâneo permitem aumentar a resolução temporal para 6 dias. As imagens radar obtidas são de abertura sintética (SAR) na banda C nos modos de polarização única (HH ou VV) ou dupla (HH+HV ou VV+VH). Existem quatro modos de aquisição de imagem com resoluções espaciais que variam de 5 m a 40 m e com coberturas de 80 km a 400 km: *Stripmap* (SM), *Interferometric Wide Swath* (IW), *Extra Wide* (EW) e *Wave* (WV) (ESA, 2021).




Figura 5: Sentinel 1 A e B  
Fonte: ESA (2021)

O modo de imagem SM fornece uma cobertura numa faixa de 80 km de largura e com uma resolução espacial 5m. Pode operar em um dos seis feixes disponíveis cujos ângulos de incidência podem variar de  $20^\circ$  a  $45^\circ$ . Os seis feixes sobrepostos permitem cobrir uma faixa total de 375 km. Destina-se ao apoio de ações de emergência. No modo IW a aquisição da informação é realizada em três subfaixas com uma cobertura total de 250 km e uma resolução espacial de 5 m por 20 m. Destina-se à aquisição de dados na superfície da Terra. O modo EW é destinado a operações marítimas, a monitorização de derrames de óleo, a zonas polares, entre outras, onde é necessária uma ampla cobertura com grandes resoluções temporais. Funciona de forma semelhante ao modo IW usando cinco subfaixas totalizando uma cobertura de 400 km com uma resolução espacial de 20 m por 40 m. No modo WV as imagens são do tipo SM como uma cobertura de 20 km por

20 km, em dois ângulos de incidência diferentes 23° e 36.5° com uma alternância de 100 km. Estas imagens têm utilidade na determinação da direção, do comprimento e da altura, das ondas nos oceanos abertos (ESA, 2021). A Figura 6 caracteriza os diferentes modos de aquisição de imagens pelo Sentinel 1.




Figura 6: Modos de aquisição do Sentinel 1  
Fonte: ESA (2021)

A Tabela 2 apresenta os parâmetros, nomeadamente o ângulo incidente, a resolução espacial, a largura da faixa e a polarização de cada um dos modos de aquisição de imagem do Sentinel-1.

Tabela 2: Parâmetros dos modos de aquisição da missão Sentinel-1  
Fonte: ESA (2021)

Modo	Ângulo	Resolução	Largura da	Polarização
SM	18.3° - 46.8°	5 × 5 m	80 km	HH+HV, VV+VH, HH,
IW	29.1° - 46.0°	5 × 20 m	250 km	HH+HV, VV+VH, HH,
EW	29.0° - 47.0°	20 × 40 m	410 km	HH/HV, VV/VH, HH,
WV	21.6° - 25.1° 34.8° - 38.0°	5 × 5 m	20 × 20 km	HH, VV

A Figura 7 mostra a distribuição espacial no mundo da resolução temporal, da frequência, e da cobertura das observações da constelação Sentinel-1. A Figura 8 mostra a distribuição espacial da polarização e dos modos de aquisição das imagens da constelação Sentinel-1 disponíveis no mundo (ESA,2021).

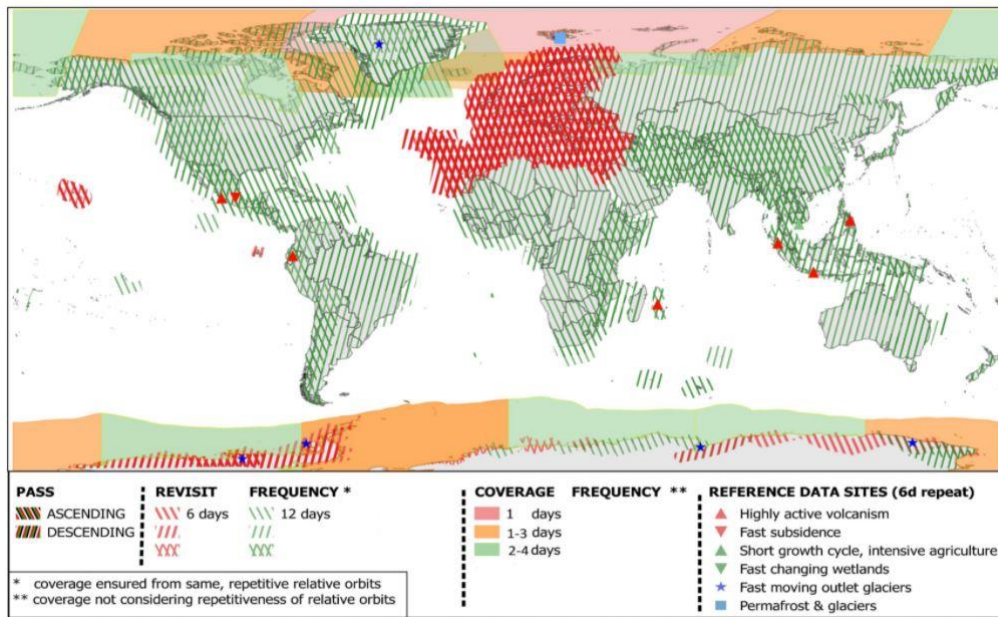


Figura 7: Constelação Sentinel 1- Revisão e frequência  
 Fonte: ESA (2021)

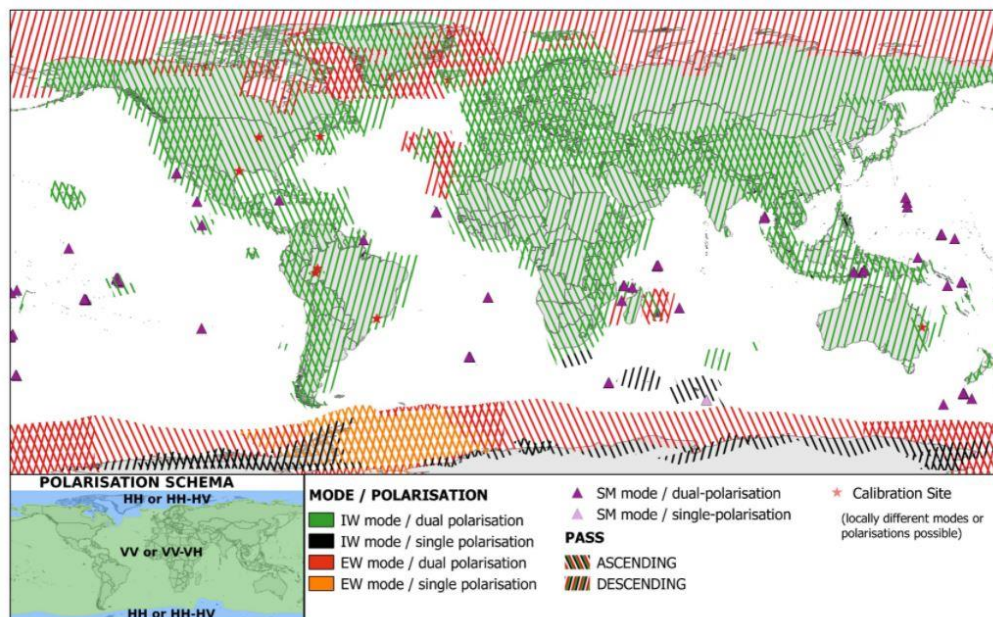



Figura 8: Constelação Sentinel 1-Distribuição espacial da polarização e dos modos de aquisição das imagens  
 Fonte: ESA (2021)

Os produtos do Sentinel-1 podem ser obtidos segundo três níveis de processamento. Os produtos de nível 0, consistem em dados brutos, os de nível 1, podem ser dados com um processamento SLC (*Single Look Complex*) com uma geometria oblíqua contendo informações de fase e amplitude ou com um processamento GRD (*Ground Range Detected*) em que os dados são georreferenciados, multivisados e projetados no terreno.

Os produtos de nível 2 são dados oceânicos que contêm parâmetros geofísicos geolocalizados (nomeadamente, campo de vento oceânico, espectros das ondas e velocidade radial) (ESA, 2021).

## 2.7 Discriminação entre mancha de óleo e semelhantes

A reflexão de um impulso de radar na superfície marítima pode ocorrer de duas maneiras: (i) uma sob forma difusa, quando estão presentes as ondas capilares que tornam a superfície oceânica rugosa, refletindo o impulso em várias direções atingindo parcialmente o sensor e (ii) sob forma especular, quando está presente uma superfície suavizada devida, por exemplo, a uma mancha de óleo, em que a maior parte do impulso é refletido segundo um ângulo oposto à da visada do sensor (Figura 9). A intensidade da energia refletida que chega ao sensor é representada radiometricamente numa escala de cinzentos. Quando estamos na presença de tons claros significa que a energia que chega ao sensor é elevada, já quando se observa tons escuros é porque a energia que chega ao sensor é menor. A cor preta representa ausência de reflexão devido, por exemplo, à reflexão especular. Assim, a deteção de óleo através das imagens SAR é possível, graças à diferença da rugosidade entre a superfície marítima com óleo e sem óleo (Espedal, 1998). Outros fatores também podem influenciar na deteção de manchas de óleo, nomeadamente, a quantidade e o tipo de óleo libertado e os parâmetros específicos do sensor, como o comprimento de onda e a polarização (Solberg *et al.*, 2007, Mera *et al.*, 2012 e Fingas e Brown *et al.*, 2017).



**Figura 9: Reflexão do sinal do Radar em duas superfícies marinhas. Uma livre da presença de óleo e outra não.**

Fonte: Alawadi, F.A (2011).

Um dos principais problemas no uso do SAR para a monitorização e deteção de derrames de óleo é a distinção de manchas de óleo de outros fenómenos, os chamados falsos alvos, que também são identificados como manchas escuras nas imagens SAR, e esses fenómenos amortecem as ondas de micro-ondas e criam manchas escuras na superfície do mar (Espedal, 1998). Nas imagens SAR os falsos alvos são devido à baixa velocidade dos ventos, à concentração de clorofila na superfície do mar, à altura das ondas, às áreas onde ocorrem chuvas fortes (células de chuva) e aos rastros dos navios.

No oceano quando os ventos são superiores a 3m/s forma-se à superfície uma ondulação designada por “capilar”, originando uma superfície lambertiana. Assim, a energia refletida é difusa produzindo na imagem zonas brilhantes. Quando os ventos são fracos (velocidades inferiores a 3 m/s) o mar fica como uma superfície especular, não existindo sinal de retorno para o sensor, provocando as manchas negras na imagem que se confundem com as de óleo (Lichtenegger, 1994, Espedal, 1998). De acordo com Solberg *et al.* (2007), Mera *et al.* (2012) e Fingas e Brown *et al.* (2017) em comprimentos de onda na banda C das micro-ondas, as velocidades de vento a partir de 2-3m/s permite que se consiga distinguir manchas de óleo, já para valores superiores a 8 m/s é difícil fazer essa distinção.

Grandes concentrações de algas na superfície do mar provocam a absorção das ondas eletromagnéticas de determinados comprimentos de onda, nomeadamente nas micro-ondas, originando cores escuras na imagem (Roriz, 2006).

Um mar calmo com ondas pequenas contribui para um impulso curto e bem definido, já um mar agitado com ondas altas origina um impulso mais longo. As condições do estado do oceano adequadas para deteção de derrames de óleo são caracterizadas por alturas de ondas menores que 1,5 m. (Miranda *et al.*, 2004).

Além disso, as fortes chuvas na superfície do oceano causam turbulência, o que enfraquece as ondas capilares. Como resultado, as células de chuva dão origem a uma reflexão baixa, enquanto as suas áreas circundantes provocam uma reflexão mais elevada (Espedal *et al.*, 1998). Como resultado, regiões com fortes células de chuva tornam a deteção de óleo extremamente difícil.

A interpretação oceanográfica dos mapas de temperatura fornece informações sobre características, como ressurgência, frentes oceânicas e correntes oceânicas. Este procedimento auxilia na interpretação das imagens SAR para a deteção de derrames de óleo no mar, excluindo as manchas escuras originadas por esses fenómenos (Miranda *et al.*, 2004).

Segundo Brekke (2007) a identificação de derrames de óleo e a discriminação de falsos alvos de óleo causados pelos efeitos meteorológicos ou oceanográficos têm preconizado para a investigação um grande desafio na implementação de distintas metodologias de deteção.

Outro aspeto importante na deteção de óleo no mar é a identificação da localização dos navios. Segundo Brekke (2007) várias técnicas têm sido estudadas, implementadas e melhoradas no que concerne à deteção automática de navios usando imagens SAR. Dependendo da forma como as informações são obtidas e processadas, cada técnica apresenta diferentes desempenhos e resultados. Hoje em dia existem vários algoritmos com o objetivo de obter melhores resultados na deteção de navios, nomeadamente a aplicação *Sentinel Application Platform* (SNAP) desenvolvida pela *European Space Agency* (ESA), que reúne todas as ferramentas para o processamento de dados SAR.

## 2.8 Processamento das imagens SAR

O processamento das imagens SAR para detecção de derrames de óleo é realizado em quatro etapas: pré-processamento, segmentação, extração e classificação de imagem (Vespe *et al.*, 2011, Vespe *et al.*, 2012). O pré-processamento consiste na retificação radiométrica e geométrica das imagens. A segmentação divide a imagem em múltiplas regiões agrupando *pixéis* similares de acordo com um limiar adaptativo (Solberg *et al.*, 2007, Brekke e Solberg, 2005) ou com um limiar de densidade espacial (Shu *et al.*, 2010), sendo extraídas as características contíguas da imagem segmentada. Segundo Brekke e Solberg (2005) e Topouzelis *et al.*, (2007) foram propostos um conjunto de parâmetros para caracterizar distintas manchas (vetores de características). Podem ser agrupados de acordo com os seguintes parâmetros: (i) geometria e forma da região segmentada; (ii) valores de reflexão; (iii) aspetos contextuais; (vi) e aspetos texturais. A classificação utiliza as informações dos vetores para classificar as diferentes manchas, separando os derrames de óleo de outras manchas. Esta fase depende da maior ou menor diferenciação das características dos objetos da classe de derrame de óleo em relação à dos objetos das classes semelhantes que não são manchas de óleo. Métodos eficazes para desenvolver classificadores envolvem numa primeira etapa uma aprendizagem a partir de padrões (fase de treino) e numa segunda fase a classificação propriamente dita. Em abordagens estatísticas, a decisão de classificação é baseada na probabilidade e no custo de uma determinada decisão (Brekke e Solberg, 2007). Vários classificadores podem ser aplicados ao problema de detecção de derrame de óleo utilizando diferentes estatísticos (Topouzelis, K., Karathanassi, V., Pavlakis, P., & Rokos, D. (2003). Todos os algoritmos podem apresentar classificações erróneas de falsas manchas de óleo e por isso Girard-Arduin *et al.* (2003) sugere a combinação de dados meteorológicos e oceânicos obtidos por outros sensores multiespetrais, às imagens SAR. Estes dados referem-se às medições de vento de superfície, temperatura da superfície do mar, frentes atmosféricas, nuvens e clorofila (Genovez *et al.*, 2009).

### 2.8.1 Filtragem Espacial

As imagens de radar estão sujeitas a fortes ruídos como resultado de processamento dos ecos do radar sendo que, a aplicação de filtros espaciais permite retificar radiometricamente as imagens SAR. A presença de ruído *speckle* afeta a qualidade dos

detalhes espaciais, dificultando a etapa de classificação. Portanto, é necessário efetuar um pré-processamento que consiste na filtragem espacial da imagem. Este processo consiste na convolução de uma imagem original com ruído, através da passagem de uma janela (ou *kernel*) em que o nível digital do pixel, que está no centro do *kernel*, é alterado de acordo os níveis digitais dos *pixéis* vizinhos. Muitos filtros espaciais têm sido desenvolvidos para a redução do ruído *Speckle* na imagem SAR, sendo os filtros adaptativos os mais comuns, uma vez que suprimem o ruído multiplicativo em regiões homogêneas e ao mesmo tempo preservam os limites, os detalhes e as características da textura da imagem. *Lee* e *Frost* são exemplos de filtros adaptativos que suavizam dentro de uma janela fixa, através da minimização do erro médio quadrático baseado nas características estatísticas da imagem SAR e do ruído *Speckle* (Papila *et al.*, 2018)

Segundo Klogo, Gasonoo, A e Ampomah, I. K. (2013) os filtros mais utilizados nas imagens SAR são os seguintes:

*Boxcar filter*: É um filtro típico de passa-baixo, também designado por filtro da média que suaviza a imagem e remove o ruído de alta frequência (Lee *et al.* 1983).

*Median filter*: É um filtro não linear em que o valor do pixel central do kernel é substituído pelo valor da mediana dos elementos da janela. Reduz o efeito de blurring e edging (Wang, X., Thomas, J. B., Hardeberg, J. Y., & Gouton, P, 2013).

*Lee filter*: É um filtro que minimiza o erro médio quadrático através da linearização do ruído multiplicativo utilizando as estatísticas locais. Preserva os fenômenos de baixa e alta frequência em simultâneo (Lee 1983).

*Frost filter*: É um filtro linear derivado da minimização do erro quadrático médio sobre o modelo multiplicativo do ruído. Aplica uma média exponencialmente ponderada com base no coeficiente de variação, que é a razão entre o desvio padrão local e a média local da imagem (Frost *et al.*, 1982).

*Refined Lee filter*: Com objetivo de preservar mais a textura, Lopes *et al.* (1990) melhorou os filtros de *Frost* e *Lee*, utilizando o critério da separação as imagens em três classes de homogeneidade, a partir do coeficiente de variação local. Nas classes homogêneas o valor do pixel é substituído pela média dos valores do filtro. Nas classes heterogêneas mantem-se o valor de pixel obtido pelo modelo filtragem original. As classes que contêm os Pontos-alvo não alteram o valor de pixel.

*Lee-Sigma filter*: Neste filtro é considerado que os dados têm uma distribuição gaussiana. Assim, os *pixéis* dentro do intervalo de desvio padrão são substituídos com a média de todos os *pixéis* da janela do filtro (Lee, 1983).

*GammaMap filter*: Para minimizar a perda de informações em relação a textura Lopes *et al.* (1990) considerou uma distribuição gama para estimar as características do ruído.

## 2.8.2 Segmentação da imagem

A segmentação de imagens é geralmente usada para encontrar objetos e limites (linhas ou contornos) tornando a imagem mais perceptível para ser analisada (Sathya e Malathi, 2011). É uma etapa fundamental na detecção de derrames de óleo uma vez que permite diferenciar manchas de óleo de falsos alvos. Consiste na divisão da imagem em várias regiões (segmentos) quer através do agrupamento de *pixéis* pertencentes a um mesmo objeto/região de acordo com determinado atributo, ou através da subdivisão da imagem em zonas homogêneas e uniformes, em função de um determinado atributo comum.

A segmentação pode seguir duas estratégias gerais, descontinuidade, onde a segmentação da imagem é baseada em mudanças repentinas de intensidade (e.g., detecção de fronteiras e limiarização) e a similaridade, onde é realizada a segmentação com base na semelhança dos *pixéis*, seguindo um determinado critério (e.g., limiarização, crescimento de regiões, divisão e junção de regiões).

A limiarização é a forma mais simples de segmentar imagens para identificar manchas de óleo (Saldanha e Freitas, 2009). Este processo consiste em definir classes a partir de um ou vários limites radiométricos. Assim os *pixéis* serão associados a cada classe de acordo com o seu nível digital. Um dos processos de limiarização é a análise do histograma da imagem, onde os “vales” do histograma correspondem aos limiares que definem as diferentes classes. No caso da detecção de manchas de óleo o objetivo é encontrar distintos valores radiométricos, entre 0 e 255, que separe diferentes tons (classes) (Saldanha e Freitas, 2009).

### 2.8.3 Extração das características

Nesta etapa são extraídas as características das manchas de óleo face às áreas circundantes. De acordo com Genovez *et al.* (2017) a textura do óleo é uniforme e macia, enquanto a textura da superfície do mar não é tão uniforme. Para além da textura, a geometria (perímetro, área e forma), a cor (nível digital radiométrico) e as informações contextuais também são usadas para diferenciar as manchas de óleo da superfície oceânica e de falsos alvos.

Um exemplo de um descritor geométrico é a forma alongada da mancha no caso de ser um derrame de óleo provocado pelo navio em movimento (Genovez *et al.*, 2009).

Parâmetros estatísticos, como a média e o desvio padrão, dos valores de reflexão, também podem ser utilizados para caracterizar as manchas de óleo (Topouzelis *et al.*, 2007). O gradiente do valor de reflexão das manchas fornece informações precisas para distinguir um derrame de óleo de falsos alvos. A textura também pode fornecer informação sobre a correlação espacial entre os *pixéis* vizinhos e a homogeneidade da imagem (Brekke e Solberg, 2005).

### 2.8.4 Classificação

A classificação de imagens consiste na categorização de forma automática de todos os *pixéis* de uma imagem em classes, formando regiões em que os *pixéis* apresentam características semelhantes entre eles. A classificação pode ser supervisionada ou não supervisionada. (Silva *et al.*, 2003).

A classificação não supervisionada consiste na agregação de *pixéis* (*clusters*) de forma automática (realizada pelo *software*) de acordo com as suas características espectrais. O utilizador apenas intervém na escolha do número e da dimensão mínima dos *clusters*, e no processo de agregação dos *clusters* que representam a mesma classe. Uma das técnicas clássicas da classificação não supervisionada é a análise do histograma da imagem, em que os *clusters* poderão ser definidos segundo dois níveis: (i) *broad*, a divisão é feita pelos vales do histograma e (ii) *fine*, a divisão é feita pelos vales e dorsos do histograma (Richards, 1993). Outros algoritmos que são frequentemente usados são o *K-means*, o ISODATA (*Iterative Self-Organizing Data Analysis Technique Algorithm*) e o MAXSET. Os algoritmos *K-means* e o ISODATA são procedimentos iterativos, em que

inicialmente é atribuído um vetor de *cluster* arbitrário. A segunda etapa classifica cada *pixel* para o cluster mais próximo. Na terceira etapa, os novos vetores médios do cluster são calculados com base em todos os *pixéis* que pertencem ao *cluster*. A segunda e a terceira etapas são repetidas até que não existam diferenças consideráveis entre as iterações, e, existir uma pequena percentagem de *pixéis* que muda de uma classe para outra ou pela pequena diferença do vetor médio do *cluster* de uma iteração para outra. A diferença entre os algoritmos é que o ISODATA permite diferentes números de *clusters* enquanto o *K-means* assume que o número de *clusters* é conhecido à priori (Abbas *et al.*, 2016). O MAXSET baseado na teoria *Dempster-Shaferuma* (variante da lógica Bayesiana) atribui *pixéis* a classes que podem ser combinações de classes que foram criadas numa fase de treino. Neste sentido, MAXSET é também considerado um classificador não supervisionado porque cria as suas próprias classes a partir de classes definidas à priori (Matsukuma, 2002).

A classificação supervisionada, ou semiautomática, permite a identificação e a diferenciação de objetos presentes na imagem através do padrão da assinatura espectral. Este processo associa os *pixéis* a classes de acordo com a assinatura espectral de cada objeto presente na imagem. Para estabelecer a categorização de cada classe que se pretende identificar na imagem é necessário a intervenção do utilizador, nomeadamente na definição de áreas de treino para a descrição da assinatura espectral da classe. Em seguida cada *pixel* irá ser alocado à classe em que a sua assinatura espectral mais se assemelha de acordo com um determinado classificador.

Existem diversos classificadores, sendo os mais comuns, o paralelepípedo, a distância mínima à média e a probabilidade de máxima verossimilhança. O classificador do paralelepípedo caracteriza cada classe pela diferença entre os valores de radiância máxima e mínima da respetiva área de treino para cada banda espectral utilizada. No caso de um *pixel* que não apresente um nível radiométrico dentro do intervalo de valores definido para a classe, não é classificado. O classificador da distância mínima à média calcula a distância euclidiana entre as assinaturas espectrais dos *pixéis* da imagem (de cada banda) e as áreas de treino, sendo o *pixel* alocado à classe que apresente a distância mínima. O algoritmo da máxima verossimilhança calcula as distribuições de probabilidade para as classes, baseado na regra de decisão de Bayes. Este classificador usa a média e a variância/covariância das assinaturas espectrais de cada classe estimando em qual classe um *pixel* pertence (Richards e Jia, 2006).

A Rede Neural Artificial (RNA) é uma ferramenta eficiente para a classificação automática de imagens. É um modelo matemático simplificado, baseado no funcionamento das células neuronais humanas, que usa algoritmos iterativos de aprendizagem à medida que vão entrando no sistema novos dados (Singha e Bellerby, 2013)

A rede adquire o conhecimento através do processo de aprendizagem (algoritmo de treino) e armazena-o através das conexões entre neurónios (sinapses). As sinapses podem ter um peso excitatório que incrementam a soma dos sinais ou inibidor que decrementam a soma dos sinais (Jomi, 2006).

Os neurónios estão organizados e ligados entre si com um dado sentido, numa determinada arquitetura adotada. Existem vários tipos de arquiteturas de RNA: as redes de camada única, as redes multicamada e as redes recorrentes. As RNA podem ser classificadas quanto à aprendizagem: a supervisionada e a não supervisionada (Singha e Bellerby, 2013).

Na supervisionada são conhecidas à priori as respostas/saídas corretas correspondentes a um determinado conjunto de dados de entrada. Conhecendo as respostas corretas da rede das diferentes entradas de dados são definidos os pesos das diferentes sinapses dos neurónios da rede. Existem vários algoritmos deste tipo de classificação, tais como, o *Perceptron* e a retropropagação do erro. (Andrade *et al.*, 2009)

Na não supervisionada não há conhecimento antecipado das respostas consideradas corretas. Existem na generalidade dois algoritmos para esta classificação: a estimulação pela entrada (*reinforcement algorithms*) e a aprendizagem competitiva (*competitive learning*). Na estimulação pela entrada, cada vetor de entrada da rede estimula um ajuste dos pesos favorável a uma saída com certas características. Na aprendizagem competitiva, os neurónios de saída da rede competem entre si pelo direito de serem ativados, ou seja, fornece uma dada resposta a uma dada entrada (Gonçalves, M. L., Andrade Netto, M. L., Zullo Jr, J., & Costa, J. A. F., 2008).

### **2.8.5 Change Detection**

A técnica *Change Detection* (CD) usando a DR é um método de análise de duas ou mais imagens de satélites obtidas da mesma área geográfica em diferentes períodos, tendo

como objetivo identificar alterações que possam ter ocorrido entre as datas de aquisição (Vaiyammal e Raja, 2017). O desempenho desta técnica, a partir da literatura, depende da qualidade das imagens adquiridas e da imagem da diferença (Maithree *et al.*, 2020).

A técnica CD pode ser dividida em três etapas: (i) o pré-processamento das imagens, que inclui a georreferenciação, as correções geométricas e a redução de ruído; (ii) a diferença entre imagens, que consiste na subtração ou no quociente entre *pixéis*; (iii) a limiarização da diferença e a respetiva reclassificação em dois clusters (com ou sem alteração) (Maithree *et al.*, 2020). Esta última etapa é definida a partir da análise do histograma da diferença de imagens, em que as caudas do histograma dizem respeito às zonas onde ocorreram alterações. Os limiares das caudas são definidos pela média e pelo desvio padrão da imagem resultante da diferença.

### 2.8.6 Textura

A análise de textura tem sido amplamente utilizada em diversas aplicações, como imagens médicas e DR. Os métodos de análise diferem na forma como as características texturais são extraídas e são úteis na classificação de imagens. As medidas de textura utilizam as informações de *pixéis* vizinhos para caracterizar os objetos ou regiões de interesse numa imagem (Haralick, 1973).

Uma das análises de textura mais utilizada em aplicações de DR foi proposta por Haralick em 1973. Este apresentou uma matriz chamada de co-ocorrências de níveis de cinzento (*Gray-Level Co-Occurrence Matrix*, GLCM) que representa as relações espaciais de distância e as relações espaciais angulares sobre uma sub-região da imagem de determinado tamanho (janela). Cada elemento da GLCM é uma medida de probabilidade de ocorrência de valores de níveis de cinzento separados por uma distância numa dada direção (Kuplich *et al.*, 2005). Para cada elemento da imagem, numa determinada vizinhança e com uma determinada orientação e espaçamento, é calculada a matriz de co-ocorrências. Haralick (1973) propôs 14 medidas de textura a serem extraídas da matriz, sendo as mais relevantes, a Energia (ENE) e o Segundo Momento da Diferença Inversa (SMDI) que avaliam a uniformidade textural da imagem, a Entropia (ENT) que mede a desordem da imagem, o Contraste (CON) que mede a presença de transição de níveis de cinzento, a Variância (VAR) determina a heterogeneidade da imagem e a Correlação

(COR) determina a dependência linear de um nível de cinzento em relação aos seus vizinhos.

### 3. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A região Nordeste do Brasil com cerca de 3400 km de linha de costa é constituída por nove estados, todos costeiros: Bahia (BA), Sergipe (SE), Alagoas (AL), Pernambuco (PE), Paraíba (PB), Rio Grande do Norte (RN), Ceará (CE), Piauí (PI) e Maranhão (MA). Toda esta extensão confere-lhe uma paisagem diversificada ao longo da costa, como praias, dunas, arribas, barreiras de corais, estuários, ilhas, deltas, entre outros, apresentando dinâmicas específicas e vulnerabilidades diferenciadas. Nessa área encontram-se centros populacionais importantes, cujas populações totalizam aproximadamente 7,5 milhões pessoas. (IBGE, 2010). A Figura 10 ilustra a área de estudo.

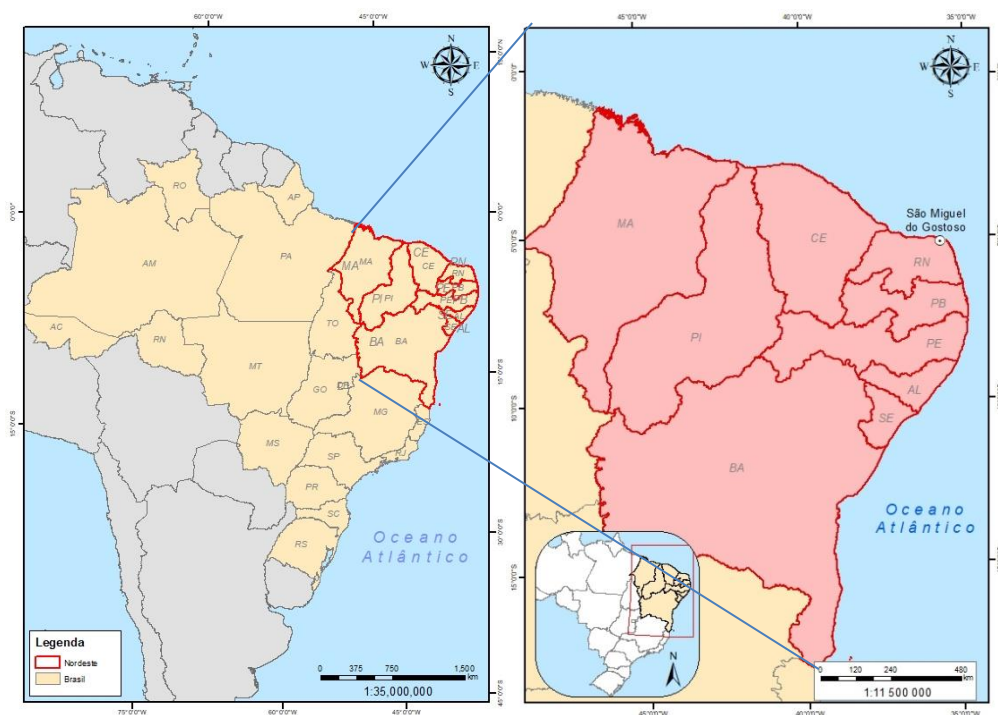


Figura 10: Brasil e Região Nordeste  
Fonte: Autor

O Nordeste brasileiro apresenta três tipos de clima: o clima litorâneo húmido (do litoral da Bahia ao Rio Grande do Norte), o clima tropical (em áreas dos estados da Bahia, Ceará,

Maranhão e Piauí) e o clima tropical semiárido (sertão nordestino) o que corresponde na classificação de Köppen-Geiger como clima “BSh”, semiárido e quente (Kayano *et al.*, 2009). Vários fatores influenciam o clima da região Nordeste, nomeadamente, a localização geográfica, o relevo e a ação conjunta de diferentes sistemas de circulação e que tornam a climatologia da região mais complexa (Nimer, 1989). Segundo Kayano (2009), o regime pluviométrico é caracterizado por uma variabilidade interanual, que varia de 300 a 2000 mm, apresentando anos secos e outros chuvosos (Nimer, 1989). A temperatura média do mar apresenta valores médios anuais que variam entre 20° e 28° C. (APRH, 2021).

Ao longo do tempo a população tem ocupado a zona litoral, promovendo o aumento da habitação, do comércio, dos transportes, da agricultura, da pesca e da aquicultura. A grande diversidade da paisagem em conjunto com as características climáticas e a temperatura das águas, contribuíram para que esta região se tornasse um destino turístico internacional. Para além disto, a indústria de exploração de petróleo tem vindo aumentar bem como o tráfego de navios petroleiros o que leva a um incremento do risco de acidentes com derrames de óleo (APRH, 2021).

Na área de estudo foi identificada no dia 24 de julho de 2019 uma mancha de óleo pelo satélite Sentinel-1A, a 40 km de São Miguel do Gostoso no estado do Rio Grande do Norte, sendo que a mancha de óleo atingiu 877 locais em mais de 127 municípios em 11 estados (LAPIS, 2021). No final de agosto de 2019, essas manchas de óleo atingiram a faixa litoral de toda a região (LAPIS, 2021). Pela configuração do derrame presume-se que a origem do desastre tenha sido de um navio que passou pela costa do Brasil, mas nenhum órgão oficial o confirmou. Este acidente foi considerado como o maior desastre ambiental de derrame de óleo bruto no Brasil e um dos mais extensos registados no mundo (IBAMA, 2021). Tratou-se de um evento de enorme extensão geográfica, provocando graves danos à fauna e a áreas protegidas, principalmente as mais sensíveis, como manguezais e recifes de coral, danos humanos, uma vez que a as condições de subsistência de inúmeros grupos populacionais dependem da pesca e do turismo (LAPIS, 2021).

## 4. METODOLOGIA

Neste trabalho foram utilizados diversos *softwares* de geoprocessamento, tais como SNAP, um software de código aberto criado pela ESA, ideal para a exploração dos dados de Observação da Terra; ImageJ também um software de código aberto para o processamento e análise de imagens científicas e ArcGIS versão 10.8, um software que engloba um conjunto de aplicações e ferramentas para o mapeamento, análise e gerenciamento de dados geográficos. A metodologia de trabalho está organizada de acordo com o fluxograma da Figura 11.

Numa primeira fase foi efetuada a aquisição da informação, nomeadamente, as imagens do satélite Sentinel-1 e os dados Meteo-oceanográficos. As imagens Sentinel-1 foram sujeitas a um processamento que consistiu, no recorte da imagem pela área de estudo, nas correções radiométricas e geométricas, na elaboração da máscara para diferenciar a Terra do Mar e na aplicação de diversos filtros. Os dados Meteo-oceanográficos serviram como base para a elaboração dos mapas Meteo-oceanográficos. Os mapas de identificação das embarcações foram elaborados a partir do *software* SNAP, que contém uma ferramenta *Ocean object detection* e possui um algoritmo automático para identificar objetos no mar. Através do cruzamento das imagens processadas e dos mapas foram extraídas as manchas com base no *Change Detection*, Ferramenta *Oil Spill*, Textura e Classificação pela Máxima Verosimilhança.

As Figuras apresentadas neste trabalho foram criadas com o software Arcgis 10.8, desenvolvido pela ESRI (2021).

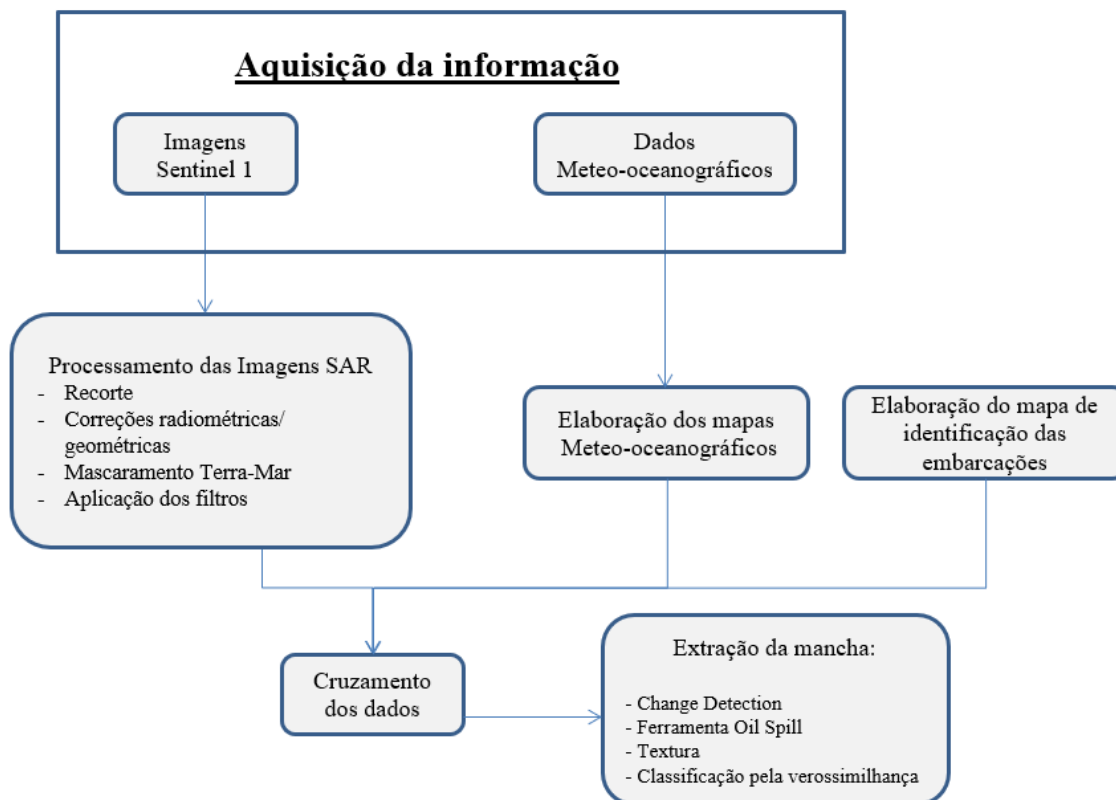


Figura 11: Fluxograma geral das atividades do trabalho

## 4.1 Aquisição da informação

### 4.1.1 Imagens Sentinel - 1

Foram utilizadas nesta investigação oito imagens de Sentinel 1 (SAR), com polarização cruzada e paralela (VH e VV), associadas ao sistema global de coordenadas WGS84 (*World Geodetic System 1984*) (Tabela 3). Estas imagens foram disponibilizadas gratuitamente pela *European Space Agency* (ESA) a partir do programa *Copernicus Open Access Hub*, anteriormente conhecido como *Sentinels Scientific Data Hub*. As Figuras 12 e 13 mostram a área de estudo a Norte antes da ocorrência do derrame (12 de julho de 2019) nas duas polarizações (VH e VV). Na Figura 14 referente à polarização VV do dia 24 de julho de 2019 observa-se nitidamente uma mancha (provavelmente de óleo) e os eventuais navios (pontos brancos). Na Figura 15 que diz respeito à imagem da mesma data, mas com a polarização VH, não é visível a mancha nem os navios. Nas Figuras 16 e 17 (imagens VH e VV de 5 de agosto de 2019) deixa-se de observar a mancha. A Figura 18 (imagem VV de 22 de setembro de 2019) mostra uma pequena porção da mancha mais

a sul (SE), donde se pressupõe que ocorreu um deslocamento ou uma nova descarga. A Figura 19 do mesmo dia, mas com a polarização VH, não mostra essa mancha, mas identifica os navios. À priori, constata-se que é a polarização VV a mais útil na identificação das manchas.

**Tabela 3: Produtos Sentinel-1 utilizados**

Data	Hora	Produto
12 de julho de 2019	08:01	S1A_IW_GRDH_1SDV_20190922T080111_20190922T080136_029131_034E91_DA2A_VH.tiff
		S1A_IW_GRDH_1SDV_20190922T080111_20190922T080136_029131_034E91_DA2A_VH.tiff
24 de julho de 2019	08:01	S1A_IW_GRD-VH_20190724t080108-20190724t080133-028256-033120-002
		S1A_IW_GRD-VV_20190724t080108-20190724t080133-028256-033120-001
05 de agosto de 2019	08:01	S1A_IW_GRDH_1SDV_20190922T080111_20190922T080136_029131_034E91_DA2A_VH.tiff
		S1A_IW_GRDH_1SDV_20190922T080111_20190922T080136_029131_034E91_DA2A_VH.tiff
22 de setembro de 2019	08:01	S1A_IW_GRDH_1SDV_20190922T080111_20190922T080136_029131_034E91_DA2A_VH.tiff
		S1A_IW_GRDH_1SDV_20190922T080111_20190922T080136_029131_034E91_DA2A_VH.tiff




Figura 12: 12 de julho de 2019, polarização VV




Figura 13: 12 de julho de 2019, polarização VH




Figura 14: 24 de julho de 2019, polarização VV




Figura 15: 24 de julho de 2019, polarização VH




Figura 16: 05 de agosto de 2019, polarização VV

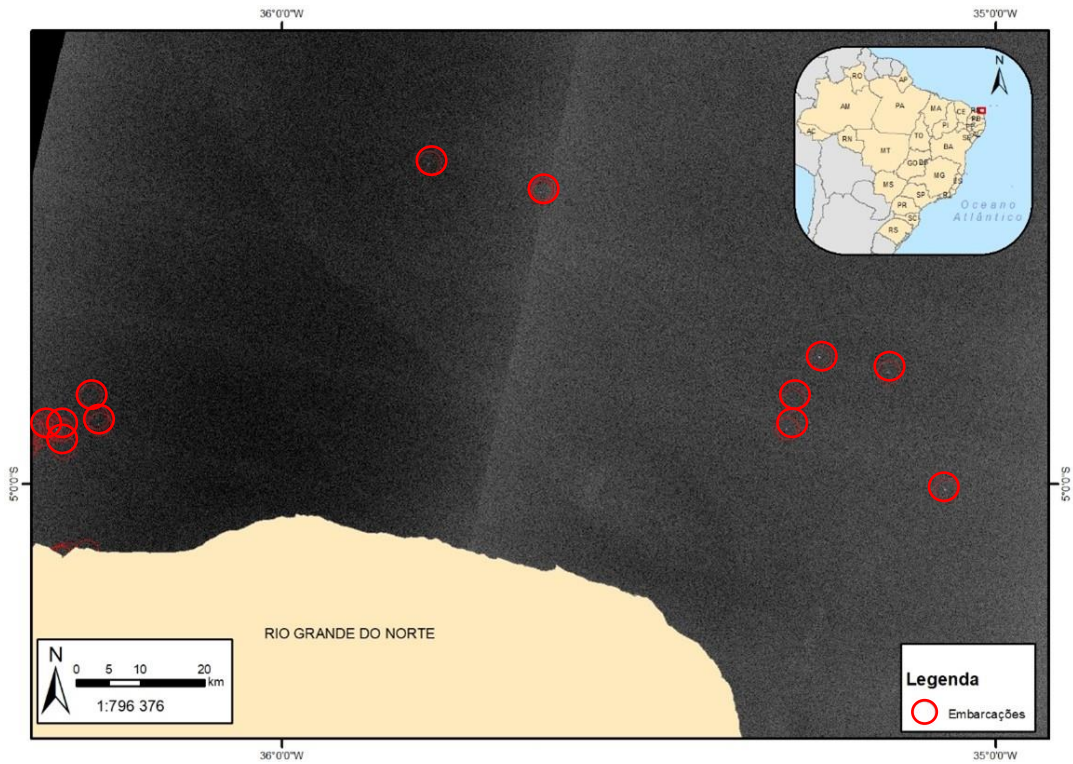


Figura 17: 05 de agosto de 2019, polarização VH




Figura 18: 22 de setembro de 2019, polarização VV




Figura 19: 22 de setembro de 2019, polarização VH

### 4.1.2 Dados Meteo-oceanográficos

Para uma análise mais detalhada das imagens SAR, em particular, diferenciar falsos alvos das manchas de óleo foi necessário elaborar mapas Meteo-oceanográficos nas datas referentes à aquisição dos dados do Sentinel-1. Esta informação é disponibilizada pelo CMEMS (2021) (*Copernicus Marine Service* ou *Copernicus Marine Environment Monitoring Service*), que fornece informações oficiais gratuitas, regulares e sistemáticas sobre o estado do oceano numa escala global e regional, financiado pela Comissão Europeia (CE) e implementado pela *Mercator Ocean International*. A informação recolhida refere-se à direção do vento, à concentração de clorofila, à altura das ondas e à temperatura da superfície do mar. A Tabela 4 apresenta as datas e hora das imagens utilizadas para cada tipo de dados.

**Tabela 4: Data e horas das imagens meteo-oceanográficas**

Parâmetros	Data	Hora
Vento	12 de julho de 2019	06:00
	24 de julho de 2019	06:00
	05 de agosto de 2019	06:00
	22 de setembro de 2019	06:00
Concentração de Clorofila	12 de julho de 2019	06:00
	24 de julho de 2019	06:00
	05 de agosto de 2019	06:00
	22 de setembro de 2019	06:00
Altura das Ondas	12 de julho de 2019	09:00
	24 de julho de 2019	09:00
	05 de agosto de 2019	09:00
	22 de setembro de 2019	09:00
Temperatura da Superfície do Mar (TSM)	12 de julho de 2019	12:00
	24 de julho de 2019	12:00
	05 de agosto de 2019	12:00
	22 de setembro de 2019	12:00

## 4.2 Processamento das imagens SAR

Foi efetuado o processamento das imagens de polarização VV (já que nas imagem com a polarização VH não se conseguiu observar as eventuais manchas de óleo) com o *software* SNAP.

A primeira etapa consistiu no recorte das imagens originais para reduzir o tempo dos processamentos. De seguida foram executadas várias correções radiométricas e geométricas, nomeadamente: (i) Correção das órbitas dos satélites (*Apply orbit file*) - os parâmetros das órbitas contidos nos metadados dos produtos SAR não são precisos e as informações corretas para cada órbita de satélite são calculadas e disponíveis após dias ou semanas da passagem do satélite. A atualização automática dos parâmetros das órbitas permite o conhecimento da posição precisa do satélite na altura da obtenção da imagem; (ii) Planificação do terreno (*Terrain Flattening*) – devido aos diferentes ângulos de incidência, as áreas viradas para o sensor são mais brilhantes e outras mais escuras, o que origina um achatamento dos objetos. Esta ferramenta faz a correção destas distorções recalculando a radiometria real com base na área iluminada por *pixel*; (iii) Calibração radiométrica (*Radiometric calibration*) - transforma os níveis digitais dos *pixéis* das imagens em refletâncias com base em parâmetros fornecidos nos metadados; (iv) Georreferenciação e ortoretificação (*Geometric Correction /Elipsoide Correction*) - a presença de distorções geométricas em imagens SAR, ou seja, o encurtamento, a escala e sombra, podem minimizar o uso de dados e impedir a extração de informações em várias formas. Esta ferramenta georreferencia as imagens e ortoretifica com base no modelo digital de terreno a partir dos dados do *Shuttle Radar Topography Mission* (SRTM) com uma resolução de 30m. Neste caso não foi realizada a correção de terreno porque o objetivo do trabalho é a deteção de derrames de óleo sobre a água. O referencial elipsoidal é suficiente para garantir uma boa a geometria das imagens; (v) Redução do ruído *Speckle* através da técnica *Multilooking* – consiste na divisão da abertura sintética em visadas (*looks*). A imagem produzida resulta da média das imagens de cada *look*, geradas separadamente, reduzindo desta forma o *Speckle*; e (vi) Aplicação de filtros para melhoramento das imagens (*filtering*) - O *software* SNAP dispõe de vários filtros tendo sido testados, o *Box Car*, a *Median*, o *Lee*, o *Frost*, o *Refined Lee*, o *Lee Sigma* e o *Gamma Map*. Neste trabalho concluiu-se que o fitro *Lee Sigma*, permitiu uma melhor

interpretação visual da imagem. A etapa final do processamento consistiu na criação de uma máscara para excluir a Terra e a linha de costa de forma a facilitar a detecção da mancha de óleo no mar.

### 4.3 Elaboração dos mapas Meteo-oceanográficos

Os dados gerados pelos satélites que fornecem dados Meteo-oceanográficos ajudam na interpretação das imagens de radar a fim de diferenciar falsos alvos do derrame de óleo.

Os dados de vento são originados de modelos desenvolvidos pelo *Copernicus* que é detetado remotamente a partir do dispómetro a bordo dos satélites ASCAT-A e ASCAT-B (*Advanced SCAT terometer*). A análise é realizada para cada hora e possui uma resolução espacial de  $0,25^\circ$  em longitude e latitude sobre todos os oceanos.

O mapa de concentração de clorofila inclui arquivos médios diários e mensais de parâmetros biogeoquímicos como, clorofila, nitrato, oxigênio, ferro, fitoplâncton, entre outros, sobre o oceano global, através do Satélite Sentinel-3 que identifica a cor do mar, permitindo monitorizar a produtividade biológica nos oceanos.

Os dados da altura das ondas são oriundos de altímetros capazes de registar mudanças na superfície marítima. O sistema global de análise e previsão do oceano fornece análises diárias e previsões, dos satélites NOAA e disponibilizados no site do *Copernicus*, de 10 dias para as ondas da superfície dos oceanos.

Para a elaboração dos mapas de TSM, foram utilizadas informações diárias e mensais de temperatura, salinidade, correntes, nível do mar, profundidade da camada mista e parâmetros de gelo de cima para baixo sobre os oceanos disponíveis no *site copernicus*, através do Sentinel-3, que além de identificar a cor do oceano consegue medir a temperatura.

As Figuras 20 à 23 representam exemplos de informação Meteo-oceanográfica para o dia 24 de julho de 2019. Onde os valores mais altos são representados pela cor vermelha e os valores mais baixos e mais fracos representados pela cor azul.

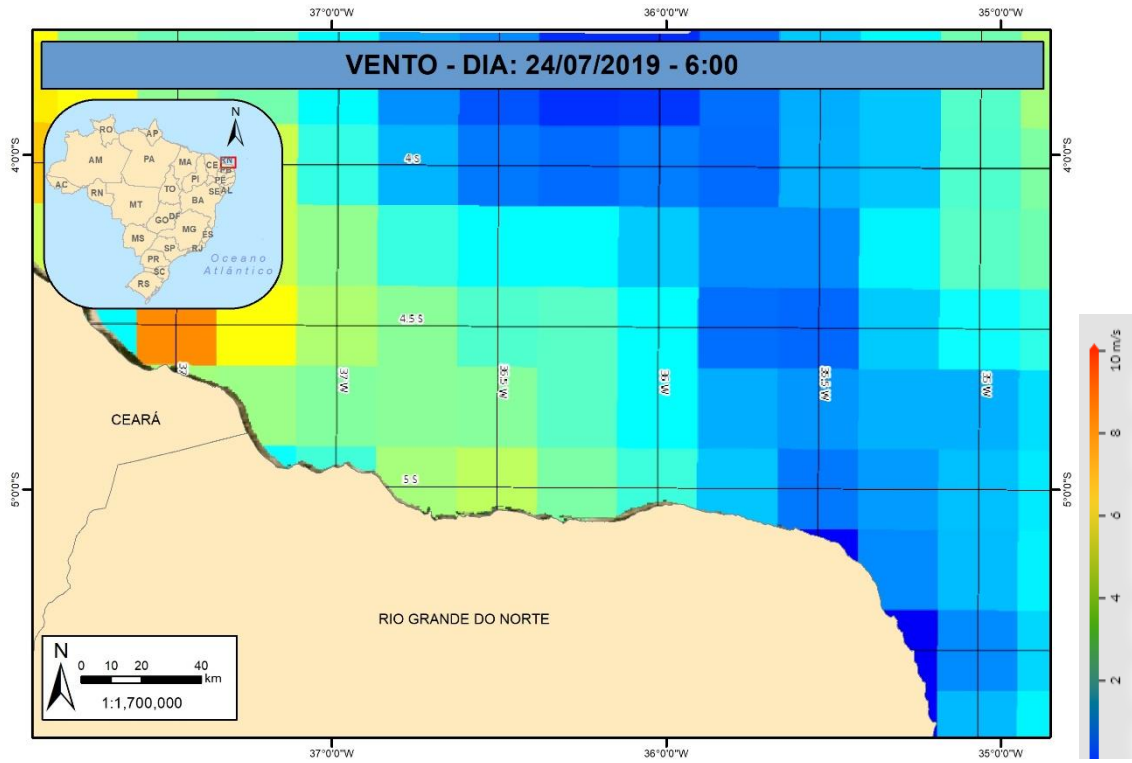


Figura 20: Vento do dia 24/07/2019

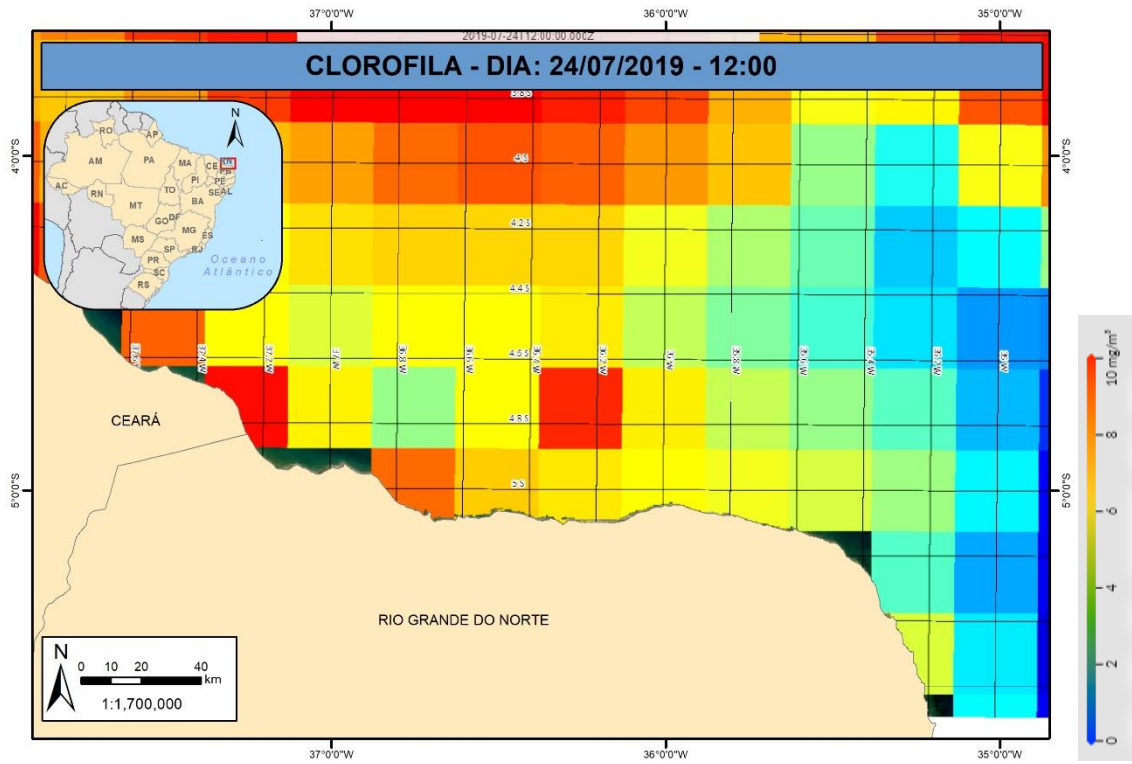


Figura 21: Concentração de clorofila do dia 24/07/2019

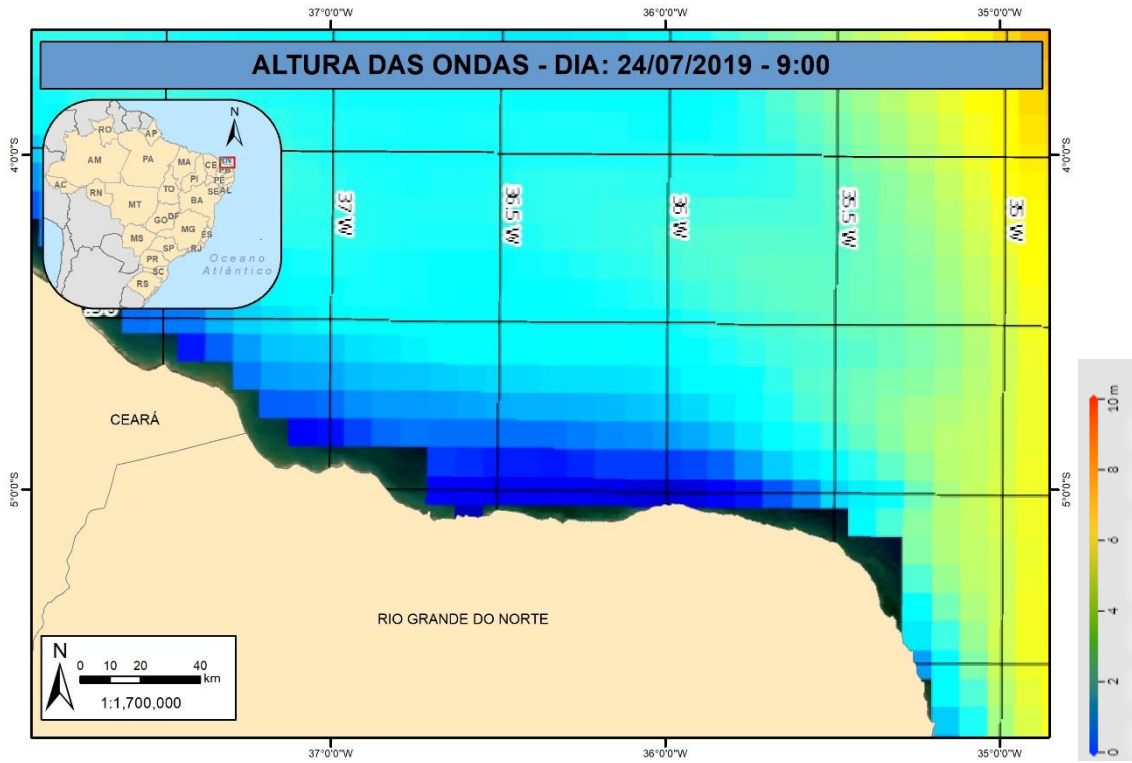


Figura 22: Altura significativa das ondas, do dia 24/07/2019

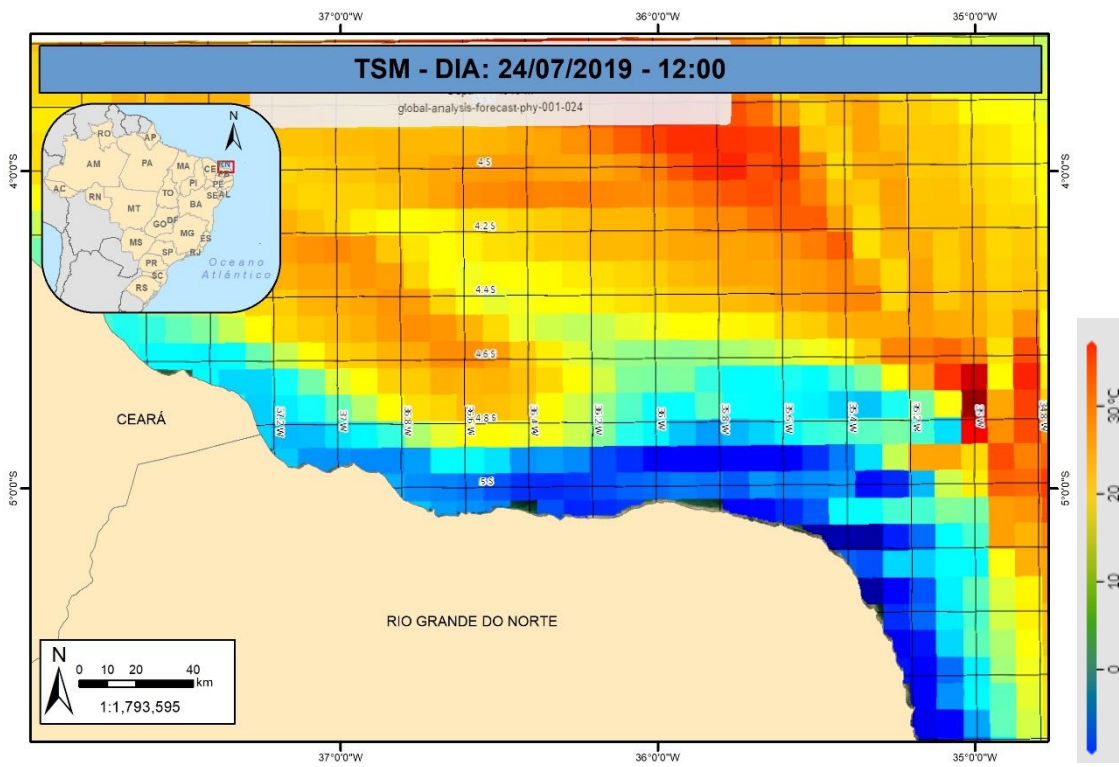


Figura 23: Temperatura da superfície do mar (TSM), do dia 24/07/2019

## 4.4 Identificação de embarcações

Tal como foi abordado no capítulo 2, a identificação das embarcações é um ponto muito importante para a identificação de falsos alvos de derrames de óleo no mar.

A localização das embarcações foi feita com a ferramenta *Ocean object detection* da aplicação SNAP, que possui um algoritmo automático para identificar objetos no mar. Os pontos brilhantes com níveis de cinzento acima de 180 (para 8 bits) foram consideradas embarcações.

A identificação das embarcações foi realizada com base nas seguintes operações: (i) Pré-processamento - calibração da imagem por forma a facilitar uma pré-seleção dos *pixéis* brilhantes; (ii) Máscara - criada para separar a terra do mar, por forma a que a deteção dos *pixéis* brilhantes seja focada apenas na superfície do mar. Esta operação é realizada com base no Modelo Digital de Elevação (DEM), sendo neste estudo utilizado os dados SRTM (*Shuttle Radar Topography Mission*) obtidos a partir do *download* automático durante o processamento do SNAP; (iii) Pré-triagem - os objetos são identificados com um detetor *Constant False Alarm Rate* (CFAR). e (iv) Correção do terreno - última etapa para minimizar a influência do ângulo de incidência local na imagem.

O algoritmo CFAR tem como objetivo encontrar as embarcações, através da deteção de *pixéis* mais brilhantes em comparação com outros *pixéis* nas áreas circundantes, utilizando a técnica do Limiar Adaptativo. Cada pixel é testado em três janelas a envolvê-lo: a de destino, a de proteção e a de fundo, (Figura 24). A dimensão da janela de destino tem aproximadamente o tamanho do menor objeto a ser identificado, a de proteção tem aproximadamente o tamanho do maior objeto encontrado e a de fundo deve ter uma dimensão suficiente grande por forma a estimar com precisão as estatísticas locais. Durante esta operação, falsas deteções são eliminadas com base em medições de alvo simples. O algoritmo agrupa *pixéis* detetados adjacentes num único agrupamento, em seguida, as informações de largura e comprimento dos clusters são extraídas. Com base nessas medidas e nos critérios de discriminação de entrada do utilizador, os clusters que são muito grandes ou muito pequenos são eliminados. Neste estudo, 50m e 250m foram determinados para o tamanho mínimo e máximo do alvo. Esses valores foram selecionados com base na estimativa do tamanho do navio e alguns testes preliminares.




Figura 24: Níveis dos produtos dos modos de aquisição da missão Sentinel-1  
Fonte: ESA, 2021.

## 4.5 Cruzamento dos dados

Através da observação das diferentes imagens foram definidas três classes: a embarcação (*pixéis* muito brilhantes), óleo (*pixéis* de cor escura distribuídos sob uma forma longitudinal) e a água (restantes *pixéis*). A classe embarcação foi validada pela ferramenta “*Ocean object detection*” do SNAP. A classe óleo, foi validada com base nas diferentes técnicas de DR, nomeadamente, *Change Detection*, *Oil Spill Detection*, Textura e a Classificação Supervisada pela Máxima Verossimilhança. Os restantes *pixéis* das imagens foram classificados como água.

## 4.6 Extração da mancha com técnicas de Detecção Remota

### 4.6.1 *Change Detection*

O princípio básico deste método é limitar a área do derrame a partir da subtração de duas imagens da mesma área, mas em épocas diferentes. O processo de deteção semiautomática de derrame de óleo foi realizado no *software* SNAP, seguindo o fluxograma da Figura 25. Para gerar a imagem da diferença, foi necessária a criação de um *stack*, ou seja, a criação de um único produto contendo todos os produtos (neste caso as imagens) como bandas. Essa função permite colocar duas imagens sobrepostas espacialmente, conseguindo assim estabelecer pontos em comum entre as imagens, e determinar os valores da diferença.

Neste caso, foram subtraídos os *pixéis* da imagem de 12/07/2019 (pré derrame) com a de 24/07/2019 (durante o derrame) e a de 05/08/2019 (após o derrame) com a 24/07/2019 (durante o derrame), resultando duas imagens que representam as alterações entre épocas.

O mesmo processo foi aplicado para a mancha mais ao sul, onde as imagens utilizadas foram adquiridas no dia 10/09/2019 (pré derrame), 22/09/2019 (durante o derrame) e 04/10/2019 (pós derrame).

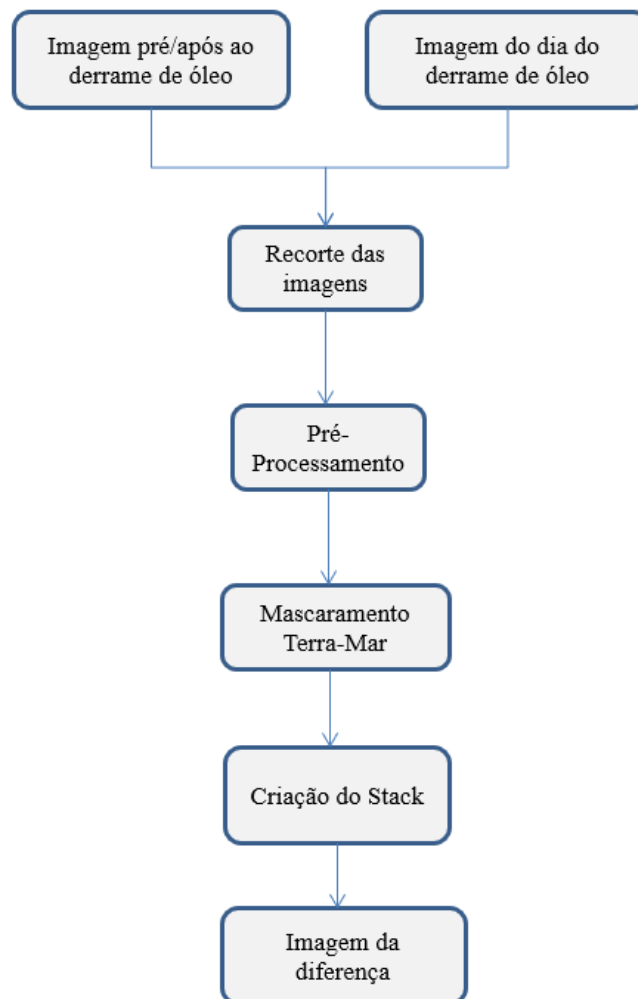


Figura 25: Processo semiautomático de *Change Detection*.

#### 4.6.2 *Oil Spill Detection*

O módulo *SAR Ocean Application* do SNAP possui uma ferramenta denominada por *oil spill detection* que permite mapear de forma automática derrames de óleo. O princípio básico desta ferramenta consiste na identificação de *pixéis* escuros no mar, a partir da

definição de um limiar adaptativo, agrupando-os em clusters, cuja dimensão mínima é definida pelo utilizador (Misra e Balaji, 2017). O algoritmo do limite adaptativo consiste na estimação do nível médio local da refletância dos *pixéis* numa janela de determinada dimensão. Os *pixéis* classificados como escuros são os que possuem valores de refletância inferiores à refletância média local da janela com uma determinada tolerância definida pelo utilizador. As etapas do processamento automático do SNAP estão representadas na Figura 26. Foram efetuados diversos testes com diferentes valores de entrada: tamanho da janela, limiar e tamanho do cluster. Os valores *default* que vem pré-definidos no *software* foram também utilizados.

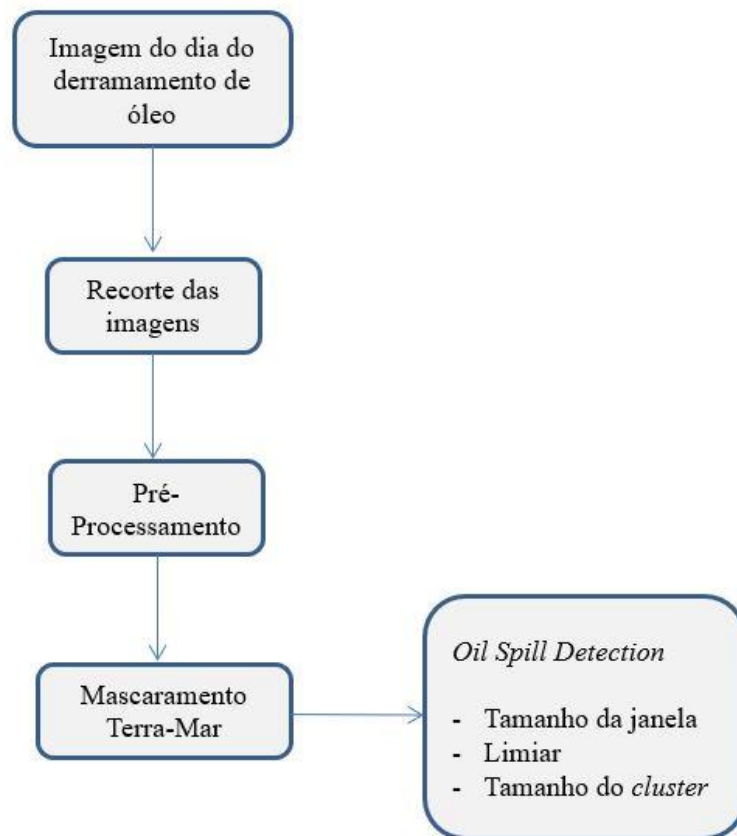


Figura 26: Processo automático com a ferramenta *Oil Spill Detection*

### 4.6.3 Textura GLCM

O cálculo da textura envolveu várias etapas. Primeiro foi realizada uma análise visual, com base na forma, no tamanho e nas informações adicionais adquiridas dos dados Meteo-oceanográficos, de seguida a imagem digital original foi recortada em torno da

eventual mancha de óleo a fim de reduzir o tempo de processamento dos cálculos. Por último foi efetuada uma análise de textura através do algoritmo *Gray level co-occurrence matrix* (GLCM).

A análise da textura foi realizada com o *software ImageJ* usando o *plugin GLCM Texture Analyzer 1.3*. Foi calculada para as várias imagens a matriz GLCM para servir de base à determinação dos parâmetros de textura dentro de uma janela de pesquisa. O *plugin* tem uma funcionalidade um tanto limitada, uma vez que o utilizador não tem um acesso ao GLCM real e só pode especificar dois parâmetros para controlar a matriz distância/deslocamento entre dois *pixéis* e a sua relação espacial (direção: 0°, 90°, 180° ou 270°). O *plugin* atualmente funciona com imagens de 8 *bits* consistindo em 256 níveis de quantificação (Figura 27).

Neste estudo foram utilizadas distâncias entre *pixéis* de 7, 15 e 30, para as quatro direções.

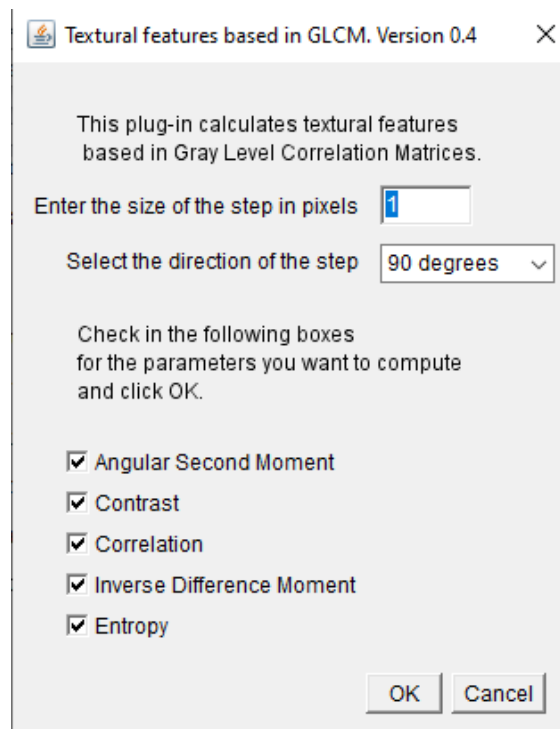


Figura 27: Interface do ImageJ plugin GLCM Texture Analyzer

#### 4.6.4 Classificação supervisionada pela máxima verossimilhança

Utilizando o método de classificação supervisionada pela máxima verossimilhança, a imagem foi classificada usando assinaturas espectrais de categorias já conhecidas, obtidas a partir de amostras de feições ou objetos de interesse, tal como embarcações, água ou

óleo, em formato de polígonos. Este método foi realizado utilizando a ferramenta existente no ArcGIS 10.8.

Foram digitalizados polígonos para cada classe para ter como resultado as áreas de treino, tendo sempre em atenção, que dentro das áreas digitalizadas não podem existir *pixéis* que não correspondam às classes que se está a representar. Devido às cores que as imagens SAR possuem este procedimento é difícil e moroso. Foram digitalizadas quatro áreas de treino por cada feição (água, óleo e embarcações) num total de 12 áreas. Por fim, o classificador utilizado associou os *pixéis* à assinatura espectral mais parecida com base no cálculo da probabilidade condicional.

## 5. RESULTADOS E DISCUSSÃO

### 5.1 Processamento das imagens Sentinel 1

A Figura 28 mostra a imagem original SAR de 24/07/2019 recortada com a polarização VV.

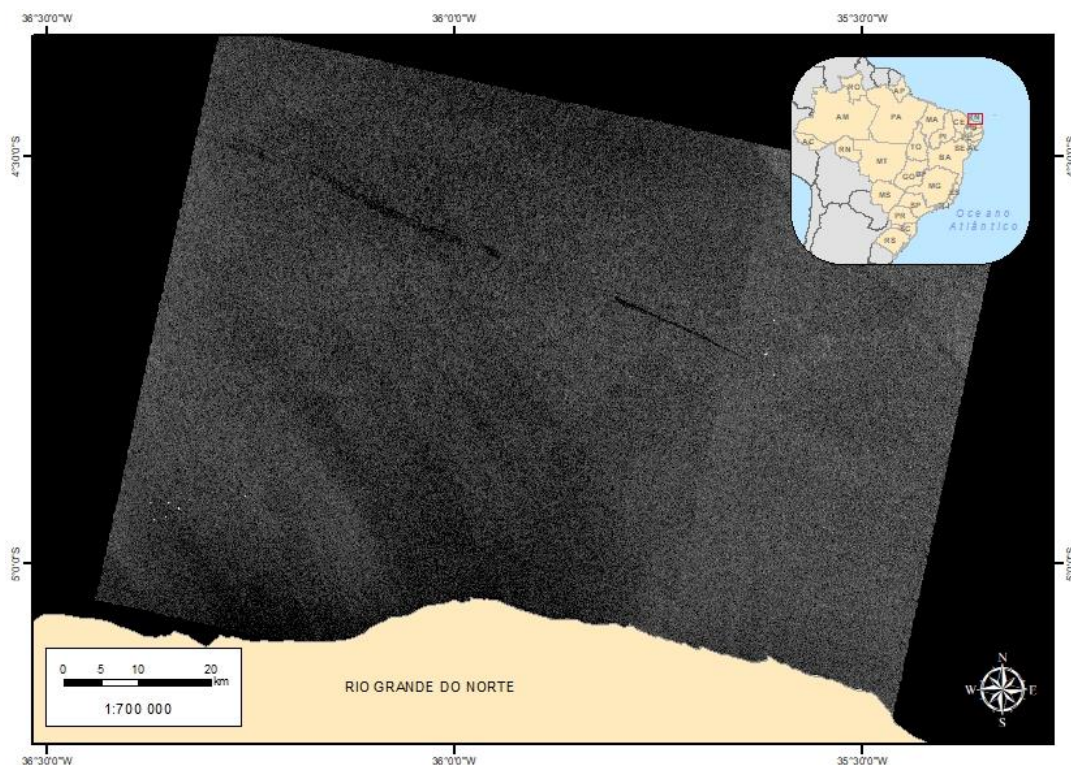


Figura 28: Imagem original SAR, polarização VV

As Figuras 29 à 35 dizem respeito às imagens filtradas utilizando os filtros, *Boxcar*, *Frost*, *Gamma Map*, *Lee*, *Lee Sigma*, *Mediana* e *Refined Lee*.

Em percepção global, os filtros são muito parecidos e observou-se que o ruído *speckle* reduziu. Verificou-se que todos os filtros preservaram as bordas e contrastaram suavemente as regiões de possíveis manchas de óleo.

A resolução dos filtros *Boxcar*, *Frost* e *Gamma map* e *Lee* para manipulação individual dos *pixéis*, não foi considerada apropriada, pois visualmente quase não há redução dos ruídos. Na imagem do filtro da mediana podemos observar uma ligeira diferença no contraste da mancha de óleo com o restante da imagem. No filtro *Refined Sigma*, este contraste melhora.

Após uma comparação entre todos os filtros, concluiu-se que o filtro *Lee Sigma* atendeu mais efetivamente ao requisito de melhor interpretação visual, e assim tendo sido escolhido para dar sequência ao restante processamento.

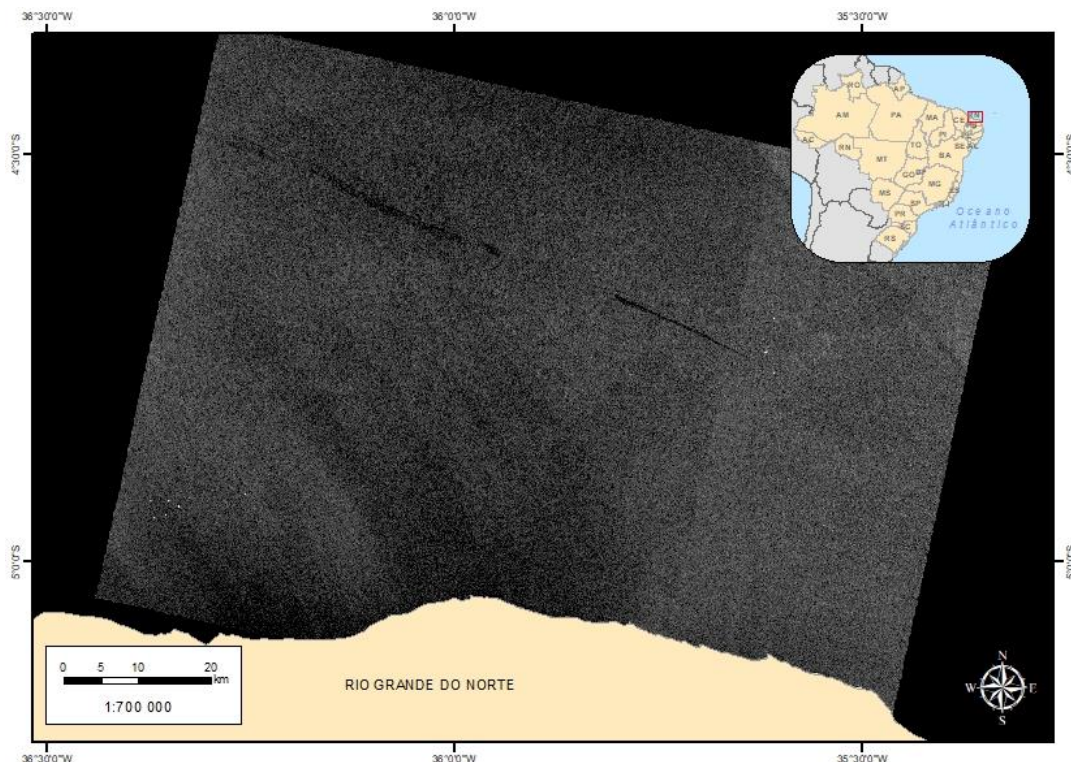


Figura 29: *Boxcar*.

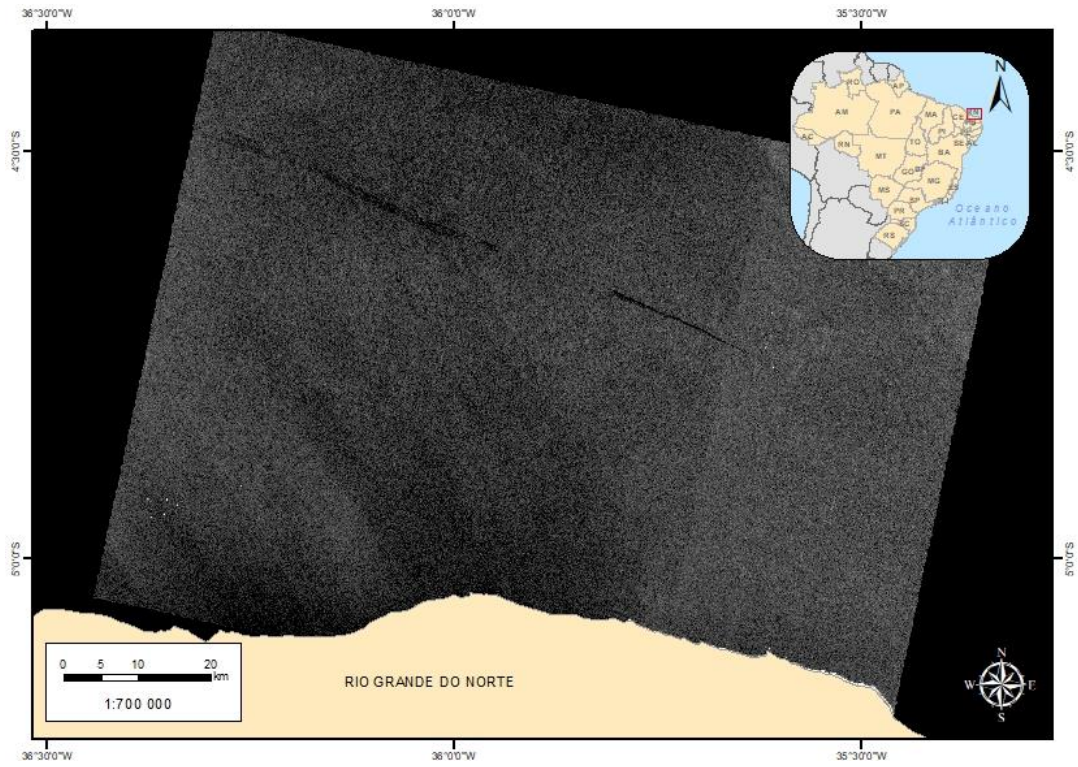


Figura 30: Frost.

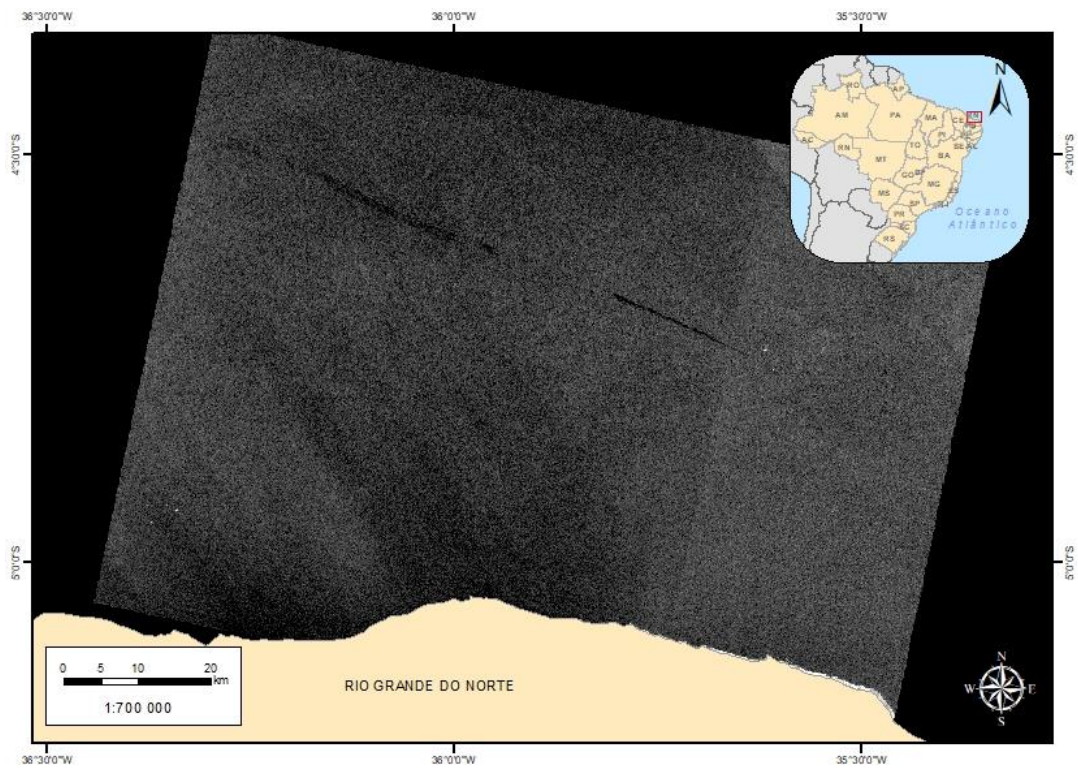


Figura 31: Gamma Map.

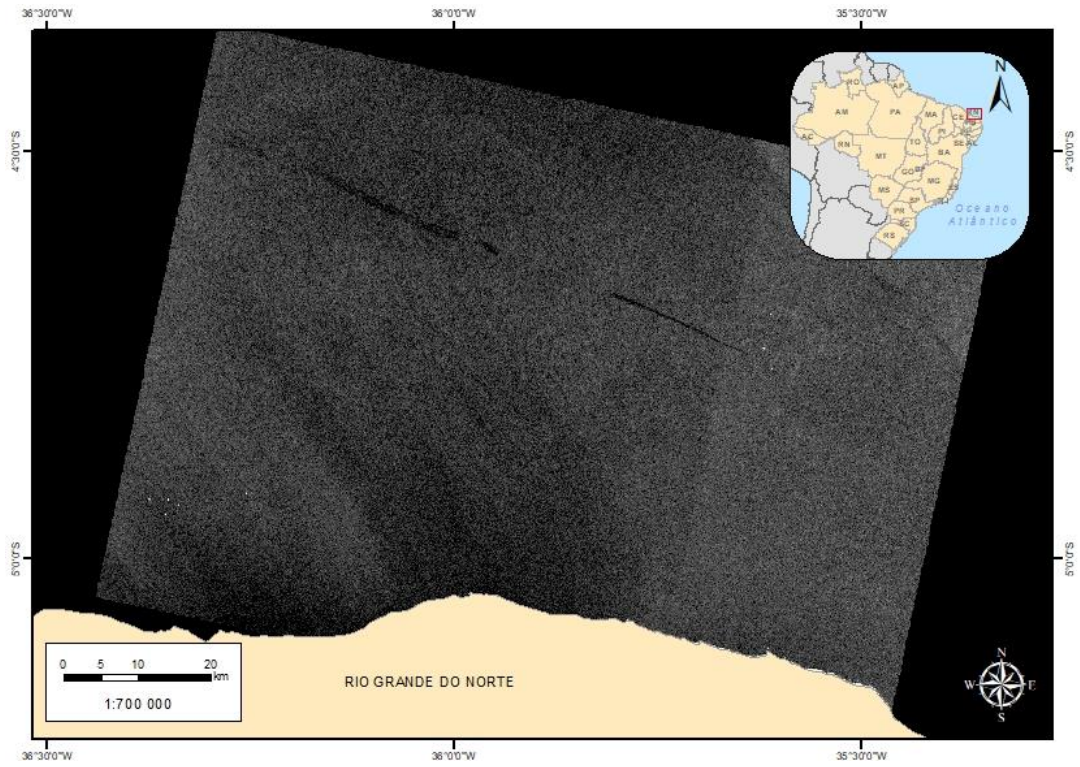


Figura 32: Lee

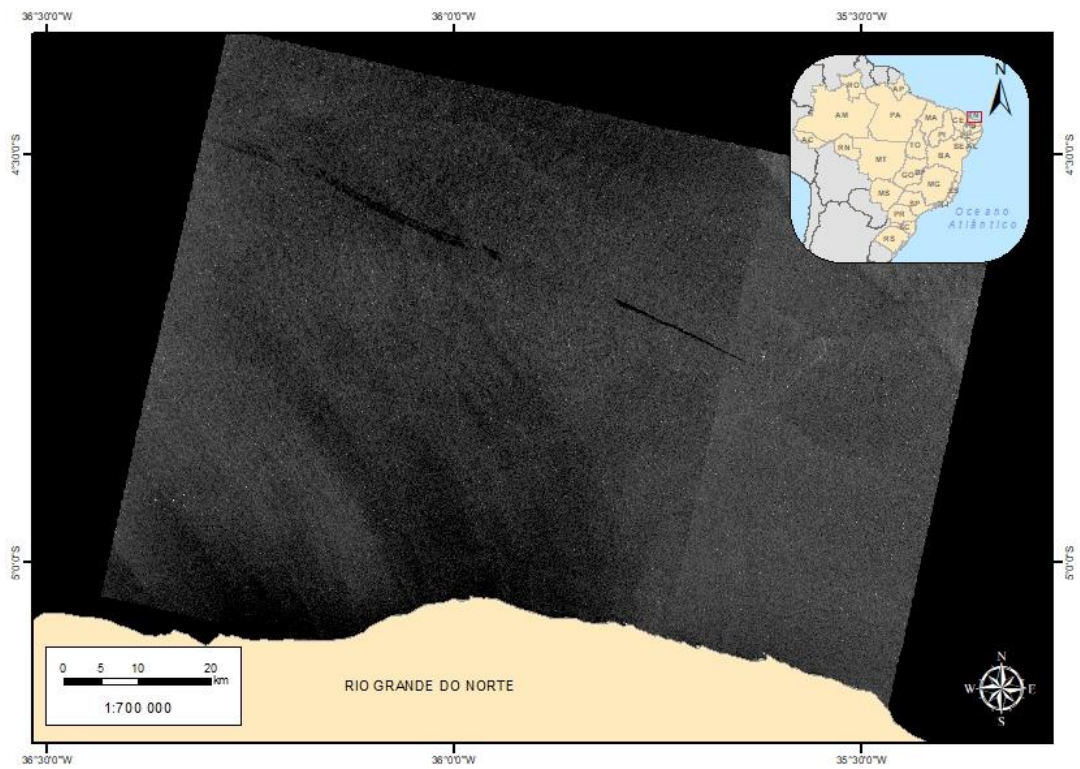


Figura 33: Lee Sigma

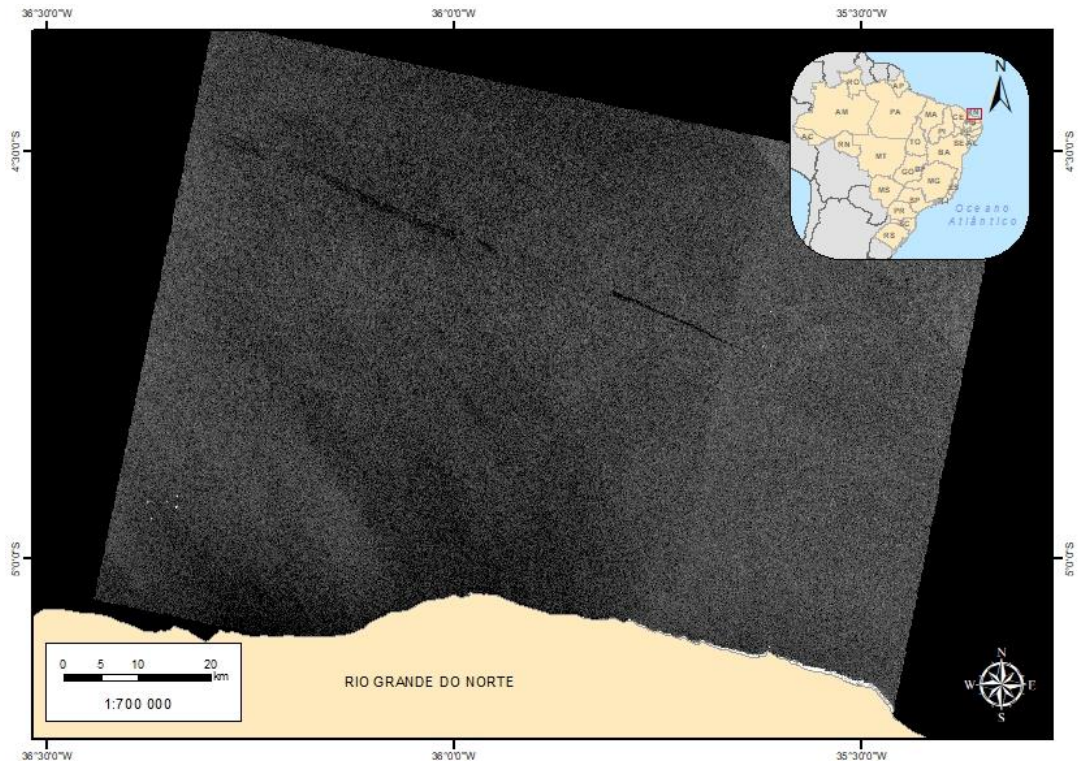


Figura 34: Mediana

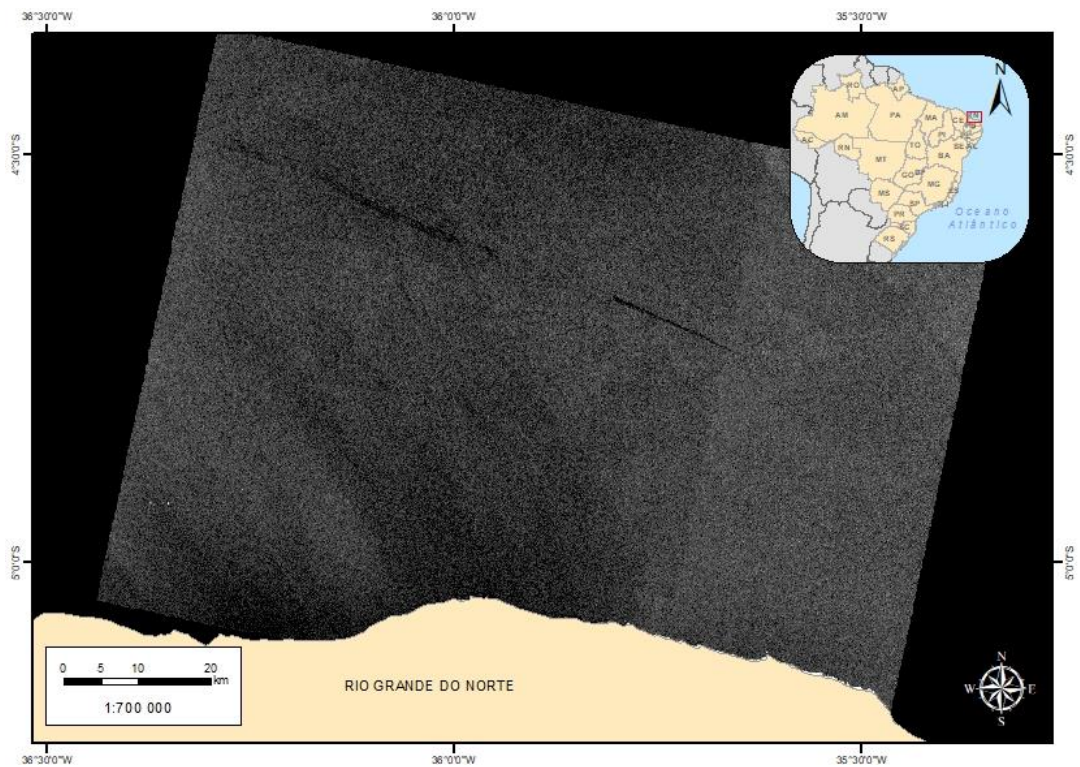


Figura 35: Refined Lee

A Figura 36 mostra o resultado do processo de *multilooking*, que também diminuiu o efeito do ruído *Speckle*. Esta técnica foi utilizada na imagem original, sendo somente feita para melhorar o resultado visual da mancha, já que este processo faz com que os pixels percam seus valores reais.

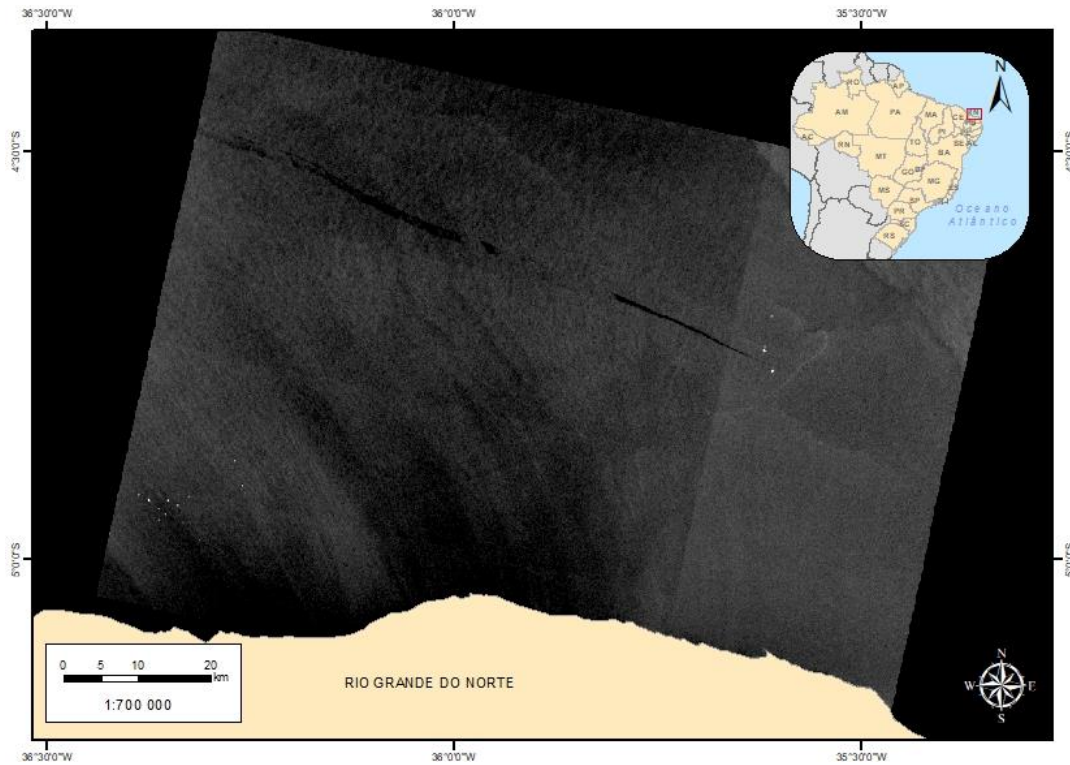


Figura 36: Multilooking

## 5.2 Identificação das embarcações

As Figuras 37 e 38 mostram o resultado da ferramenta “*Ocean object detection*” em que foram identificadas as embarcações nas áreas de estudo (a vermelho).

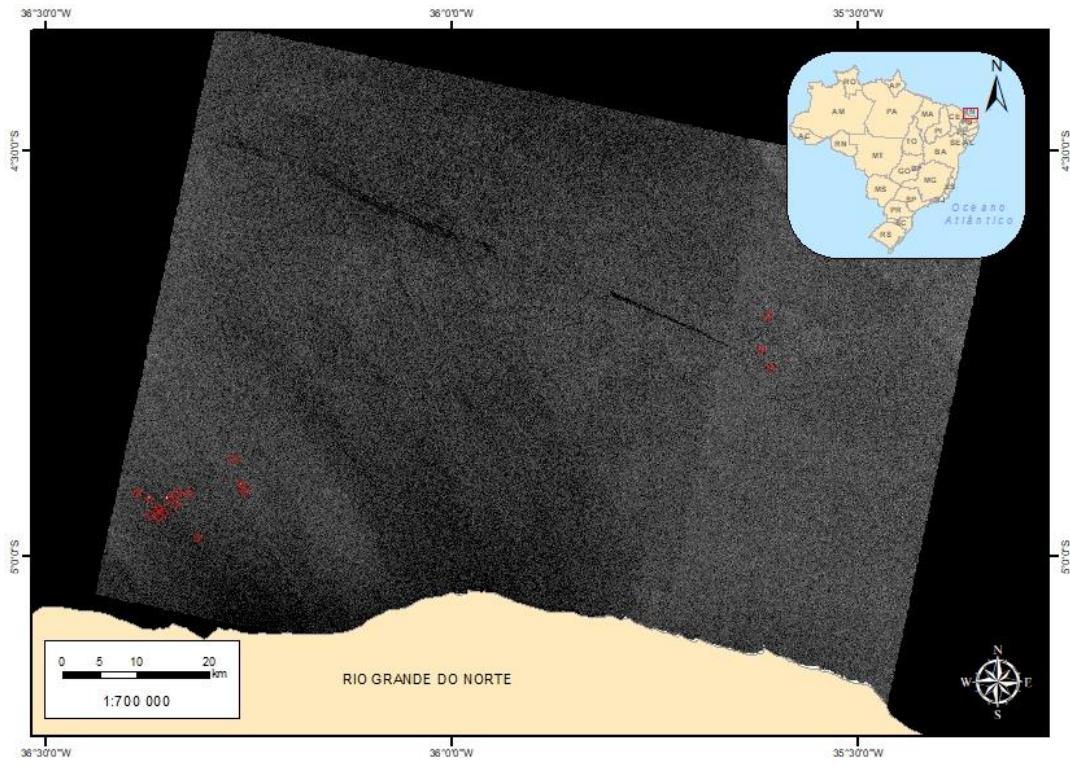


Figura 37: Identificação de embarcações N




Figura 38: Identificação de embarcações SE

### 5.3 Cruzamento dos dados

A figura 39 e 40 mostram setas com diferentes cores que indicam as classes definidas: a vermelho foi considerado óleo, a azul a água e a preto as embarcações.




Figura 39: Classes: água, óleo e embarcação/plataforma N




Figura 40: Classes: água, óleo e embarcação/plataforma SE

As figuras seguintes mostram o resultado do cruzamento de dados Meteo-oceanográficos, nomeadamente, o vento, a altura das ondas, a temperatura da superfície do mar e a concentração de clorofila com as respetivas classes.

A partir da análise da Figura 41, pode-se observar que na região da área de abrangência da imagem de 24/07/2019, ocorrem ventos entre 2,5 e 4,5 m/s. Segundo Miranda (2004) estes valores são adequados para a deteção de óleo no oceano. Portanto, foi descartada a existência de falsos alvos de manchas de óleo porque não existiam velocidades de vento baixas que pudessem provocar manchas.

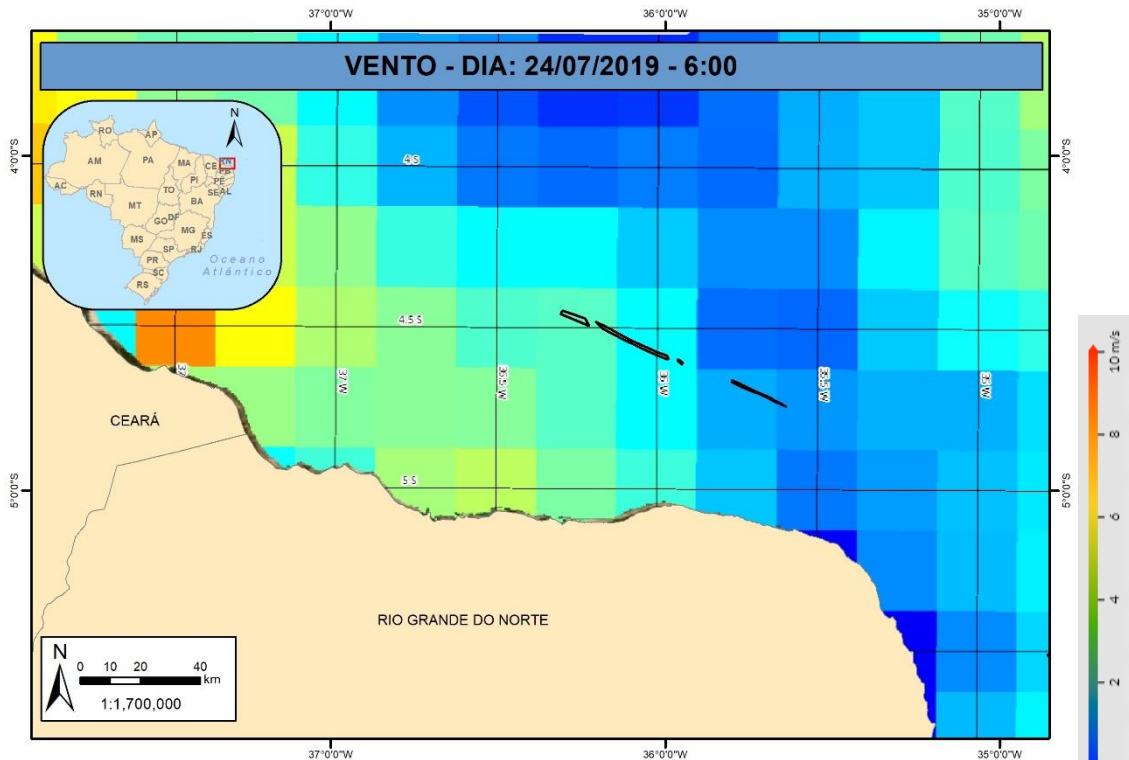


Figura 41: Vento (24/07)

Na Figura 42 é observada a ocorrência de ondas entre 1,0 e 1,5 m de altura, o que define uma ótima condição do estado do mar para identificação de manchas de óleo.(Solberg *et al.* (2007), Mera *et al.* (2012) e Fingas e Brown *et al.* (2017)

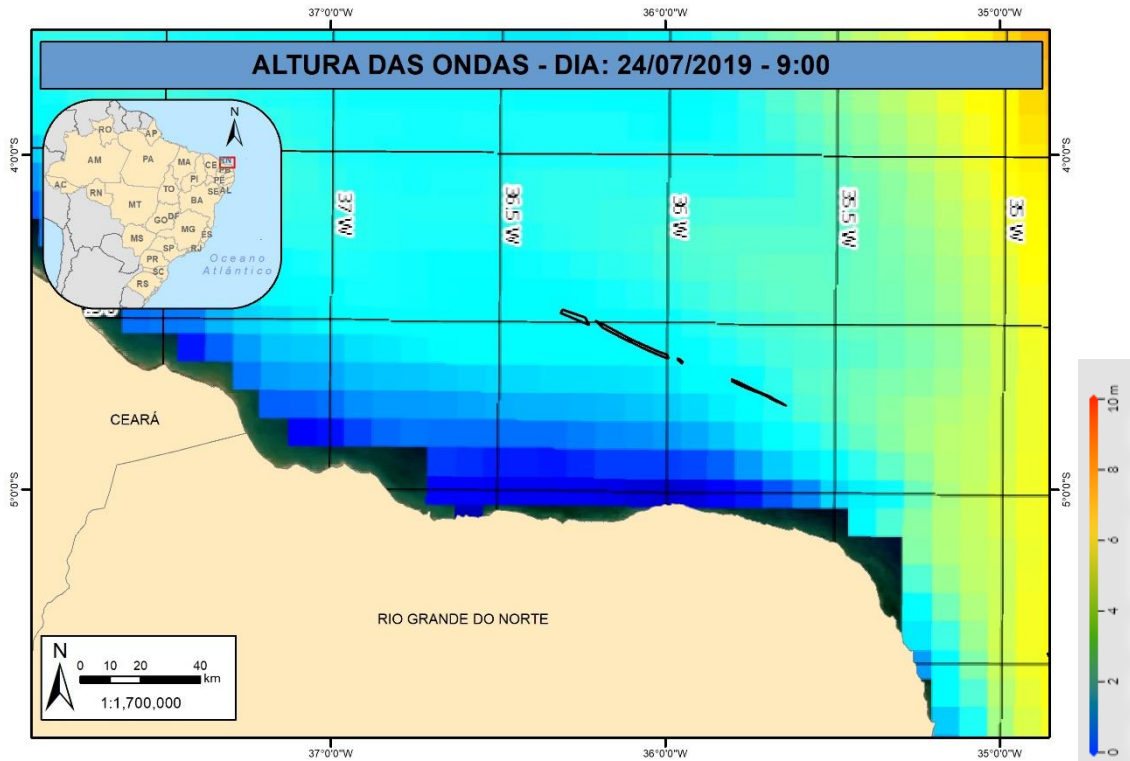


Figura 42: Altura das Ondas (24/07)

A Figura 43 mostra a TSM da área de estudo. As temperaturas identificadas na zona onde se localiza a mancha escura são baixas em relação às áreas circundantes, isso pode caracterizar uma zona de ressurgência. Este movimento ascendente das águas marinhas sub superficiais que se traduz em águas mais frias na superfície do mar, é propícia ao aparecimento de feições naturais que podem ser caracterizadas como manchas escuras (Fingas, 2017). Contudo, analisando as imagens anteriores e a forma longitudinal da feição, considerou-se que as zonas mais escuras da imagem são efetivamente de óleo e não de ressurgência.

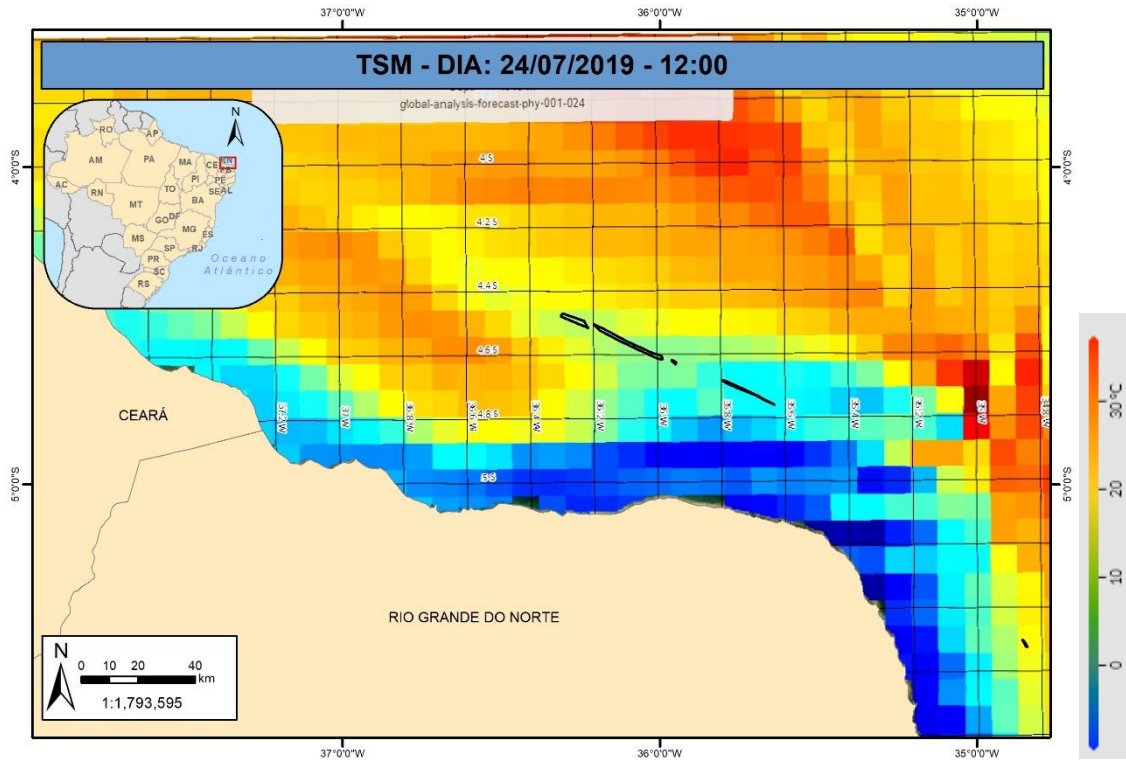


Figura 43: TSM (24/07)

A Figura 44 mostra a concentração de clorofila entre 5 a 6.5  $\text{mg}/\text{m}^2$  na área de estudo, o que caracteriza a área com uma baixa concentração de clorofila na zona da mancha mais escura, sendo assim, foi descartado um possível falso alvo.




Figura 44: Concentração de clorofila (24/07)

O mesmo processo de cruzamento de dados foi feito para a mancha mais ao sul como pode se observar nas figuras seguintes. A partir da análise da Figura 45, pode-se observar ventos entre 6,5 e 7,0 m/s. Segundo Miranda (2004) estes valores são adequados para a detecção de óleo no oceano. Na Figura 46 é observada a ocorrência de ondas com menos de 2,0 metros de altura, o que caracteriza uma condição adequada para detetar um derrame de óleo. Como pode observar na Figura 47, a temperatura da água gira em torno de 20 graus e está uniforme em toda a área, o que permite uma análise clara. A Figura 48 mostra a concentração de clorofila com menos de 7 mg/ m<sup>2</sup> na área de estudo. Após o cruzamento dos dados meteo- oceanográficos pode se excluir a ideia de falsos alvos na área, pois as condições eram propícias para a identificação da mancha de óleo, já que todos os parâmetros estão dentro das condições ideais para melhor identificar a mancha de óleo.

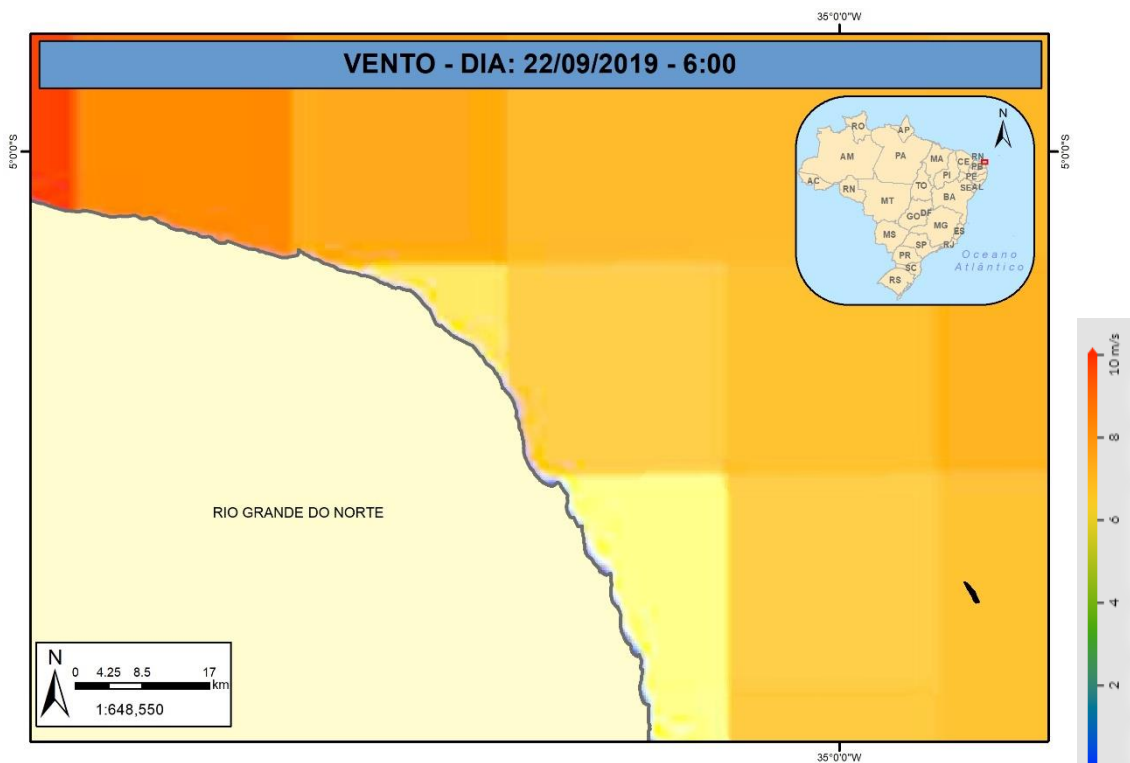


Figura 45: Vento (22/09)

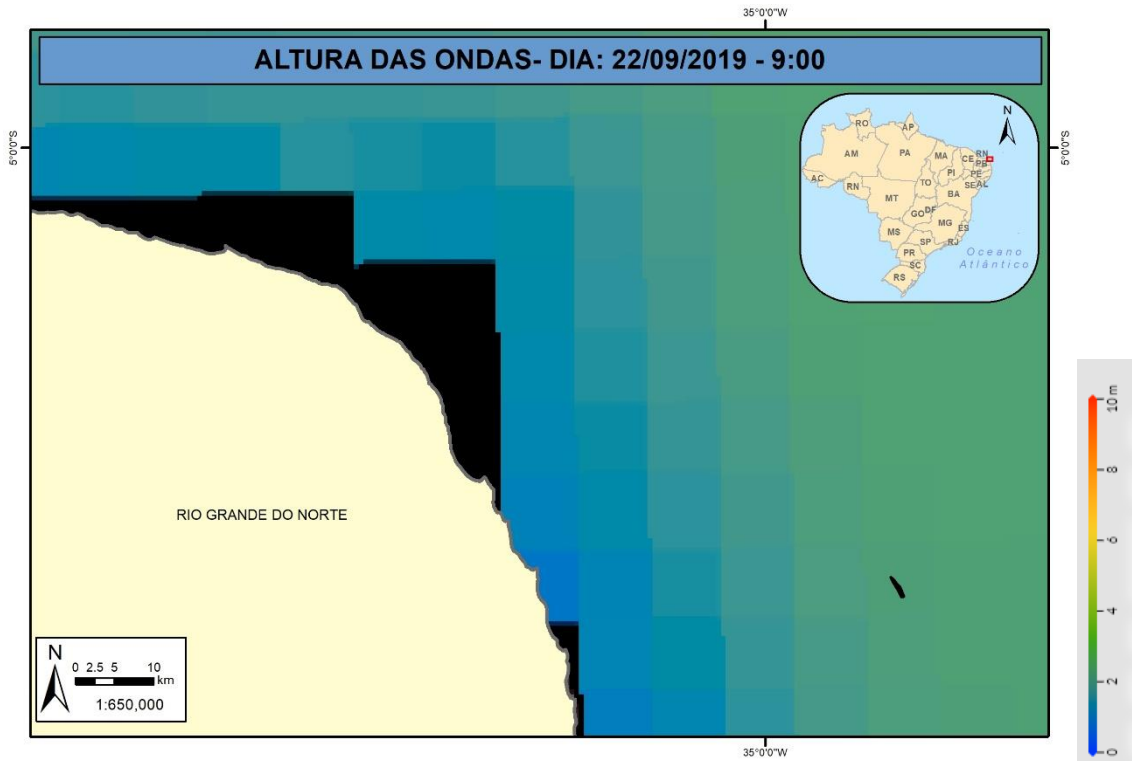


Figura 46: Altura das ondas (22/09)

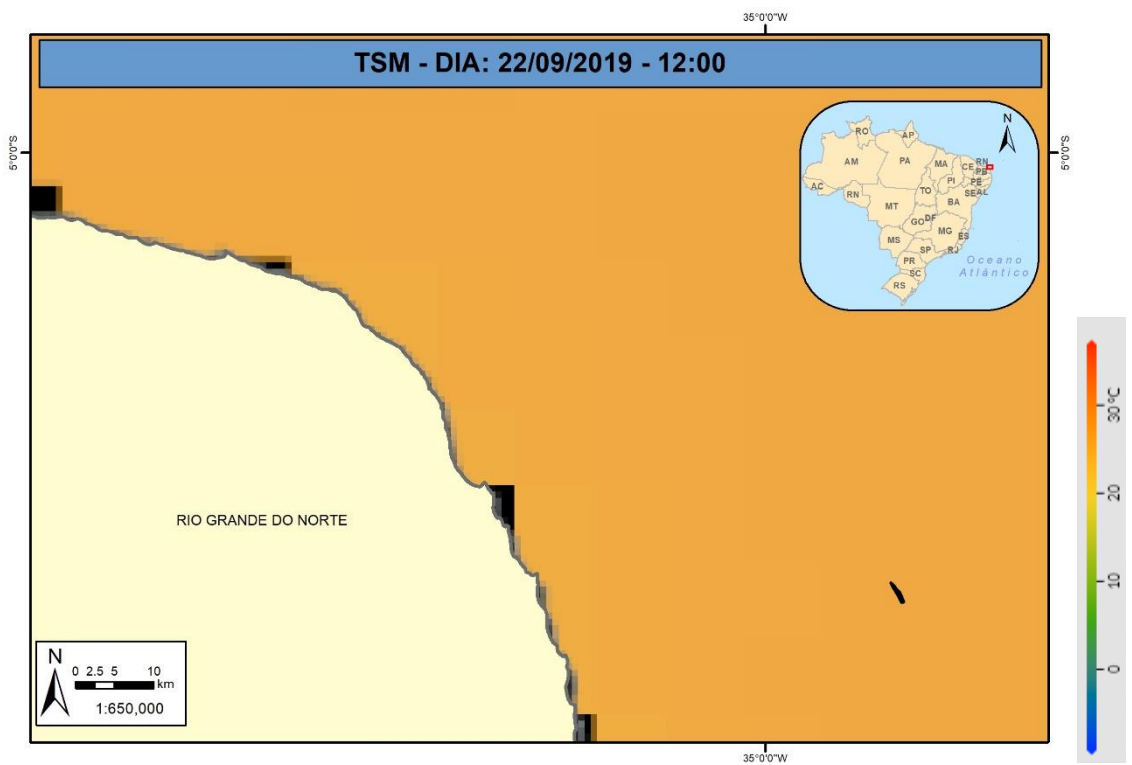


Figura 47: TSM (22/09)

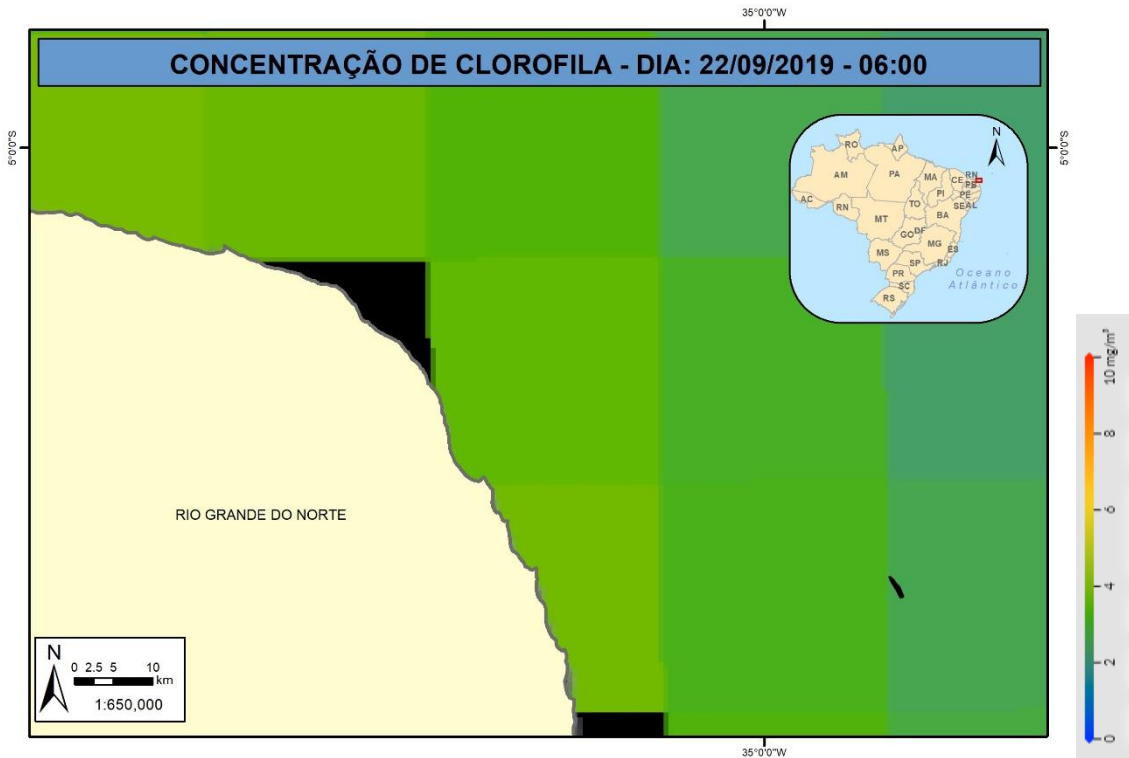


Figura 48: Concentração de clorofila (22/09)

## 5.4 Extração da mancha com técnicas de Deteção Remota

### 5.4.1 *Change Detection*

Geralmente, a água que foi poluída pela mancha de óleo tem valores de *pixels* mais baixos e, portanto, aparece mais escura na imagem.

A Figura 49 mostra o resultado do *change detection* entre as épocas pré e durante o derrame de óleo. A Figura 50 representa o *change detection* entre as épocas após e durante o derrame de óleo. Como é possível observar nas duas figuras, existem outros *pixels* na cor branca que não foram identificadas como mancha de óleo, isso deve-se ao filtro aplicado *Lee Sigma* não ter sido capaz de remover todo o ruído *speckle* da imagem original. Porém como o mesmo agrupamento longitudinal de *pixels* brancos foi identificado nas duas imagens de datas diferentes (pré e após derrame), pode-se portanto concluir que este agrupamento era o derrame de óleo e com isso pode excluir-se outras possibilidades como fatores naturais ou ruídos da imagem.

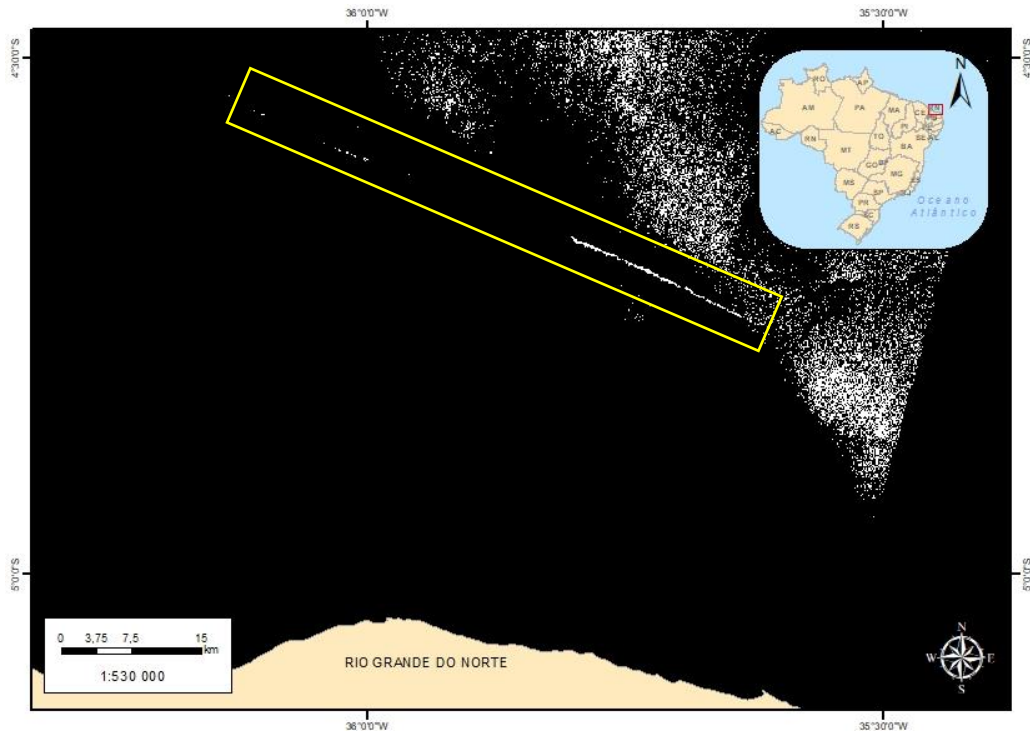


Figura 49: Resultado Change Detection (12/07-24/07)

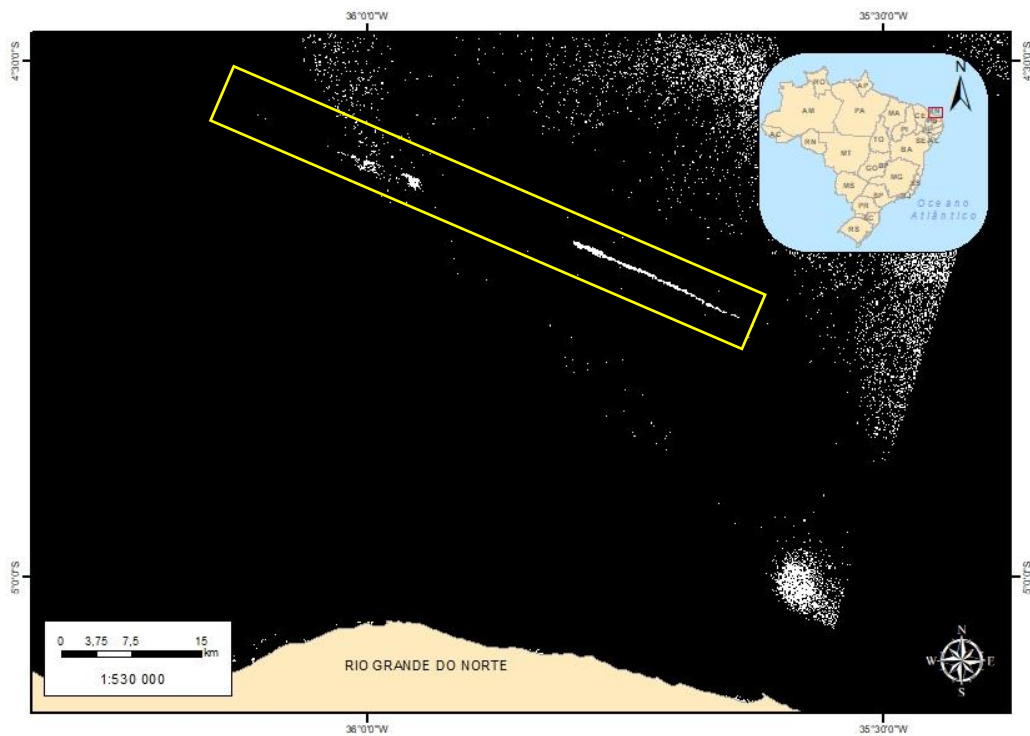


Figura 50: Resultado Change Detection (05/09-24/07)

A Figura 51 mostra o resultado do *change detection* da mancha mais ao sul, entre as épocas pré e durante o derrame de óleo e a Figura 52 mostra o resultado entre as épocas

após e a data do derrame. Como foi observado anteriormente, neste caso também é possível observar a alteração dos *pixéis* brancos espalhados pela imagem, mas também é possível observar a permanência de manchas longitudinais brancas nas duas imagens, o que possibilitou a identificação do derrame.




Figura 51: Resultado *Change Detection* (22/09-10/09)




Figura 52: Resultado *Change Detection* (22/09-04/10)

#### 5.4.2 *Oil Spill Detection*

A Figura 53, mostra o resultado da aplicação da ferramenta *Oil Spill Detection* utilizando os parâmetros padrão, janela de fundo (0.0), mudança de limiar (2.0 dB) e o tamanho mínimo de cluster de 0,1 km<sup>2</sup>. Neste caso o algoritmo não detetou nenhum pixel que tivesse correspondência com a mancha de óleo. A falha na identificação do derrame de óleo pela abordagem automática deve-se principalmente aos parâmetros padrão definidos no algoritmo. O tamanho da janela de fundo onde é calculado o valor médio local de refletância é muito pequeno o que faz que o valor médio local estimado da refletância seja bastante semelhante ao pixel individual na imagem, não sendo o suficiente para discriminar os *pixéis* escuros.

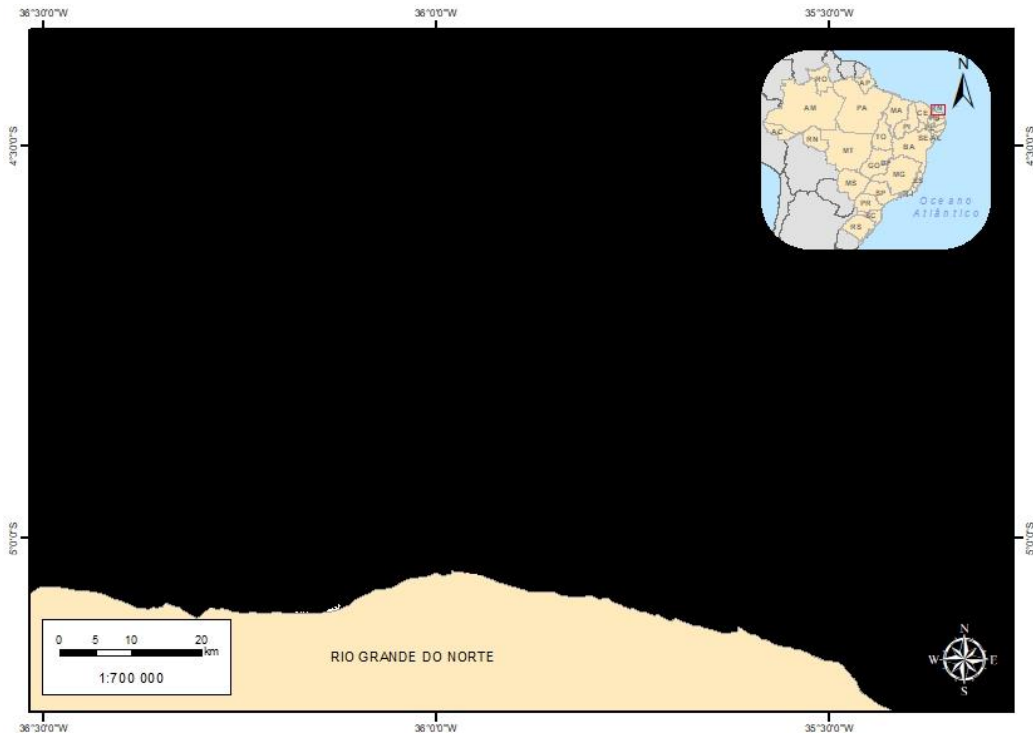


Figura 53: Resultado Oil Spill detection, Default

A Figura 54 é o resultado do teste 1 em que se procedeu ao aumento dos valores dos parâmetros: janela de fundo (75), mudança de limiar (2.0 dB) e o tamanho mínimo de cluster de  $0,1 \text{ km}^2$ . Verifica-se que a mancha de óleo começou a ser detetada.

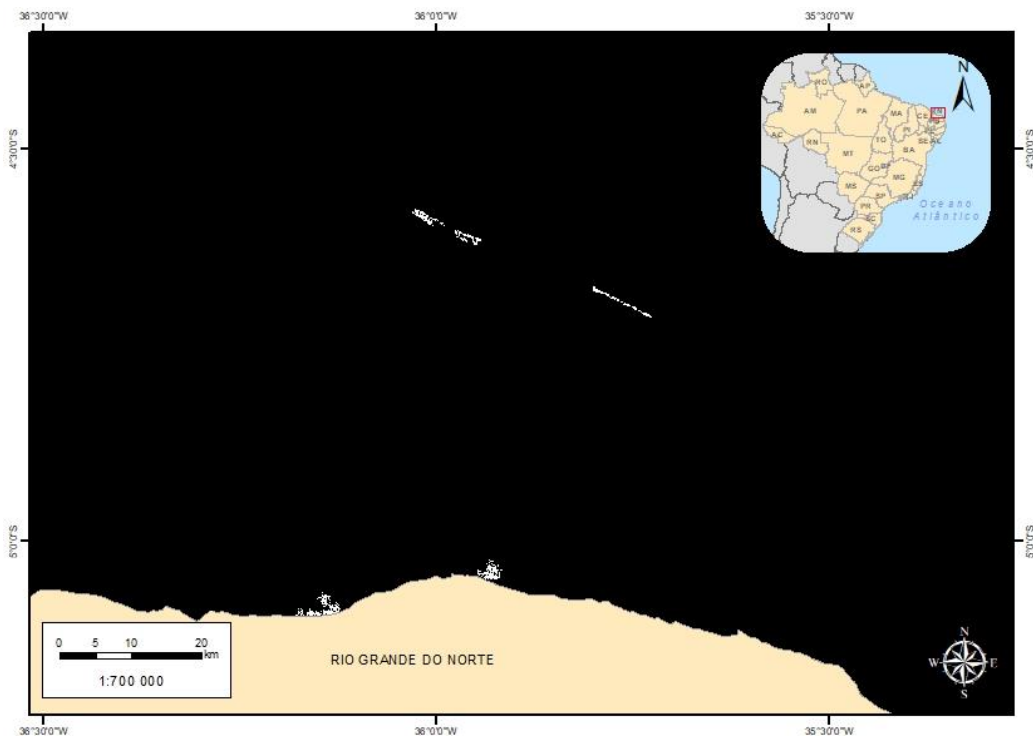


Figura 54: Resultado Oil Spill na detecção da mancha (teste 1)

Na Figura 55 (teste 2), a mancha de óleo foi totalmente identificada. Neste caso utilizaram-se os seguintes parâmetros: janela de fundo (100), a mudança de limiar (2,5 dB) e o tamanho mínimo de cluster de 0,1 km<sup>2</sup>.

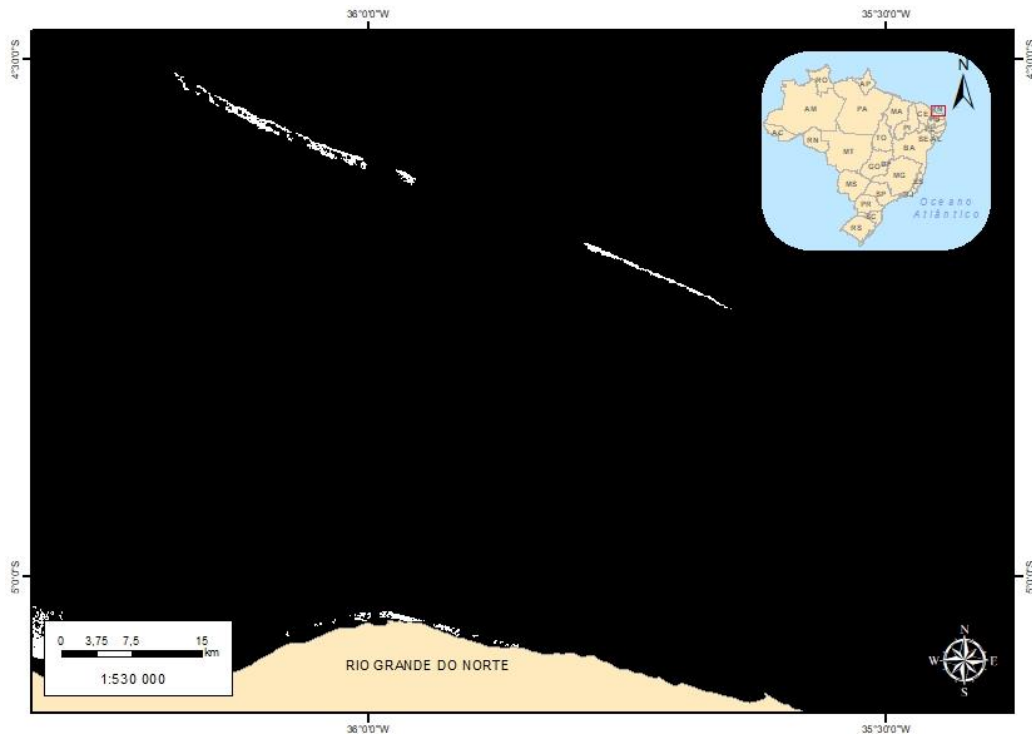


Figura 55: Resultado Oil Spill, na detecção da mancha (teste 2)

A Figura 56, mostra o resultado da segunda mancha mais a sul, com a aplicação dos mesmos parâmetros que foram definidos no teste 2 da primeira mancha. O resultado foi satisfatório, pois a mancha foi identificada corretamente.

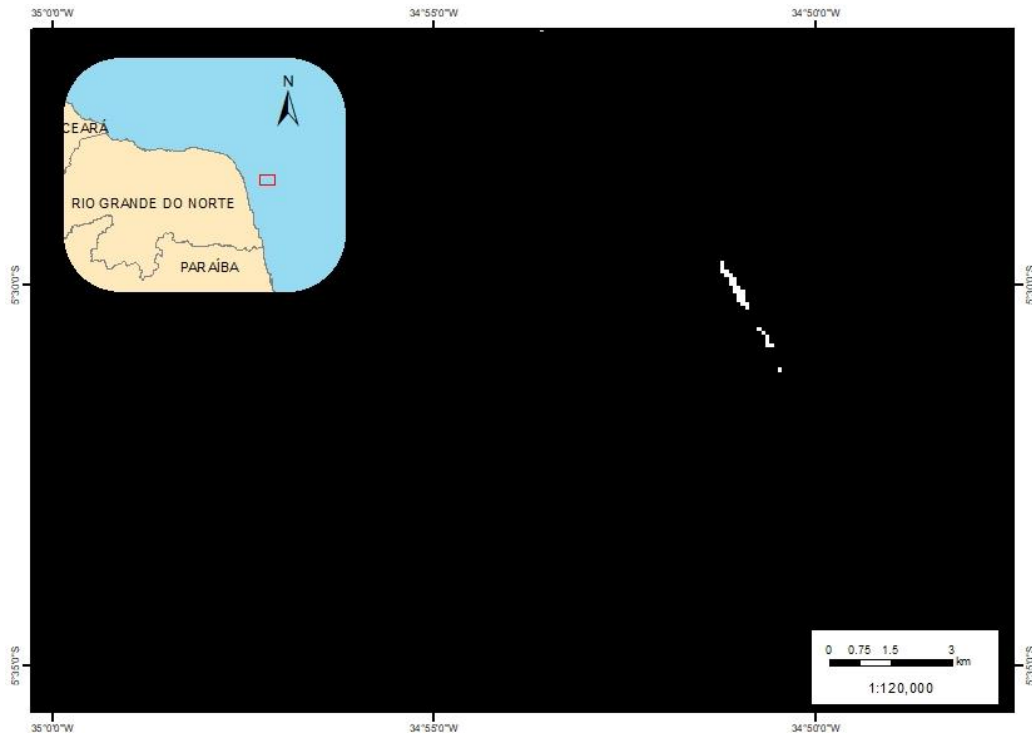


Figura 56: Resultado Oil Spill na detecção da mancha mais a sul.

### 5.4.3 Textura GLCM

A Figura 57 ilustra a imagem recortada de 24/07/2019, filtrada com o algoritmo do *Lee Sigma*.




Figura 57: Imagem SAR (29/07/2019)

As características textuais foram primeiramente extraídas de forma individual. As Figuras 58, 59 e 60 mostram os resultados da análise da textura com o tamanho da janela de 7 *pixéis* na direção 90°, distância de 15 *pixéis* na direção 90° e distância de 30 *pixéis* na direção 90°, respectivamente. Após os vários testes, concluiu-se que ao usar uma maior distância entre os *pixéis*, os detalhes da imagem SAR original são perdidos, nomeadamente a mancha. A distância de 7 *pixéis* permitiu extrair melhor as características texturais da imagem (e a respetiva mancha), sendo a entropia (a), a correlação (d) e a diferença inversa (e) as que apresentam melhores resultados.




Figura 58: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - 7×7 *pixéis*, na direção 90°.

Quando se utilizou 15 *pixéis* de separação apenas conseguiu identificar a mancha com a correlação.




Figura 59: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa - 15x15 pixels, na direção 90°

Como já foi referido anteriormente com 30 pixels de afastamento a mancha não é detetável com nenhum parâmetro textural com exceção da correlação, que apresenta a mancha com fraca definição e bastante dilatada.




Figura 60: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa -  $30 \times 30$  pixels na direção  $90^\circ$

A Figura 61 é a imagem final da textura composta pelos melhores parâmetros de textura: diferença inversa (10%), correlação (95%) e entropia (10%), para um afastamento de 7 pixels na direção  $90^\circ$ . A mancha de óleo detetada está representada a vermelho.





Figura 61: Resultado da primeira mancha (N) a partir da análise da textura.

A Figura 62, mostra a imagem da mancha mais a sul do dia 22/09/2019 recortada, com uma resolução de 10 metros e filtrada com o algoritmo do *Lee Sigma*.



**Figura 62: Imagem SAR (22/09/2019)**

As Figuras 63, 64 e 65, mostram os resultados dos testes em relação à mancha mais a sul (SE). A distância entre *pixéis* foi mantida em 7, pois esse valor foi o que permitiu extrair melhor as características texturais da imagem referente à primeira mancha, mudando apenas a direção, para 90°, 180° e 270°.

Nas três imagens é possível identificar a mancha, mas como pode se observar nas figuras 63 e 65 a mancha perde um pouco a nitidez e alguns detalhes de contraste com o restante da imagem, já na figura 64 (direção 180°) pode-se observar os limites com mais nitidez e um contraste maior.

A Figura 66 mostra o resultado com a aplicação de uma distância de 7 *pixéis* como mencionando anteriormente, e na direção 180°, devido a direção da mancha ser mais na vertical e onde foi observado o melhor mapeamento da mancha, a imagem final é composta pelos parâmetros de textura: segundo momento angular (20%) e o contraste (80%). A cor vermelha indica a presença do óleo e o ponto branco indica a embarcação.




Figura 63: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa -  $7 \times 7$ , na direção  $90^\circ$




Figura 64: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa -  $7 \times 7$ , na direção  $180^\circ$




Figura 65: a) Entropia, b) Segundo momento angular, c) Contraste, d) Correlação, e) Diferença inversa -  $7 \times 7$ , na direção  $270^\circ$




Figura 66: Resultado final da segunda mancha a partir da análise da textura

### 5.3.4 Classificação Supervisada pela Máxima Verossimilhança

A Figura 67 mostra o resultado da classificação pela Máxima Verossimilhança. Constatase que o algoritmo conseguiu diferenciar a mancha de óleo das demais feições presentes na imagem. No entanto, outros *pixéis* de valores baixos foram classificados como óleo, já os pontos referentes às embarcações foram bem classificados (pontos a vermelho). Podemos observar que na mesma área em que se encontram os *pixéis* pretos perto do continente existe também uma grande concentração de clorofila presente na água (ver Figura 44), que poderá explicar a presença de manchas escuras. Podemos assim excluir a hipótese de haver óleo próximo do continente o que constitui, portanto, um falso alvo.




Figura 67: Imagem final a partir da classificação da Máxima Verossimilhança

A Figura 68 mostra a classificação da segunda mancha (a SE), onde a cor preta indica a presença do óleo, e a cor vermelha indica as embarcações. O resultado da classificação mostra que a mancha foi mapeada com sucesso.




Figura 68: Imagem da segunda mancha a partir da classificação da máxima Verossimilhança.

Para melhorar os resultados sugere-se que no futuro seja realizada a aquisição de imagens de outros sensores com mais bandas espectrais, para que se possa identificar melhor as assinaturas espectrais dos objetos de estudo na fase de treino e assim conseguir distingui-los melhor na fase de classificação.

Dentro de todas as técnicas testadas, a classificação foi a que obteve melhores resultados chegando a apresentar um desempenho em torno dos 90% na deteção das duas manchas. A ferramenta automática *Oil Spill Detection* também teve um desempenho muito interessante conseguindo identificar mais de 80% do óleo. Porém esta última necessita de uma intervenção maior do utilizador no processo de configuração dos parâmetros necessários para identificar um derrame de óleo. Já a identificação da mancha pela textura e pelo *Change Detecion*, não apresentaram resultados muito satisfatórios. Apesar de a mancha ter sido identificada, ela foi mapeada apenas 75%.

A Tabela 5 mostra o valor de área em km<sup>2</sup> para cada mancha. As Tabelas 6 e 7 apresentam em percentagem a área mapeada de cada mancha utilizando as diferentes técnicas de extração.

**Tabela 5: Área total das manchas**

	Data	Área (Km <sup>2</sup> )
Mancha 1	24 de julho de 2019	47,73
Mancha 2	22 de setembro de 2019	0,93

**Tabela 6: Área detetada Mancha 1**

Técnica	Change Detection	Oil Spill	Textura	Classificação
Área (%)	75	85	70	91

**Tabela 7: Área detetada Mancha 2**

Técnica	Change Detection	Oil Spill	Textura	Classificação
Área (%)	75	92	75	92

## 6. CONCLUSÕES

Neste estudo, foram abordados os sistemas de satélite SAR, nomeadamente o Sentinel-1, para ilustrar o seu potencial na deteção dos derrames de óleo. O impacto causado por esses derrames depende de alguns fatores como tipo e quantidade de óleo, localização, tempo, profundidade da água, condições meteorológicas e características oceanográficas.

A capacidade dos sensores SAR em adquirir imagens independentemente da presença de nuvens, e de outras condições meteorológicas, tanto de dia como de noite, faz com que esse sensor tenha vantagem sobre outros sensores no que respeita à identificação de mancha de óleo no oceano, além de cobrir extensas áreas. Os satélites Sentinel-1 possuem uma resolução espacial e temporal adequada à monitorização de grandes acidentes de derrames de óleo no oceano. Identificar e monitorizar manchas de óleo em ambiente marinho, especialmente perto da costa, é essencial para mitigar os impactos ambientais e económicos da região.

Várias metodologias foram abordadas para a deteção de derrames de óleo no mar e para a diferenciação destes em relação a falsos alvos provocados por outros fenómenos. Os métodos semiautomáticos e automáticos apresentados são úteis e rápidos, mas a abordagem manual nunca deverá ser desvalorizada, em particular na validação dos resultados.

Nesta dissertação foram aplicadas quatro metodologias para identificar o derrame de óleo referente ao acidente ocorrido em julho de 2019 junto à costa do Nordeste brasileiro utilizando como base imagens VV Sentinel-1. Os métodos utilizados foram o *Change Detection*, o *Oil Spill Detection* (SNAP), a Análise de Textura e a Classificação Supervisada pela Máxima Verossimilhança. Foram usadas informações meteo-oceanográficas, como o vento, a presença de clorofila, a temperatura da superfície do mar e a altura significativa das ondas, obtidas através do CMEMS (2021) por forma a diferenciar as manchas de óleo dos falsos alvos.

O ruído *speckle*, presente em todas as imagens SAR, afeta a qualidade radiométrica da imagem, por isso foi necessário utilizar vários filtros para diminuir os ruídos de forma a tornar-se mais fácil e mais precisa a análise do objeto de estudo. Observou-se que em todos os filtros os ruídos da imagem original diminuíram. No entanto, a filtragem pelo

algoritmo *Lee Sigma* foi permitiu um melhor realce da mancha de óleo e foi a partir deste filtro que seguiu o restante processo de extração de manchas de óleo.

O método de detecção automática *Oil Spill Detection* do SNAP mostrou ser uma ferramenta eficaz para detecção de óleo, após o ajustamento do tamanho da janela de fundo de 100, da mudança de limiar 2,5 dB e do tamanho mínimo de cluster 0,1 km<sup>2</sup>.

A abordagem semiautomática através do *Change Detection* foi derivada a partir da diferença das imagens pré-evento, durante e a imagem pós-evento. Os resultados experimentais mostraram que este método apresentou um desempenho menos satisfatório em relação à abordagem mencionada acima.

A análise da Textura foi efetuada no *ImageJ*, com o *plugin Texture Analyzer GLCM*. A ferramenta mostrou ser capaz de identificar com sucesso a mancha de óleo ajustando os parâmetros de pesquisa que correspondeu a uma distância entre *pixéis* de 7 e a uma direção de 90° para mancha localizada a norte e 180° para a mancha que estava a sul. As medidas de textura que apresentaram melhores resultados foram a entropia, a correlação e a diferença inversa.

A classificação pela Máxima Verossimilhança identificou a mancha de óleo com sucesso, depois de o resultado ter sido cruzado com dados meteo-oceanográficas.

Dentre todas as técnicas estudadas neste trabalho, a metodologia que se mostrou mais eficiente, em termos de tempo de processamento e de acurácia foi a classificação, tendo esta identificado mais de 90% da mancha. O que é um resultado bastante satisfatório para o estudo em questão.

As abordagens testadas neste estudo tratam-se de metodologias eficientes em termos de custo e de tempo que podem ser usadas em decisões rápidas durante incidentes de derrames de óleo e, posteriormente, para mitigação de desastres.

No trabalho de investigação futura (doutoramento) para melhorar a qualidade dos resultados pretende-se testar outras técnicas como as Redes Neurais Artificiais de Lógica Difusa aplicadas a imagens obtidas com diferentes sensores. Pretende-se ainda mapear a propagação espacial da trajetória da mancha de óleo através de modelos de previsão baseados em dados meteorológicos com grande resolução.

## REFERÊNCIAS BIBLIOGRÁFICAS

- APRH – Associação Portuguesa dos Recursos Hídricos (2021).  
[https://www.aprh.pt/rgci/pdf/rgci-58\\_Pinheiro.pdf](https://www.aprh.pt/rgci/pdf/rgci-58_Pinheiro.pdf) - Acessado em 2021.
- Abbas, A. W., Minallh, N., Ahmad, N., Abid, S. A. R., & Khan, M. A. A. (2016). K-Means and ISODATA clustering algorithms for landcover classification using remote sensing. *Sindh University Research Journal-SURJ (Science Series)*, 48(2).
- Andrade, L. N. D., Vieira, T. G. C., Lacerda, W. S., Alves, H. M. R., Volpato, M. M. L., Braga, R. C. A., & Souza, V. C. O. D. (2009). Redes neurais artificiais na classificação de áreas cafeeiras da região de Guaxupé.
- Alawadi, F. A. (2011). Detection and classification of oil spills in MODIS satellite imagery (Doctoral dissertation, University of Southampton).
- BBC, (2010)  
[https://www.bbc.co.uk/blogs/portuguese/planeta\\_clima/2010/04/tecnologia\\_contra\\_a\\_mancha.shtml](https://www.bbc.co.uk/blogs/portuguese/planeta_clima/2010/04/tecnologia_contra_a_mancha.shtml) - Acessado em 2021.
- Brekke, C., & Solberg, A. H. (2005). Oil spill detection by satellite remote sensing. *Remote sensing of environment*, 95(1), 1-13.
- CMEMS (2021) - <https://marine.copernicus.eu/access-data/myocean-viewer>. Acessado em 2021.
- Espedal, H. A., Johannessen, O. M., Johannessen, J. A., Dano, E., Lyzenga, D. R., & Knulst, J. C. (1998). COASTWATCH'95: ERS 1/2 SAR detection of natural film on the ocean surface. *Journal of Geophysical Research: Oceans*, 103(C11), 24969-24982.
- ESA (2021). Obtido de Programa Copérnico:  
<https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- ESRI (2021)– [www.esri.com](http://www.esri.com). Acessado em 2021.
- Fingas, M., & Brown, C. E. (2017). A review of oil spill remote sensing. *sensors*, 18(1), 91.
- Frost, V. S., Stiles, J. A., Shanmugan, K. S., & Holtzman, J. C. (1982). A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE Transactions on pattern analysis and machine intelligence*, (2), 157-166.

- Genovez, P., Palmeira, F. L. B., & Bentz, C. M. (2009). Detecção e Monitoramento de Óleo através da Utilização Integrada de Imagens de Satélite, Verificações de Campo e Modelagem de Deriva de Óleo: Uma Abordagem Operacional.
- Genovez, P., Ebecken, N., Freitas, C., Bentz, C., & Freitas, R. (2017). Intelligent hybrid system for dark spot detection using SAR data. *Expert Systems with Applications*, 81, 384-397.
- Girard-Ardhuin, F., Mercier, G., & Garello, R. (2003). Oil slick detection by SAR imagery: potential and limitation. In *Oceans 2003. Celebrating the Past... Teaming Toward the Future (IEEE Cat. No. 03CH37492)* (Vol. 1, pp. 164-169). IEEE.
- Gonçalves, M. L., Andrade Netto, M. L., Zullo Jr, J., & Costa, J. A. F. (2008). Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. *Revista Brasileira de Cartografia*, 60(1), 17-29.
- IBAMA (2021) - <http://www.ibama.gov.br/>. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais. Acessado em 2021.
- IPIECA (2019) - <https://www.ipieca.org/news/sustainability-reporting-2019/>. International Petroleum Industry Environmental Conservation Association. Acessado em 2019.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.
- IBGE –Instituto Brasileiro de Geografia e Estatística (2010). <https://www.ibge.gov.br/>. Acessado em 2021.
- INPE - Instituto Nacional de Pesquisas Espaciais (2021). <https://www.gov.br/inpe/pt-br>. Acessado em 2021.
- Jomi, F. H., (2006). Redes Neurais. Departamento de Sistemas e Computação- Universidade Regional de Blumenau. Brasil.
- Kayano, M. T., & Andreoli, R. V. (2004). Decadal variability of northern northeast Brazil rainfall and its relation to tropical sea surface temperature and global sea level pressure anomalies. *Journal of Geophysical Research: Oceans*, 109(C11).

- Klogo, G. S., Gasonoo, A., & Ampomah, I. K. (2013). On the Performance of Filters for Reduction of Speckle Noise in SAR Images off the Coast of the Gulf of Guinea. arXiv preprint arXiv:1312.2383.
- Koppe, W.; Gnyp, M. L. C.; Hütt, Y.; Miao, Y.; Chen, X. e Bareth, G. (2013). Rice monitoring with multi-temporal and dual-polarimetric TerraSAR-X data. *International Journal of Applied Earth Observation and Geoinformation*, Vol. 21, pp. 568-576.
- Kuplich, T. M., Curran, P. J., & Atkinson, P. M. (2005). Relating SAR image texture to the biomass of regenerating tropical forests. *International Journal of Remote Sensing*, 26(21), 4829-4854.
- LAPIS - Laboratório de Análise e Processamento de Imagens de Satélites (2021). Acessado em 2021.
- Lee, J. S. (1983). Digital image enhancement and noise filtering by use of local statistics. *IEEE transactions on pattern analysis and machine intelligence*, (2), 165-168.
- Lichtenegger, J. (1994). Using ERS-1 SAR images for oil spill surveillance. *Earth Obs. Q.*, (44), 7-10.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- Lopes, A., Nezry, E., Touzi, R., & Laur, H. (1990). Maximum a posteriori speckle filtering and first order texture models in SAR images. In *10th annual international symposium on geoscience and remote sensing* (pp. 2409-2412). Ieee.
- Maithree, H., Dinushka, D., & Wijayasiri, A. (2020). Change Detection Using Synthetic Aperture Radar Videos. *arXiv preprint arXiv:2007.14001*.
- Matsukuma, C. K. (2002). Análise comparativa de algoritmos de classificação digital não-supervisionada, no mapeamento do uso e cobertura do solo (Doctoral dissertation, Universidade de São Paulo).
- Meneses, P. R., & Sano, E. E. (2012). Sensor radar de abertura sintética. *Introdução ao processamento de imagens de sensoriamento remoto. Brasília: Unb*, 57-76.

- Mera, D., Bolon-Canedo, V., Cotos, J. M., & Alonso-Betanzos, A. (2012). On the use of feature selection to improve the detection of sea oil spills in SAR images. *Computers & Geosciences*, 100, 166-178.
- Miranda, F.P., Marmol, A. M. Q., Pedroso, E. C., Beisl, C. H., Welgan, P., & Morales, L. M. (2004). Analysis of RADARSAT-1 data for offshore monitoring activities in the Cantarell Complex, Gulf of Mexico, using the unsupervised semivariogram textural classifier (USTC). *Canadian Journal of Remote Sensing*, 30(3), 424-436.
- Misra, A., & Balaji, R. (2017). Simple approaches to oil spill detection using sentinel application platform (SNAP)-ocean application tools and texture analysis: a comparative study. *Journal of the Indian Society of Remote Sensing*, 45(6), 1065-1075.
- Moreira, A., Prats-Iraola, P., Younis, M., Krieger, G., Hajnsek, I., & Papathanassiou, K. P. (2013). A tutorial on synthetic aperture radar. *IEEE Geoscience and remote sensing magazine*, 1(1), 6-43.
- Natural Resources Canada. (2019). Obtido de Remote Sensing Tutorials: <https://www.nrcan.gc.ca/nrcan/about-us/10838>
- Nimer, E. (1989). Climatologia do Brasil, IBGE. *Rio de Janeiro*.
- Papila, İ., Sertel, E., Kaya, Ş., & Gazioğlu, C. (2018). Oil spill detection using remote sensing technologies-synthetic aperture radar (SAR). *Oil Spill along the Turkish Straits*, 140.
- Richards, J. A. (1993). Remote sensing digital image analysis. An introduction.
- Richards, J. A., & Jia, X. (2006). Remote Sensing Digital Image Analysis. *Remote Sensing Digital Image Analysis*, 197.
- Roriz, C. E. D. (2006). *Detecção de exsudações de óleo utilizando imagens do satélite RADARSAT-1 na porção offshore do delta do Niger* (Doctoral dissertation, COPPE, Universidade Federal do Rio de Janeiro (UFRJ)).
- Saldanha, M. F. S. & Freitas, C. C., (2009). *Segmentação de imagens digitais: uma revisão*. São José dos Campos, 2009.
- Sathya, P., & Malathi, L. (2011). Classification and segmentation in satellite imagery using back propagation algorithm of ann and k-means algorithm. *International Journal of Machine Learning and Computing*, 1(4), 422.

- Silva, J.; Mano, M. F.; Hargreaves, F. M.; Cabral, A. P.; Miranda, F. P.; Pedroso, E. C.; Beisl, C. H. (2003). Utilização de dados orbitais multisensores na caracterização de exsudações naturais de óleo no Golfo do México. XIV Brazilian Remote Sensing Symposium (SBSR), p. 929- 936, INPE.
- Singha, S., Bellerby, T. J., & Trieschmann, O. (2013). Satellite oil spill detection using artificial neural networks. *IEEE Journal of selected topics in applied earth observations and remote sensing*, 6(6), 2355-2363.
- Shu, Y., Li, J., Yousif, H., & Gomes, G. (2010). Dark-spot detection from SAR intensity imagery with spatial density thresholding for oil-spill monitoring. *Remote Sensing of Environment*, 114(9), 2026-2035.
- Solberg, A. H. S. (2012). Remote sensing of ocean oil-spill pollution. *Proceedings of the IEEE*, 100(10), 2931-2945.
- Solberg, A. H., Brekke, C., & Husoy, P. O. (2007). Oil spill detection in Radarsat and Envisat SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 45(3), 746-755.
- Topouzelis, K., Karathanassi, V., Pavlakis, P., & Rokos, D. (2003). Oil spill detection: SAR multiscale segmentation and object features evaluation. In *Remote Sensing of the Ocean and Sea Ice 2002* (Vol. 4880, pp. 77-87). International Society for Optics and Photonics.
- Topouzelis, K., Karathanassi, V., Pavlakis, P., & Rokos, D. (2007). Detection and discrimination between oil spills and look-alike phenomena through neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62(4), 264-270.
- Vaiyammal, K., & Raja, R. A. (2017) Change Detection on SAR Images. *International journal of engineering research & technology*, 5(17).
- Vespe, M., del, G., Posada, M., Greidanus, H., & Perkovic, M. (2011). Oil spill detection using COSMO-SkyMed over the Adriatic Sea: The operational potential. In *2011 IEEE International Geoscience and Remote Sensing Symposium* (pp. 4403-4406). IEEE.
- Vespe, M., & Greidanus, H. (2012). SAR image quality assessment and indicators for vessel and oil spill detection. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11), 4726-4734.

Wang, X., Thomas, J. B., Hardeberg, J. Y., & Gouton, P. (2013, February). Median filtering in multispectral filter array demosaicking. In *Digital Photography IX* (Vol. 8660, p. 86600E). International Society for Optics and Photonics.

Zhang, F., Shao, Y., Tian, W., & Wang, S. (2008). Oil spill identification based on textural information of SAR image. In *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 4, pp. IV-1308). IEEE.