



Deteção de *dark vessels* através de Deteção Remota

Uma abordagem através de sensores óticos e sensores SAR

Yury Vladislavovich Orzhekhovskiy

Dissertação

apresentada como requisito parcial para obtenção do grau de Mestre em Ciência e Sistemas de Informação Geográfica

NOVA Information Management School
Instituto Superior de Estatística e Gestão de Informação

Universidade Nova de Lisboa

NOVA Information Management School
Instituto Superior de Estatística e Gestão de Informação
Universidade Nova de Lisboa

Deteção de *dark vessels* através de Deteção Remota

Uma abordagem através de sensores óticos e sensores SAR

por

Yury Vladislavovich Orzhekhovskiy

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Ciência e Sistemas de Informação Geográfica

Orientada por:

Joel Dinis Baptista Ferreira da Silva, PhD, NOVA Information Management School

Junho, 2025

DECLARAÇÃO DE INTEGRIDADE

Declaro que o trabalho contido neste documento é da minha autoria e não de outra pessoa. Toda a assistência recebida de outras pessoas está devidamente identificadas e é efetuada referência a todas as fontes utilizadas (publicadas ou não).

O trabalho não foi anteriormente submetido ou avaliado na NOVA Information Management School ou em qualquer outra instituição. Declaro ainda que tenho conhecimento das Regras de Conduta e do Código de Honra da NOVA Information Management School.

Assinado por: **Yury Vladislavovich Orzhekhovskiy**
Num. de Identificação: 30635397
Data: 2025.06.16 11:08:54+01'00'



UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA

Tarefas	NÃO	SIM	Ferramentas de Inteligência Artificial Generativa
Compreender melhor as questões relacionadas com a investigação	X		
Resumir texto de bibliografia / recursos	X		
Resumo do(s) método(s) utilizado(s)	X		
Tradução de texto		X	ChatGPT
Verificação gramatical	X		
Parafrasear ou reescrever texto de outras pessoas/recursos	X		
Codificação em R, Python, etc.	X		
Obter ajuda sobre um software		X	ChatGPT
Criação e edição de imagens, mapas, vídeos, etc.	X		
Análise de dados	X		
Especificar abaixo outras tarefas não mencionadas acima:			

DEDICATÓRIA

À “sementinha”.

AGRADECIMENTOS

Começo por agradecer ao meu orientador, Sr. Prof. Joel Silva, por todo o apoio ao longo deste trabalho.

Ao Comandante Gonçalves de Deus, o meu sincero agradecimento pela enorme disponibilidade e prontidão, cujo contributo foi fundamental para a realização do trabalho e para reforçar a minha convicção quanto à pertinência e importância deste projeto.

À minha família, que mais uma vez, agora neste segundo mestrado, esteve sempre presente e foram um pilar essencial na minha educação e no meu percurso académico e pessoal.

Por fim, um especial agradecimento à Sofia, que me acompanhou ao longo de todo o percurso deste mestrado. Foi verdadeiramente um porto de abrigo, sempre presente nos momentos de cansaço, incerteza e desmotivação. O seu carinho, compreensão e incentivo foram fundamentais para recarregar baterias e concluir esta etapa.

Um enorme obrigado!

DETEÇÃO DE *DARK VESSELS* ATRAVÉS DE DETEÇÃO REMOTA

Uma abordagem através de sensores óticos e sensores SAR

RESUMO

Os *dark vessels* são navios que navegam propositadamente sem transmitir a sua posição, estando frequentemente envolvidos em atividades ilegais. A deteção desta prática criminosa por técnicas convencionais constitui um desafio para a vigilância marítima, sendo, no entanto, essencial para a segurança e fiscalização do mar. Este trabalho inicia-se com uma análise bibliométrica que revela a pertinência e emergência deste tema e explora o potencial da deteção remota na deteção de *dark vessels*, utilizando dados de sensores óticos e radar de abertura sintética (SAR). Foram analisadas imagens de Sentinel-1 (SAR) e Sentinel-2 (ótico), com o objetivo de desenvolver um processo de deteção de navios, que é depois sobreposto com uma base de dados AIS, permitindo detetar embarcações que não estejam a transmitir a posição AIS. A metodologia utilizada baseia-se numa abordagem por *threshold*, com recurso à banda artificial NDWI para a deteção de navios com sensores óticos e em CFAR para a deteção de navios por sensores SAR. Os resultados obtidos indicam que a abordagem SAR apresenta resultados superiores à abordagem por sensores óticos, não sendo afetada por condições meteorológicas. Este trabalho contribui para a análise das vantagens e desvantagens de cada abordagem, propondo uma solução simples e eficaz para a deteção de *dark vessels* através de imagens de satélite.

PALAVRAS-CHAVE

Dark vessel; Deteção Remota; Radar de Abertura Sintética (SAR); Satélites óticos; Deteção navios

Objetivos do Desenvolvimento Sustentável (ODS):



DARK VESSEL DETECTION USING REMOTE SENSING

An approach through optical and SAR sensors

ABSTRACT

Dark vessels are ships that purposely sail without broadcasting their position and are often involved in illegal activities. Detecting this criminal practice using conventional techniques is a challenge for maritime surveillance, but it is essential for the safety and surveillance of the sea. This work begins with a bibliometric analysis that reveals the relevance and emergence of this topic and explores the potential of remote sensing in detecting dark vessels, using data from optical sensors and synthetic aperture radar (SAR). Sentinel-1 (SAR) and Sentinel-2 (optical) images were analyzed with the aim of developing a ship detection process, which is then overlaid with an AIS database, making it possible to detect vessels without AIS. The methodology used is based on a threshold approach, using the NDWI artificial band for detecting ships with optical sensors and CFAR for detecting ships with SAR sensors. The results obtained indicate that the SAR approach provides better results than the optical sensor approach as it is not affected by meteorological conditions. This work contributes to analyzing the advantages and disadvantages of each approach and proposes a simple yet effective solution for detecting dark vessels using satellite images.

KEYWORDS

Dark vessel; Remote Sensing; Synthetic Aperture Radar; Optical satellite; Ship detection

Sustainable Development Goals (SGD):



ÍNDICE

1. Introdução	12
1.1. Enquadramento teórico	15
1.2. Objetivos.....	17
1.3. Estrutura	17
2. Revisão da Literatura	19
2.1. Análise bibliométrica	19
2.1.1. Performance analysis.....	20
2.1.2. Science mapping	21
2.1.3. Análise bibliométrica – <i>dark vessels</i>	27
2.2. Estado da arte.....	29
2.2.1. Dados utilizados em outros trabalhos	29
2.2.2. Metodologias utilizadas em trabalhos congéneres.....	31
3. Metodologia	33
3.1. Área de Estudo	34
3.2. Dados	36
3.3. Seleção do satélite e sensor e aquisição dados	37
3.3.1. Sensores óticos	37
3.3.2. Sensores SAR.....	38
3.4. Pre-processamento	38
3.4.1. Sensores óticos	38
3.4.2. Sensores SAR.....	38
3.5. Análise exploratória dos dados	38
3.5.1. Sensores óticos	38
3.5.2. Sensores SAR.....	39
3.6. Detecção navios	39
3.6.1. Sensores óticos	39
3.6.2. Sensores SAR.....	40
3.7. Detecção <i>dark vessels</i>	41
3.8 Cálculo precisão.....	42
4. Estudo Empírico.....	44
4.1 Prova de conceito - ótico.....	44
4.2. Prova de conceito - SAR.....	53
5. Resultados e Discussão.....	57

5.1. Resultados	57
5.2. Discussão	60
6. Conclusões e Investigação Futura	63
Referências Bibliográficas	65
Apêndice A	69

ÍNDICE DE TABELAS

Tabela 3.1. Disponibilidade de dados óticos e SAR. Fonte: Autor.	37
Tabela 5.1. Resultados obtidos.....	60

ÍNDICE DE FIGURAS

Figura 1.1. Exemplo de spoofing. Retirado de (Gabler & Koch, 2012)	14
Figura 2.1. Estatísticas iniciais dos documentos. Fonte: Adaptado de Bibliometrix	20
Figura 2.2. Tipos de documentos. Fonte: Adaptado de Bibliometrix	20
Figura 2.3. Produção científica anual. Fonte: Bibliometrix	21
Figura 2.4. Número de documentos por autor. Fonte: Bibliometrix	22
Figura 2.5. Produção dos autores ao longo do tempo. Fonte: Bibliometrix	22
Figura 2.6. Instituições mais relevantes. Fonte: Bibliometrix	23
Figura 2.7. Nacionalidade dos autores. Fonte: Bibliometrix	24
Figura 2.8. Produção científica por país, ao longo do tempo. Fonte: Bibliometrix	24
Figura 2.9. Mapa de colaboração entre países	25
Figura 2.10. Principais keywords. Fonte: VOSviewer	26
Figura 2.11. Principais keywords em formato WordCloud. Fonte: Bibliometrix	26
Figura 2.12. Estatísticas iniciais dos documentos sobre dark vessels. Fonte: Adaptado de Bibliometrix	27
Figura 2.13. Análise resultados dark vessels. (a) Produção científica anual. (b) Produção dos autores ao longo do tempo. (c) Principais instituições. (d) Nacionalidade dos autores	28
Figura 2.14. Principais keywords em dark vessels. Fonte: VOSviewer	29
Figura 3.1. Área de estudo. Fonte: Autor	35
Figura 4.1. Composição colorida RGB 432	46
Figura 4.2. Composição colorida RGB 843	48
Figura 4.3. Banda artificial NDWI	49
Figura 4.4. Navios detetados satélite ótico	50
Figura 4.5. Erros da detecção de navios, satélite ótico	51
Figura 4.6. Classificação de navios, satélite ótico	52
Figura 4.7. Análise exploratória SAR, compósito RGB (VV, VH, VH)	54
Figura 4.8. Análise exploratória SAR, colorida RGB (VV, (VV-VH), VH)	55
Figura 4.9. Navios detetados, SAR	56
Figura 5.1. Compilação da classificação de navios, sensor ótico	58
Figura 5.2. Compilação da classificação de navios, sensor SAR	59

ACRÓNIMOS

AIS - *Automatic Identification System*

ASF - *Alaska Satellite Facility*

CFAR - *Constant False Alarm Rate*

DAGI - *Direção de Análise e Gestão da Informação*

DL – *Decreto-Lei*

ESA - *European Space Agency*

EST - *Esquema de Separação de Tráfego*

EUA - *Estados Unidos da América*

FD - *Falsa-Deteção*

FN - *Falso-Negativo*

FP - *Falso-Positivo*

GRD - *Ground Range Detected*

GT - *Gross tonnage*

HR - *High Resolution*

IMO - *International Maritime Organization*

LIDAR - *Light Detection and Ranging*

MCP - *Multiple Country Publications*

MMSI - *Maritime Mobile Service Identity*

MMSSIS AIS - *Multinational Maritime Safety and Security Information System AIS*

MSI - *Multispectral Instrument*

MTP - *Mar Territorial Português*

NASA - *North Aeronautics and Space Administration*

NDWI - *Normalized Difference Water Index*

NE - *Nordeste*

NM - *Nautical Mile*

NOVA IMS – *Nova Information Management School*

NUDF - *National University of Defense Technology*

OI - Objetivo de investigação

PCA - *Principal Component Analysis*

RADAR - *Radio Detection and Ranging*

RGB - *Red, Green, Blue*

SAR - *Search and Rescue*

SAR - *Synthetic Aperture RADAR*

SAT-AIS - *Satellite AIS*

SCP - *Single Country Publications*

SIG – *Sistemas de Informação Geográfica*

SLC - *Single Look Complex*

SNAP - *Sentinel Application Platform*

T-AIS - *Terrestrial AIS*

VH - *Vertical-Horizontal*

VHF - *Very High Frequency*

VHR - *Very High Resolution*

VP - *Verdadeiro-Positivo*

VV - *Vertical-Vertical*

ZC - *Zona Contígua*

ZEE - *Zona Económica Exclusiva*

ZMPS - *Zona Marítima Particularmente Sensível*

1. INTRODUÇÃO

É inegável a importância que o mar tem, quer de um ponto de vista da economia, em que 90% do comércio é feito pela via marítima e constitui fonte de trabalho para milhões de pessoas (OECD, 2020), quer de um ponto de vista estratégico e militar, em que o mar é a chave para a paz e para a prosperidade (NATO, 2022). O mar tem um valor incalculável, sendo uma via para transporte de material e alimentação, é a principal via para passagem de cabos de comunicações e tem potencial para produção de energia. Para além destas, os navios têm um papel importante em outras áreas como na oceanografia (National Oceanography Centre, 2025) e pesquisa científica (Thana, 2013).

Os motivos acima elencados fazem com que o mar seja altamente atrativo para a atividade criminosa (Bellamy, 2020).

De acordo com as Nações Unidas (2019), estão identificados, entre outros, os seguintes crimes no espaço marítimo: Tráfico de seres humanos, tráfico de estupefacientes e pirataria. Por trás da deplorável natureza do tráfico de seres humanos, está uma fonte lucrativa para os criminosos, que se estima ter um lucro anual de 36 mil milhões de dólares (Ashe, 2014). Cerca de 70% do tráfico de estupefacientes é confiscado por via marítima ou após ter sido transportado por esta via (Aune, 1990). A pirataria, para além de afetar as vias marítimas e pôr em risco a vida dos tripulantes, causa a perda de milhões de dólares através de roubos e sequestros (INTERPOL, n.d.).

Existem várias formas para fazer o combate aos crimes em espaço marítimo. Entre elas, os Sistemas de Informação Geográfica (SIG), que são utilizados em vários trabalhos (Gupta et al., 2012; Bala et al., 2015) e tornaram-se fundamentais para compreender os padrões de crime, analisar os atos criminosos e para desenvolver formas de enfrentar a criminalidade. Muitas das ferramentas baseadas em SIG consistem em fazer o *tracking* a embarcações e em análise de dados geoespaciais, como é o caso das Nações Unidas (n.d.) que através da *United Nations Office on Drugs and Crime* criou um sistema (*Drugs Monitoring Platform*), plataforma de monitorização de droga, para recolha, visualização e partilha de dados sobre narcotráfico. Este sistema tem como objetivo o acesso a informação em tempo real sobre o tráfico de droga, disponibilizando informação interativa e diversas formas de visualização de forma a apoiar as entidades legais e analistas. Desta forma, o sistema disponibiliza informação geográfica com mais de 586 mil dados de apreensão de droga de vários países do mundo. São vários os

trabalhos com bases de dados que contêm informação a cerca de ataques de pirataria. Estas bases de dados referem importante informação como a localização, data e hora dos ataques e estado do navio atacado. possível o estudo da pirataria através de sistemas de informação geográficos. Num artigo publicado no *Journal of Research in Crime and Delinquency* (Marchione & Johnson, 2013), estudou-se a localização e o *timing* de ataques de pirataria para verificar se, à semelhança de outros crimes, os ataques são agrupados no espaço e no tempo. Com a elaboração de mapas de densidade de *Kernel*, estatísticas de *Moran's* e simulações de *Monte Carlo* concluiu-se que a atividade de pirataria está agrupada no espaço, em cinco sub-regiões do planeta. É possível verificar que muitos trabalhos e muitas técnicas desenvolvidas baseiam-se no conhecimento do posicionamento dos navios, que nem sempre é possível de obter.

Os navios, dependendo das suas características e das leis em vigor, devem ter um sistema que permita conhecer a sua posição. Existem vários motivos pelo qual é importante conhecer a posição de um navio. De um ponto de vista da segurança da navegação, permite a identificação de navios, uma vez que partilha informação em tempo real e facilita assim a comunicação entre os mesmos (IMO, 2015). Em cenários de emergência, como é no caso naufrágios, facilita as operações de *Search and Rescue* (SAR), uma vez que permite saber a última posição conhecida. Também no combate aos crimes em espaço marítimo, permite detetar atividade e comportamentos suspeitos, numa tentativa de prevenir e detetar atividades ilegais. Neste âmbito, através de ferramentas em ambiente SIG, e conhecendo as posições dos navios, é possível medir a densidade de tráfico marítimo, medir alterações sazonais de tráfico e podem ser utilizadas ferramentas para a deteção de comportamentos possivelmente ilícitos (Nunes, 2022). Este tipo de ferramentas, como o caso da caracterização do tráfico marítimo para prever o encontro de navios (Nunes, 2022), depende do *Automatic Identification System* (AIS) para a obtenção das posições dos navios, e está sujeita a que os possíveis criminosos desliguem o AIS ou que enviem informação incorreta através do mesmo, tornando assim a sua deteção muito difícil. Verifica-se então que as embarcações envolvidas em atividade criminosa desligam o seu sistema de transmissão de posicionamento, para que não sejam tão facilmente detetadas.

Estudo recentes estimam que entre 72 e 76% dos navios de pesca não transmitem a sua posição, bem como entre 21 e 30% dos navios da indústria de transporte e energia (Paolo et al., 2024). Para além destes, estima-se que até 50% das mensagens AIS contêm erros (Gabler

& Koch, 2012) tanto de introdução de dados (e. g. porto de destino), na configuração, manutenção e uso do AIS (Calder & Schwehr, 2009), tanto quanto na própria transmissão das posições. A figura abaixo representa este último caso, em que podemos verificar navios cuja posição está em terra. A estes casos, são normalmente designados por *spoofing*.



Figura 1.1. Exemplo de spoofing. Retirado de (Gabler & Koch, 2012)

O *spoofing*, segundo Androjna et al. (2021), é a manipulação intencional e deliberada dos dados AIS por forma a transmitir informação falsa sobre a posição e identificação do navio, velocidade.

Os navios que propositalmente deixam de transmitir a sua posição são comumente designados por *dark vessels*. Apesar de não ser correto assumir que todos os navios que desliguem o AIS estão envolvidos em práticas criminosas, o simples facto de estar desligado levanta fortes suspeitas sobre estes navios (Bunwaree, 2023, p. 182).

Os *dark vessels* são também denominados como *non-broadcasting vessels* ou navios que não transmitem a sua posição, *dark ships*, *ghost ships* ou *phantom fleet*, de forma a intitular ou referir os navios que escondem a sua posição, estando envolvidos em atividades ilegais como contrabando de mercadoria (Nguyen, 2023).

Assim, levanta-se a questão de “como é que é feita a deteção de navios com AIS desligado?” Segundo Gabler & Koch (2012) as técnicas utilizadas são: sistemas RADAR, deteção eletromagnética e acústica. Os sistemas RADAR, que podem ser ativos ou passivos, tem como grande vantagem o facto de que funcionam em várias condições meteorológicas, e são particularmente úteis para vigilância costeira (Gabler & Koch, 2012). A deteção eletromagnética aproveita-se das transmissões de sensores como comunicações, *Radio Detection and Ranging* (RADAR), sinais AIS, por forma a captar estas frequências e detetar a posição de navios (Gabler & Koch, 2012). A deteção acústica, baseia-se na deteção onde ondas acústicas, para a deteção e identificação de, por exemplo, navios, considerando que cada navio

tem uma assinatura acústica única. Ainda, apesar de menos habitual, a deteção de navios também pode ser feita por técnicas de radiofrequência, através de equipamentos que detetam emissões rádio (Chaltiel, 2021), como por exemplo através de um radiogoniómetro. Na Marinha Portuguesa, uma das formas de deteção de possível atividade criminosa, concretamente a deteção de navios com AIS desligado, é feita com recurso a uma aplicação desenvolvida para o efeito. Esta aplicação, de forma geral, analisa todos os sinais AIS de uma base de dados e, dependendo dos atributos definidos, identifica os navios que desligaram o AIS ou cujo sinal AIS tenha ficado interrompido por um tempo. Esta abordagem tem, no entanto, várias limitações como: está dependente dos navios transmitirem a sua posição, pelo que se um infrator nunca ligar o AIS, não seria detetado, está sujeita a muitos erros (zonas de sombra, erros humanos) e não é verificada por uma segunda fonte de dados independente. Importa que a deteção seja feita o mais cedo possível, uma vez que a deteção de atividade ilegal quando um navio atinge águas costeiras torna-se ainda mais complicada (Bunwaree, 2023, p. 184).

1.1. ENQUADRAMENTO TEÓRICO

O AIS é um sistema de comunicação marítimo destinado à segurança da navegação e ao rastreio de navios (Oumimoun et al., 2022). O AIS permite a troca de informação entre navios e com estações em terra, por forma a localizar, identificar e acompanhar os navios que tenham este equipamento (Oumimoun et al., 2022). É possível a troca de informação estática, como por exemplo a identificação do navio, mas também de informação dinâmica, como a posição, velocidade e rumo. Ainda, é possível acrescentar informação sobre a viagem, informação inserida à saída dos portos, que indica o porto de destino e tipo de carga a transportar (Tele et al., 2006, p. 1).

A *International Maritime Organization* (IMO) foi a organização que definiu e regulou o uso do AIS, implementando regras à sua utilização. Segundo a IMO (2015), o AIS foi desenvolvido com o objetivo de incrementar a salvaguarda de vidas no mar, de aumentar a segurança e eficiência da navegação e de proteger o meio marinho. Desde 31 de dezembro de 2004, os navios superiores a 300 *Gross Tonnage* (GT) em tráfego internacional, os navios de carga superiores a 500GT e todos os navios de transporte de passageiros, são obrigados a utilizar um sistema AIS (Silveira et al., 2013 citado em Nunes, 2022).

A União Europeia (2011), através Parlamento Europeu, estabeleceu que os navios de pesca com mais de 15 metros devem ter um sistema AIS.

Em Portugal, qualquer embarcação de pesca com um comprimento fora-a-fora superior a 15 metros, deverá estar equipada com um AIS, devendo manter esse sistema permanentemente operacional e ligado, exceto em circunstâncias muito específicas em que coloque em causa a segurança do navio.

De forma resumida, o AIS funciona através de ondas rádio, operando na gama *de Very High Frequency* (VHF) e, por conseguinte, o seu alcance depende das condições de propagação, do estado do mar e a altura da antena transmissora (NATO, 2021).

O sistema junta a informação da posição de um navio, bem como outra informação (*Maritime Mobile Service Identity* [MMSI], nome, destino e tipo de carga), e transmite esta informação com intervalos regulares. A informação é transmitida para outros navios, antenas em terra e satélites que depois retransmitem a informação para aumentar o seu alcance.

Existem diversas fontes de dados AIS, das quais se destacam o *Terrestrial AIS* (T-AIS), *Satellite AIS* (SAT-AIS) (SPIRE, n.d.) e o *Multinational Maritime Safety and Security Information System* (MSSIS-AIS) (Volpe National Transportation Systems Center, 2008). O T-AIS corresponde a uma fonte de dados de rede de antenas costeiras e tem um alcance aproximado de 40nm. A sua principal vantagem é ter uma latência extremamente baixa (SPIRE, n.d.). O SAT-AIS apoia-se numa rede de satélites, o que permite uma cobertura em alto mar, sendo esta cobertura global a sua grande vantagem. O MSSIS-AIS é uma base de dados, que combina várias fontes de dados de diversos países, com o objetivo de contribuir para a segurança e para a partilha de dados.

A deteção de um objeto consiste em reconhecer a presença desse determinado objeto, enquanto a classificação ou identificação envolve reconhecer o objeto, atribuindo-lhe uma categoria à qual pertence. Um exemplo de deteção consiste validar a presença de um navio no mar, enquanto a classificação identifica qual é tipo de navio. Em várias metodologias, a fase de deteção é um primeiro passo antes de se proceder à classificação (Kanjir et al., 2018).

Por sua vez, o processo de classificação é uma tarefa maior complexidade, não sendo uma tarefa tão fácil rápida de realizar (Mountrakis et al., 2011). De acordo com Mountrakis et al. (2011), a classificação com dados de deteção remota é complexa pois requer grandes quantidades de amostras de treino, algo que nem sempre se verifica possível.

1.2. OBJETIVOS

A Detecção Remota, quer através de sensores óticos ou por *Synthetic Aperture Radar* (SAR), permite a deteção de *dark vessels*, o que contribui para um incremento de segurança marítima e para a deteção de atividade ilícita (Pelich et al., 2019; Kanjir et al., 2018). O desenvolvimento de um processo, através de técnicas em SIG, permite, de uma forma simples e independente, detetar *dark vessels*, uma vez que não é dependente de sistemas de transmissão do navio.

A questão central é: “Será um modelo baseado em deteção remota eficaz na deteção de *dark vessels*?”.

Como objetivos de investigação (OI), definiram-se os seguintes:

- OI1 – Desenvolver um processo que utiliza imagens de satélite (ótico), para identificar navios no mar;
- OI2 – Desenvolver um processo que utiliza imagens de satélite (SAR), para identificar navios no mar;
- OI3 – Avaliar a precisão dos processos em detetar navios;
- OI4 – Desenvolver um processo que consiga comprar posições AIS com posições dos navios;
- OI5 – Desenvolver um processo que permita detetar *dark vessels* numa dada área de estudo e período temporal.

1.3. ESTRUTURA

Este trabalho encontra-se dividido em seis capítulos, sendo eles a Introdução, Revisão da Literatura, Metodologia, Estudo Empírico, Resultados e Discussão e por fim, Conclusão.

No primeiro capítulo, é feita uma abordagem ao tema, referindo a sua pertinência, um enquadramento teórico com conceitos importantes para acompanhar o trabalho, como o que é e como funciona o AIS e, no final, são referidos os objetivos do trabalho,

No segundo capítulo, é realizada a revisão da literatura através de uma análise bibliométrica, em que se pretende analisar os trabalhos realizados na área da deteção de navios através de deteção remota, quer por sensores óticos, quer por sensores SAR. No final do capítulo, é feita uma análise ao subtema de deteção de *dark vessels* por forma a identificar um research gap.

No terceiro capítulo, é definida a área de estudo, identificados os dados utilizados e explicada a metodologia que foi seguida.

No quarto capítulo, são feitos dois casos de estudo, um para sensores óticos e outro para sensores SAR, para testar o modelo que foi construído.

No quinto capítulo, o modelo é testado por um maior período e é feita a análise dos resultados obtidos.

No sexto e último capítulo, é feito um sumário do trabalho realizado em que são referidas algumas dificuldades na elaboração do trabalho, bem como sugestões para trabalhos futuros.

2. REVISÃO DA LITERATURA

2.1. ANÁLISE BIBLIOMÉTRICA

A metodologia utilizada para a revisão da literatura foi a análise bibliométrica, que permite analisar uma grande quantidade de referências, de modo a apresentar o estado e a estrutura de um tema a fim de identificar padrões e tendências e contribuir para a construção de um *research gap* (Donthu et al., 2021). Segundo Donthu et al. (2021), uma análise bibliométrica divide-se em duas etapas, *performance analysis* e *science mapping*. De uma forma geral, a *performance analysis* verifica os contributos das investigações, enquanto o *science mapping* se centra nas relações. Concretamente, para a *performance analysis* procuramos contabilizar métricas como o número de publicações sobre o nosso tema, o número de autores que contribuem para o tema, número de publicações por ano, total de citações e métricas de citação e publicação como o índice de colaboração e o *h-index* (Donthu et al., 2021, p. 4). Em *science mapping* o foco são as relações e baseia-se em métricas de co-citação, co-autoria e evolução temporal de tópicos.

Para a condução da análise bibliométrica foi utilizado o *software* VOSviewer a partir de referências do *Scopus*.

De acordo com as etapas propostas por Donthu et al. (2021), começa-se por definir o objetivo e o foco da análise, que deverá ser abrangente o suficiente para se utilizar uma análise bibliométrica. Neste sentido, o objetivo é: analisar os trabalhos realizados sobre deteção de navios ou embarcações, utilizando técnicas de deteção remota, nomeadamente SAR ou através de sensores óticos. Em seguida, faz-se uma análise mais superficial a documentos exclusivamente sobre deteção de *dark vessels* através de deteção remota, de modo a compreender os trabalhos que existem neste subtema, a fim de encontrar um *research gap*. Assim, procedeu-se à pesquisa de referências no *Scopus* através da seguinte *query*:

```
( TITLE-ABS-KEY ( "ship detection" OR "vessel detection" ) AND TITLE-ABS-KEY ( "remote sensing" OR "satellite imagery" OR "SAR" OR "optical imagery" ) ) AND ( LIMIT-TO ( LANGUAGE , "English" ) )
```

Para esta análise foram apenas tidos em conta os trabalhos escritos em língua inglesa, e que façam referência aos termos "deteção de navios", "deteção de embarcações" e "deteção remota" ou "imagens satélite" ou "imagens óticas". Desta pesquisa surgem então 2469

resultados. A esta base de dados inicial, foram ainda acrescentadas 65 referências relativas a "dark vessels" e demais termos semelhantes, totalizando assim um conjunto de 2592 documentos. Em seguida, estes documentos foram então reduzidos para 2495, após uma análise mais cuidada, embora superficial, face ao elevado número de documentos, que não permite uma leitura na íntegra. Foram retirados documentos duplicados ou fora do contexto, tendo-se analisado as *keywords* e os *abstract*.

2.1.1. PERFORMANCE ANALYSIS

Tal como referido anteriormente, foram analisados 2495 documentos, em que o documento mais antigo é referente a 1978 e os documentos mais recentes são de 2024. Verifica-se um valor de média de citações por documento de 17.12, contabilizam-se 5951 autores que contribuem para este tema, verificando que apenas existem 129 documentos com um só autor. Relativamente ao tipo de documentos, são maioritariamente artigos (49.66%) e artigos de conferência (46.57%).

As figuras abaixo representam algumas das estatísticas iniciais, bem como o tipo de documentos que constituem esta análise.

	Description	Descrição	Resultados/Results
Informação principal/Main information about data	Timespan	Período temporal	1978:2024
	Sources (Journals, Books, etc)	Fontes (jornais, livros, etc)	594
	Documents	Documentos	2495
	Annual Growth Rate %	Taxa de Crescimento Anual/Annual Growth Rate %	13.68
	Document Average Age	Idade média do documento	5.35
	Average citations per doc	Média de citações por documento	17.12
Conteúdo dos documentos/ Document contents	Keywords Plus (ID)	Keywords Plus (ID)	8012
	Author's Keywords (DE)	Author's Keywords (DE)	3946
Autores/Authors	Authors	Autores	5951
	Authors of single-authored docs	Autores de documentos de autor único	73
Colaboração dos autores/ Authorss collaboration	Single-authored docs	Documentos de autor único	129
	Co-Authors per Doc	Documentos co-autorado	4.25
	International co-authorships %	Co-autorias internacionais %	11.46

Figura 2.1. Estatísticas iniciais dos documentos. Fonte: Adaptado de Bibliometrix

Tipos de documentos/ Document types	conference paper	artigo de conferência	1239	49.66%
	article	artigo	1162	46.57%
	conference review	revisão da conferência	46	1.84%
	book chapter	capítulo de livro	19	0.76%
	review	revisão/análise	18	0.72%
	book	livro	4	0.16%
	letter	carta	3	0.12%
	erratum	errata	2	0.08%
	editorial	editorial	1	0.04%
	note	nota	1	0.04%

Figura 2.2. Tipos de documentos. Fonte: Adaptado de Bibliometrix

O primeiro documento publicado, de acordo com o conjunto de documentos do estudo é em 1978 e é relativo a um artigo de conferência, relativo à utilização de dados de satélite em áreas como a temperatura da superfície do mar, correntes marítimas, detecção de navios e monitorização de tráfego marítimo (Wedler & Worsfold, 1978). Relativamente à taxa de crescimento anual, esta é de 13.68%, verificando-se um maior crescimento a partir de 2006 (17 documentos) que tem vindo a aumentar significativamente até 2024 (364 documentos). Verifica-se também, de acordo com a figura abaixo, que o ano com mais documentos publicados é o de 2022, com 376 documentos. Uma possível explicação para este incremento é as ferramentas de *Remote Sensing* estarem mais disponíveis, o avanço tecnológico na área da Inteligência Artificial (IA), e também a existência de sensores com resoluções espaciais que permitem a detecção de navios.




Figura 2.3. Produção científica anual. Fonte: Bibliometrix

2.1.2. SCIENCE MAPPING

O *science mapping* é utilizado para obter um panorama geral das interações entre diferentes elementos (autores, artigos, países), de modo a obter uma visualização dessas relações e verificar literatura relevante (Öztürk et al., 2024). Reflete, de forma intuitiva e gráfica as interações sociais, identifica instituições e principais países que trabalham nesta área de estudo (Öztürk et al., 2024). É possível ainda analisar as palavras-chave e verificar as relações entre elas, verificar como os conceitos se relacionam e identificar temas e conceitos dominantes (Öztürk et al., 2024). Tem ainda como objetivo, a identificação de subtemas e conceitos emergentes, que podem ser foco de novos estudos.

Na figura abaixo, identifica-se quais os autores com mais documentos escritos sobre o tema de estudo. Concretamente, Zhang Xiaoling, com 42 documentos elaborados, é o principal autor para o conjunto de documentos analisados.




Figura 2.4. Número de documentos por autor. Fonte: Bibliometrix

Podemos ainda analisar a produção dos autores ao longo do tempo, de modo a ter uma visão temporal sobre os autores, conforme imagem abaixo. Zhang Xiaoling, mencionado acima como o principal autor neste estudo, publicou os seus documentos entre 2019 e 2024. Podemos ainda observar que Zhang Xiaoling tem o maior número de artigos publicados num ano, com 13 artigos em 2022. Já Chen Peng, que ainda com 29 documentos publicados, é o autor que publica por um maior período, tendo o seu primeiro artigo sido publicado em 2004, e o mais recente em 2024.




Figura 2.5. Produção dos autores ao longo do tempo. Fonte: Bibliometrix

Podemos ainda fazer uma análise relativamente às instituições e universidades que produziram mais documentos. A instituição mais relevante é a *National University of Defense Technology* (NUDF), que tem origem na antiga *Military Academy of Engineering, People's Liberation Army*, fundada em 1953 na China (National University of Defense Technology, n.d.). A NUDF é uma universidade dedicada à investigação, com um importante papel no desenvolvimento da China, na segurança e em vários outros setores. Tal como se pode observar na imagem abaixo, é possível começar a concluir que uma parte significativa dos documentos tem origem na China, em que as 10 instituições com mais documentos publicados são deste país.




Figura 2.6. Instituições mais relevantes. Fonte: Bibliometrix

Neste seguimento, observa-se agora a distribuição dos autores por países. De acordo com a figura seguinte, verifica-se que com grande maioria, os documentos têm a sua autoria na China. Tanto no que se refere a *Single Country Publications* (SCP), tanto a *Multiple Country Publications* (MCP), a China é o país com os maiores valores (97 MCP e 1388 SCP). O segundo país com mais documentos é o Canadá (29 MCP e 56 SCP), seguindo-se a Itália (14 MCP e 69 SCP). Portugal aparece em 19º lugar, com 6 documentos.




Figura 2.7. Nacionalidade dos autores. Fonte: Bibliometrix

Uma vez mais, é em meados de 2006, em que existe um aumento significativo do número de artigos publicados. Concretamente, e de acordo com a figura abaixo, é nessa data que se assinala um grande incremento no número de artigos elaborados na China, que segue uma tendência exponencial, evidenciando um grande aumento, comparativamente aos restantes países.




Figura 2.8. Produção científica por país, ao longo do tempo. Fonte: Bibliometrix

No que concerne à dinâmica entre países, podemos observar com a figura abaixo o Mapa de Colaboração entre países. Observa-se que a China é o centro de produção dos documentos, com linhas de colaboração com Austrália, Estados Unidos da América (EUA), Reino Unido, Austrália e Japão. Observa-se também uma forte ligação entre a Austrália e a África do Sul. Na Europa, é de realçar os trabalhos realizados entre a Itália e Alemanha, Itália e Países Baixos, Itália e França e França e Espanha, sendo estas as principais dinâmicas europeias.

Country Collaboration Map




Figura 2.9. Mapa de colaboração entre países

Fazendo uma análise às palavras-chave ou *keywords* é possível identificar dinâmicas entre os documentos e compreender quais as *keywords* mais frequentes, como é que se interligam a outras *keywords* e identificar *clusters*. Na figura abaixo, obtida a partir dos VOSviewer, podemos observar as ligações entre as *keywords* dos vários documentos deste trabalho. Observa-se que as principais *keywords* são "ship detection" e "remote sensing", "SAR" e "detection methods", dando origem a quatro *clusters*.

2.1.3. ANÁLISE BIBLIOMÉTRICA – *DARK VESSELS*

Faz-se agora uma análise bibliométrica mais simples, mas focada nos documentos referentes a *dark vessels*, dos quais se verifica que, apesar de existirem trabalhos realizados sobre este subtema, é ainda um tema subdesenvolvido. No entanto, são fortes as ligações entre a Detecção Remota e os *dark vessels*.

Analisando então os documentos exclusivamente sobre deteção, procedeu-se à seguinte *query*:

("non broadcasting vessels" OR "dark vessel" OR "unlit ship" OR "stealthy boat" OR "covert vessel" OR "dark ships" OR "ghost ships" OR "phantom fleet") AND ("detection") AND PUBYEAR > 1990 AND PUBYEAR < 2025

Obteve-se 121 documentos, que foram depois filtrados para 101 após retirar documentos descontextualizados. Verifica-se um resultado com menor número de documentos que a pesquisa anterior (2495). Após uma análise sumária, temos os seguintes dados, de acordo com a figura abaixo. Para estes documentos, verifica-se que o primeiro é de 2003, e os documentos tem uma taxa de crescimento anual de cerca de 16%.

	Description	Descrição	Resultados/Results
Informação principal/Main information about data	Timespan	Período temporal	2003:2024
	Sources (Journals, Books, etc)	Fontes (jornais, livros, etc)	73
	Documents	Documentos	101
	Annual Growth Rate %	Taxa de Crescimento Anual/Annual Growth Rate %	16.34
	Document Average Age	Idade média do documento	4.05
	Average citations per doc	Média de citações por documento	10.20
Conteúdo dos documentos/Document contents	Keywords Plus (ID)	Keywords Plus (ID)	830
	Author's Keywords (DE)	Author's Keywords (DE)	326
Autores/Authors	Authors	Autores	377
	Authors of single-authored docs	Autores de documentos de autor único	7
Colaboração dos autores/Authorss collaboration	Single-authored docs	Documentos de autor único	7
	Co-Authors per Doc	Co-autores por documento	4.44
	International co-authorships %	Co-autorias internacionais %	17.82

Figura 2.12. Estatísticas iniciais dos documentos sobre dark vessels. Fonte: Adaptado de Bibliometrix

De forma sumária, verifica-se, pela figura (a), uma taxa de produção científica em crescimento que revela semelhança à *query* inicial. Relativamente à produção dos autores ao longo dos anos, verifica-se um comportamento diferente, em que podemos verificar que é um tema mais recente cujos autores desenvolvem os seus trabalhos por períodos mais curtos. Verifica-se

que os autores com mais documentos publicados (Graziano MD. e Renga A.) têm o seu primeiro artigo publicado em 2021. Relativamente às principais instituições, de acordo com a figura (c), são elas a *Technical University of Denmark*, a *University of Naples Federico II* e a *Stanford University*. Aqui, verifica-se uma grande diferença com a *query* inicial, em que as principais instituições são chinesas. Em relação aos países dos autores, verificam-se também diferenças, conforme se pode constatar na figura (d). Agora, temos uma distribuição mais distribuída, em que os principais países são os EUA, Reino Unido e Itália.




Figura 2.13. Análise resultados dark vessels. (a) Produção científica anual. (b) Produção dos autores ao longo do tempo. (c) Principais instituições. (d) Nacionalidade dos autores.

Observe-se agora a relação entre os documentos, através das suas *keywords*. Na figura abaixo, podemos observar a dinâmica e a forma como os documentos estão relacionados. É possível observar uma forte relação entre os temas "SAR" e "space-based radar", "AIS", "deep learning". Ainda, vemos uma relação entre SAR e "satellite imagery", que dão origem a relações com "computer simulation" e "remote sensing". Este último, relaciona-se também com um cluster final sobre "data" e "investigation". Em torno destas palavras-chave, criam-se clusters, com temas semelhantes entre si. Importa realçar o SAR como um centro entre os trabalhos de identificação de navios, utilizando SAR como principal técnica de Detecção Remota.




Figura 2.14. Principais keywords em dark vessels. Fonte: VOSviewer

A deteção de *dark vessels* é um subtema emergente dentro de um tema mais abrangente que é a deteção de navios por deteção remota. A principal diferença surge nas limitações que existem quando os navios navegam sem AIS ligado, o que torna um desafio à deteção de navios. Verifica-se desta forma uma oportunidade de estudo significativa, que apesar de não ser inteiramente nova, encontra-se ainda em desenvolvimento. Com esta análise bibliométrica podemos também concluir que os estudos nesta área são multidisciplinares e existe oportunidade de utilizar técnicas inovadoras, tais como o desenvolvimento de algoritmos de deteção através de inteligência artificial.

2.2. ESTADO DA ARTE

2.2.1. DADOS UTILIZADOS EM OUTROS TRABALHOS

Os principais trabalhos na deteção e classificação de navios utilizam de uma forma geral, dados provenientes de imagens de satélites óticos ou por *Synthetic Aperture Radar*, sendo este último a principal fonte de dados (Kanjir et al., 2018, p. 20), o que vai de encontro com a análise bibliométrica realizada.

Outras fontes de dados, ainda que menos habituais, incluem dados de *Light Detection and Ranging* (LIDAR), térmicos e infravermelhos.

2.2.1.1. SATÉLITES ÓTICOS

Os satélites óticos de observação da terra funcionam ao capturar radiação eletromagnética refletida pela Terra. Estes sensores detetam radiação ao longo de um espectro que vai desde o visível ao infra-vermelho (O'Donohue, 2023). Quando a luz, normalmente proveniente do Sol, incide na superfície da Terra, uma parte é refletida, que é detetada pelos satélites e depois é utilizada para criar as imagens e a outra é novamente enviada para o espaço (O'Donohue, 2023).

As imagens provenientes de satélites óticos recorrem a sensores passivos, que requerem iluminação externa (Kanjir et al., 2018, p. 1). Às custas de sacrificar a resolução espacial, é possível a utilização de sensores multiespectrais, que por sua vez permite a colorização das imagens, facilitando a classificação de contactos (Kanjir et al., 2018, p. 3). No entanto, os sensores óticos são suscetíveis às condições meteorológicas, nomeadamente da cobertura de nuvens, chuva e por dependerem de iluminação externa, não são capazes de funcionar durante o período noturno (Kanjir et al., 2018). Já Tripicchio (2024) refere que a identificação de navios a partir de sensores óticos é um desafio, atendendo às condições marítimas complexas, devido às imagens serem influenciadas por fatores como a luz, meteorologia e também pela presença de outros navios e por objetos na área.

Segundo Kanjir et al. (2018), os principais sensores utilizados, entre 1978 e 2017, são o *QuickBird*, *IKONOS*, *WorldView-2*, *GeoEye-1* e o *WorldView-3* para imagens de *Very High Resolution*. Segundo o mesmo autor, para imagens de *High Resolution* (HR) o principal sensor é o *SPOT-5*. Para imagens de média resolução os sensores mais utilizados são o *LandSat* e *CBERS*. De realçar, um aumento nos trabalhos que utilizam *Gaofen-1*, *Formosat-2* e o *Sentinel-2* (Kanjir et al., 2018, p. 13).

2.2.1.2. SAR

Os sensores SAR, por não dependerem de luz sol para produzir uma imagem, são capazes de penetrar pelas nuvens e chuva, sendo então utilizados na deteção de cheias, desflorestação, derrames de substâncias nocivas no mar, degelo e também na deteção de navios (Menezes, 2023).

De acordo com Menezes (2023), enquanto os sensores óticos absorvem a radiação refletida por uma fonte de luz (sol), nos sensores SAR, são os próprios sensores a gerar a energia, que é depois absorvida. O significado de SAR pode ser decomposto em *Synthetic Aperture* RADAR.

RADAR, por sua vez, é um acrónimo de *Radio Detection and Raging* que significa a deteção e determinação de uma distância através de ondas rádio. Já o *Synthetic Aperture* significa que a "abertura" do sensor, como numa câmara fotográfica, é produto do processamento da combinação de várias imagens, que quando combinadas, permite uma "abertura" que não seria possível, gerando resoluções espaciais maiores (Menezes, 2023).

Os sensores SAR, que são capazes de operar sem serem influenciados pelas condições atmosféricas e durante o período noturno, apresentam também algumas desvantagens, uma vez que a sua resolução espacial é menor, e uma vez que não é possível observar as imagens com cores reais, torna a classificação dos contactos mais difícil, tornando a análise das imagens uma tarefa mais complexa (Kanjir et al., 2018). Segundo Paolo et al. (2024), os sistemas SAR provaram ser a opção mais consistente para detetar navios no mar, afirmando que os sensores SAR não são afetados pelos níveis de luminosidade e pelas condições meteorológicas, incluindo nuvens e chuva (Paolo et al., 2024).

A *European Space Agency* (ESA), desenvolveu, em parceria com a *Rockmann Consult*, *SkyWatch* e a *C-S*, uma plataforma chamada *Sentinel Application Platform* (SNAP). Este software permite a visualização, análise e processamento de dados provenientes de sensores de Deteção Remota (ESA, n.d.-b), sendo particularmente úteis na análise de dados dos satélites do programa *Copernicus*, nomeadamente do *Sentinel-1*. Dispõe de várias ferramentas para a análise de dados SAR, permitindo realizar calibrações radiométricas, redução de "ruído" e ainda a deteção de objetos no mar, como navios.

2.2.2. METODOLOGIAS UTILIZADAS EM TRABALHOS CONGÉNERES

Através de uma análise às referências bibliográficas, podemos concluir que, de forma de geral, as metodologias utilizadas em outros trabalhos congéneres, como em Kanjir et al. (2018), seguem etapas semelhantes. Podemos resumir as metodologias pelas seguintes etapas:

- Aquisição de Dados – Seleção da fonte de dados, quer seja SAR, ótica ou outra;
- Separação entre Terra-Mar – Isolar a porção da imagem que corresponde apenas à zona marítima. Evita falsos-positivos, especialmente em zonas portuárias e pode ser feita recorrendo a uma máscara;
- Deteção – Assinalar os objetos que correspondem a navios. Esta etapa pode ser feita de acordo com diversas metodologias, quer seja através de algoritmos complexos

como o YOLO (Mishra et al., 2023), quer por IA, ou por uma abordagem *threshold-based* (Schwegmann et al., 2014);

- Classificação – consiste em atribuir uma categoria ao navio, como por exemplo, identificar a tipologia do navio. Em casos mais complexos esta etapa poderá ser concretizada em reconhecer e identificar qual o navio, através de um número de identificação único (e. g. IMO e MMSI);
- Cálculo da precisão – Avaliar o modelo e perceber qual o grau de precisão do mesmo.

3. METODOLOGIA

A metodologia utilizada segue uma abordagem *Design Science* em que é possível distinguir as etapas de as etapas de conceptualização, construção, avaliação e produção de um artefacto. A conceptualização, que foi feita com base no capítulo anterior, teve a sua base na revisão da literatura e na definição de objetivos. Para a construção, foi criado um modelo para a deteção de navios e, em seguida, de *dark vessels*, que irá ser explicada no decorrer deste capítulo. A etapa de avaliação é feita com recurso a uma matriz de confusão e é utilizada para avaliar a precisão do modelo. Por fim, é realizado um estudo prolongado num período e é feita a análise dos resultados e produzidas conclusões. Este capítulo apresenta o modelo desenvolvido de uma forma teórica, que é depois experimentado, no capítulo seguinte.

A metodologia que foi desenvolvida pode ser resumida ao longo de sete etapas: aquisição de dados, separação terra-mar, pré-processamento, análise exploratória de dados, deteção de navios, deteção de *dark vessels* e cálculo da precisão. Segue agora uma breve explicação destas etapas, sendo que ao longo deste capítulo estas etapas irão ser abordadas em mais detalhe.

Tal como foi referido anteriormente, a aquisição de dados consiste na seleção da fonte de dados. Para o estudo com sensores óticos, os dados foram recolhidos através do *Copernicus Browser* e correspondem a dados do Sentinel-2. Para o estudo com sensores SAR, foram obtidos pelo *ASF Data Search*, que por sua vez correspondem a dados do *Sentinel-1*.

A separação terra-mar, permite isolar a porção da imagem que corresponde apenas à zona marítima. Apesar de ser uma importante etapa, neste estudo em concreto não foi necessária, uma vez que a área de estudo é toda ela em área marítima.

O pré-processamento consiste na correção das imagens, normalmente devido a erros gerados na aquisição dos dados, como correções radiométricas e atmosféricas. Esta etapa, como vai ser explicado no decorrer do trabalho, não é necessária uma vez que os produtos disponibilizados já estão pré-processados. No entanto, nesta etapa foi realizada, para sensores óticos, o mascaramento de nuvens para reduzir o número de falsos positivos.

A análise exploratória dos dados consiste em compreender os dados e na visualização das imagens. Para sensores óticos foram criadas composições coloridas RGB 432 e RGB 843 e na banda artificial *Normalized Difference Water Index* (NDWI). Para os sensores SAR, foram criadas composições coloridas RGB VV; VH; VV e RGB VV; (VV-VH); VH.

A detecção de navios consiste em assinalar os objetos que correspondem a navios, através de um *buffer* em torno dos mesmos. Para sensores óticos é realizado através de uma abordagem de *threshold-based* e para sensores SAR através de *Two-Parameter Constant False Alarm Rate* (CFAR).

A detecção de *dark vessels* consiste em identificar quais os navios que não estão a transmitir a posição AIS e é realizado através da comparação de uma base de dados AIS com os navios detetados. Nos casos em que não existe sobreposição podemos pressupor que estamos perante um possível *dark vessel*.

O cálculo da precisão consiste em avaliar o modelo e perceber qual o grau de precisão do mesmo e é realizado através de uma matriz de confusão, para o cálculo do valor do F1-score. A tabela abaixo resume a metodologia utilizada, para cada uma das diferentes fontes de dados (ótico e SAR).

Tabela 3.1. Metodologia

	Aquisição de dados	Separação Terra-Mar	Pré-processamento	Análise Exploratória	Deteção Navios	Deteção <i>dark vessels</i>	Cálculo precisão
Ótico	Copernicus Browser Sentinel-2	Não foi necessária uma vez que a área de estudo é toda ela em área marítima	Máscara de nuvens para reduzir o número de falsos positivos	RGB 432 RGB 843 NDWI	NDWI Threshold	Sobreposição navios detetados com posições AIS	Matriz confusão Precisão Recall
SAR	ASF Data Search Sentinel-1			RGB VV; VH; VV RGB VV; (VV-VH); VH.	<i>Ocean Object Detection</i>		

3.1. ÁREA DE ESTUDO

A área de estudo foi definida com base num retângulo com as dimensões de um grau de latitude por um grau de longitude, tendo o seu vértice mais a Nordeste (NE) junto à vila de Sagres. Esta área, que tem uma dimensão de cerca de 10000 km^2 ($90\text{km} \times 110\text{km}$), isto é, cerca de 49NM^1 por 60NM . Coincide com uma das principais zonas de tráfico marítimo em

¹ Nautical Mile ou milha nautica

Portugal (Centro de Engenharia e Tecnologia Naval e Oceânica, 2025), junto aos Esquemas de Separação de Tráfego (EST) do Cabo de São Vicente e foi escolhida por forma a aumentar o número de navios possíveis de serem detetados, conforme sugerido por Nunes (2022). Esta área foi definida por um polígono entre as coordenadas: 9W e 10W de longitude e os 36N e 37N de latitude, conforme a imagem abaixo. A área de estudo abrange simultaneamente porções do Mar Territorial Português (MTP), da Zona Contígua (ZC), da Zona Marítima Particularmente Sensível (ZMPS) e da Zona Económica Exclusiva (ZEE), estando totalmente inserida na área de *Search and Rescue* (SAR), onde tem a responsabilidade pela salvaguarda da vida no mar e é responsável por assegurar a coordenação das operações de busca e salvamento marítimo (DGRM, 2018).




Figura 3.1. Área de estudo. Fonte: Autor.

3.2. DADOS

Os dados estão divididos em duas categorias, isto é, dados relativos a imagens de sensores óticos e SAR e dados com as posições de navios, provenientes de dados AIS.

Os dados AIS foram facultados pela Direção de Análise e Gestão da Informação (DAGI) da Marinha Portuguesa, e são provenientes de dados T-AIS, SAT-AIS e MSSIS, que contêm informação referente aos navios (posição medida em latitude e longitude, hora em que a posição foi obtida, velocidade, proa e rumo). Estes dados foram processados através do software MATLAB R2023b (v. 23.2.0.2409890), tendo sido criados pequenos *scripts* para seleccionar apenas dados na área de estudo, transformar a data-hora de um formato *datetime* para um formato legível em ArcGIS Pro e para compilar os dados das diversas fontes. Estes dados foram também processados por forma a excluir elementos que pudessem identificar ou associar diretamente qualquer embarcação.

As imagens provenientes de sensores óticos foram obtidas a partir do Sentinel-2, que é constituído por uma constelação de dois satélites, o *Sentinel-2A* e o *Sentinel-2B*. As imagens foram adquiridas através do *Copernicus Data Space Ecosystem (Copernicus Browser)*, que disponibiliza os dados em fonte aberta, com resoluções espacial, temporal e espectral adequadas.

Relativamente às imagens de SAR são obtidas pela plataforma *ASF Data Search*, desenvolvida pela *Alaska Satellite Facility (ASF)*, sendo uma parceria com a *National Aeronautics and Space Administration (NASA)* para disponibilizar e arquivar dados provenientes de satélites SAR, como do *Sentinel-1* (Alaska Satellite Facility, 2025).

O quadro abaixo resume a disponibilidade das imagens, considerando a resolução temporal dos satélites, que não permite obter imagens diárias para a área de estudo. Ainda, para as imagens de sensores óticos, por serem afetadas pelas condições meteorológicas, nem sempre reúnem as condições de visibilidade mínimas para serem utilizadas neste trabalho. Por forma a reduzir o número de imagens afetadas pela nebulosidade, optou-se por realizar este trabalho referente ao mês de setembro (de 2024), considerando ser um dos meses com menor nebulosidade e precipitação deste ano (Weather Spark, n.d.), e que maximiza o número de imagens possíveis de utilizar. O quadro refere ainda a percentagem da área de estudo abrangida pelas imagens.

Tabela 3.2. Disponibilidade de dados óticos e SAR. Fonte: Autor.

Set.	Sentinel - 2			Sentinel -1	
Dia	% Área	Hora	% Neb.	% Área	Hora
2				55	18:43
3	30	11:33	8.8	85	06:44
5	100	11:21	0.3		
9				100	18:35
10	100	11:21	5	60	06:36
13	30	11:33	3.5		
14				50	18:43
15	100	11:21	49	100	06:44
18	30	11:33	40		
20	100	11:21	89		
21				100	18:35
22				50	06:36
23	30	11:33	1.4		
25	100	11:21	92		
26				50	18:43
27				100	06:44
28	30	11:33	10		
30	100	11:21	0		

3.3. SELEÇÃO DO SATÉLITE E SENSOR E AQUISIÇÃO DADOS

3.3.1. SENSORES ÓTICOS

Conforme referido anteriormente, as imagens de sensores óticos foram recolhidas pelo Sentinel-2. O Sentinel-2 foi desenvolvido pela Agência Espacial Europeia (ESA) e está integrado no programa *Copernicus*. É constituído por uma constelação de dois satélites de órbita polar, com sensor multiespectral, o Sentinel-2A e o Sentinel-2B, lançados em 2015 e 2017, respetivamente (Caetano, 2018). O Sentinel-2 possui um sensor, o *MultiSpectral Instrument* (MSI), que dispõe de 13 bandas entre os 422 e os 2190 nm, cuja gama vai desde o visível ao infravermelho médio. Relativamente à resolução espacial, estão disponíveis imagens com uma resolução de 60m, 20m e 10m. Por fim, a resolução temporal deste satélite é de 10 dias². Neste trabalho utilizou-se dados com resolução espacial de 10m, utilizando -se as seguintes bandas: B02 (Azul), B03 (Verde), B04 (Vermelho) e B08 (Infravermelho próximo). Ao longo do trabalho, utilizou-se dados referentes a três dias (05, 10 e 30 de setembro 2024).

² Uma vez que existem dois satélites, é possível obter imagens no máximo a cada 5 dias para a mesma área.

3.3.2. SENSORES SAR

As imagens de sensores SAR foram recolhidas pelo Sentinel-1, que pertence também a ESA e está integrado na iniciativa *Copernicus*. O Sentinel-1 consiste numa constelação de 2 satélites de órbita polar heliossíncrona, lançados em 2014 (Sentinel-1A) e em 2016 (Sentinel-1B) (Caetano, 2018), que estão desfasados em 180 graus, o que permite operar de dia bem como no período noturno (ESA, 2025). O Sentinel-1 opera na Banda-C (entre os 3.8cm e os 7.5 cm ou entre 4 a 8Ghz) e tem resoluções espaciais de até 5m, com dupla polarização (VV e VH) (ESA, 2025). Os dados do Sentinel-1 foram obtidos através da *ASF Data Search*, que disponibiliza os produtos de nível 1, com uma resolução de 10m.

3.4. PRE-PROCESSAMENTO

3.4.1. SENSORES ÓTICOS

A primeira etapa para o processamento de imagens de satélites óticos inicia com o pré-processamento, que tem como objetivo reduzir as distorções introduzidas durante a aquisição da imagem, nomeadamente correções geométricas e correções radiométricas (Caetano, 2018). Para este trabalho, não foi necessário realizar nenhum tipo de pré-processamento, para além da remoção de áreas com nuvens, considerando que os produtos de nível 2A (Sentinel-2 L2A) já foram disponibilizados com as devidas correções (ESA, 2022).

3.4.2. SENSORES SAR

Os produtos utilizados neste trabalho foram os produtos de nível S1 *Ground Range Detected* (GRD) que já foram pré-processados antes de serem disponibilizados. Para gerar estes produtos, os dados são corrigidos seguido as etapas de pré-processamento (análise de dados brutos, calibrações), seguindo-se da aplicação de algoritmos de correção como o *Single Look Complex* (SLC) e terminando com algoritmos de pós-processamento (ESA, 2025). Neste sentido, para este estudo em concreto não foi necessário proceder a etapas de pré-processamento uma vez que os produtos de nível S1-GDR já são disponibilizados com coordenadas terrestres georreferenciadas e pronto a ser utilizado.

3.5. ANÁLISE EXPLORATÓRIA DOS DADOS

3.5.1. SENSORES ÓTICOS

A análise exploratória para sensores óticos iniciou com a transformação das bandas (B02, B03, B04 e B08) do Sentinel-2 nas *layers* 1, 2, 3 e 4, respetivamente. Para apoio à análise da área de estudo, procedeu-se à criação de composições coloridas RGB 432 (cores verdadeiras) e RGB

843 (falsa cor). A partir das imagens resultantes, foram criados compósitos RGB, reorganizando as *layers* para diferentes tipos de visualização. Na composição de cores verdadeiras, as *layers* 3, 2 e 1 foram atribuídas às cores vermelho, verde e azul, resultando na combinação (B04, B03, B02), que representa a imagem como vista pelo olho humano. Já na composição de cores falsas, as *layers* 4, 3 e 2 foram exibidas como infravermelho, verde e azul, formando a combinação (B08, B04, B03), destacando elementos não perceptíveis no espectro visível.

Considerando que toda a área de estudo se encontra no mar (em água), exceto outros objetos como navios, optou-se por efetuar um processo de transformação de bandas através da criação de um grupo de bandas artificiais (ou transformadas), através da realização de operações algébricas. Concretamente, a transformação realizada foi a *Normalized Difference Water Index* (NDWI), que foi proposta desenvolvida para detetar e monitorizar diferenças no conteúdo de água, utilizando as bandas de Infravermelho próximo e Verde (EOS, 2021). O NDWI é capaz de detetar e realçar as massas de água numa imagem. O NDWI foi calculado em *Raster Calculator* através da fórmula abaixo:

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (3.1)$$

Em que GREEN e NIR correspondem às bandas B03 e B08, respetivamente.

3.5.2. SENSORES SAR

A análise exploratória dos dados SAR consiste na análise, por parte do analista, de duas composições coloridas. A primeira, é uma composição muito comum, em que são atribuídas as seguintes *layers*: VV; VH; VV (ou VH), às cores R, G, B, respetivamente. A segunda composição colorida foi criada com o propósito de melhorar a visualização sobre objetos metálicos (e. g. navios). Para tal, atribuiu-se as seguintes *layers*: VV; (VV-VH); VH, às cores R, G, B, respetivamente. A *layer* (VV-VH) é uma *layer* artificial criada em *Raster Calculator*.

3.6. DETEÇÃO NAVIOS

3.6.1. SENSORES ÓTICOS

A deteção de navios por sensores óticos segue uma abordagem de *threshold-based*. É definido um valor a partir do qual é possível distinguir valores para água e valores para um objeto (navio), e de acordo com esse valor, é feita uma reclassificação, sendo atribuído o valor "1" a objetos classificados como navio e "0" a píxeis classificados como água. O valor do *threshold* é

definido com recurso á análise de histogramas por forma a seleccionar os valores menos frequentes e nos extremos do espectro. Para a detecção foi utilizada a banda transformada NDWI, calculada no subcapítulo anterior. No decorrer deste trabalho estudou-se outras formas de detecção de navios como classificação não supervisionada, classificação supervisionada (*Iso Cluster Supervised*) e foram utilizadas outras abordagens como a *Principal Component Analysis* (PCA). Verificou-se que a abordagem *threshold-based* permite simultaneamente obter resultados precisos e de forma mais rápida que as alternativas anteriores.

Após a classificação de píxeis como navio, são realizadas etapas de pós-processamento como a suavização e redução de ruído através de *Majority Filter*, por forma a reduzir o número de falsos positivos e reduzir o número de píxeis isolados (frutos de reflexões e erros de classificação). Os píxeis classificados como navios são depois convertidos em polígonos. Para reduzir o número de falsos positivos, seleccionou-se apenas polígonos com dimensões entre 50 e 1000 metros, por forma a evitar seleccionar falsos-positivos frutos das nuvens nas imagens. Por fim, e de forma a criar um produto mais apresentável, são criados *buffers* em torno dos objetos agora detetados como navios, que são depois trabalhados para ter apenas um *buffer* em torno de cada navio.

O modelo foi construído em *Model Builder*, conforme representado na figura abaixo e também no Apêndice A, que ilustra as etapas de detecção de navios através de sensores óticos.



Figura 3.2. Modelo da detecção de navios

3.6.2. SENSORES SAR

A detecção de navios através de imagens SAR é feita no *Software Sentinel Application Platform* (SNAP) Desktop (v. 11.0.0), através da ferramenta *Ocean Object Detection*. Esta ferramenta utiliza o método de *Two-Parameter Constant False Alarm Rate* (CFAR), que de uma forma geral, deteta píxeis com valores fora do comum, quando comparados com valores de píxeis na redondeza (ESA, n.d.-a). Este método tem quatro principais etapas:

- Pré-processamento – A imagem é calibrada por forma a tornar o processo mais preciso, através de calibração radiométrica. Para este trabalho esta etapa não é necessária, uma vez que as imagens utilizadas já foram calibradas, conforme descrito anteriormente.
- Máscara terra-mar – É criada uma máscara para separar a região do mar da região de terra para garantir que a deteção se foca na área de estudo. Novamente, esta etapa é redundante uma vez que a área de estudo escolhida é toda no mar.
- Deteção CFAR – Os objetos são detetados através do método do CFAR. O CFAR compara o valor de um píxel com os valores na sua redondeza e caso esse píxel seja mais brilhante que o valor médio, considera-o como um alvo. Para isto, são definidas três áreas: uma janela para o píxel a ser testado, uma janela de guarda para isolar a janela de teste e uma zona de fundo para estimar o valor médio (ESA, n.d.-a);
- Discriminação – Por fim, os objetos detetados são filtrados, selecionando apenas objetos com um tamanho mínimo de deteção.

3.7. DETEÇÃO *DARK VESSELS*

O processo para a deteção de *dark vessels* é idêntico tanto para os sensores óticos, como para os SAR. De um ponto de vista espacial, compara-se se existe sobreposição entre a posição AIS para esse Dia/Hora, com o *buffer* em torno do objeto que foi detetado. Se existe nesse *buffer* sobreposição com uma posição AIS, o processo classifica o objeto como “Navio a transmitir” e nos casos em que não existe uma posição AIS, é classificado como “Suspeito”.

Este processo é concretizado em um modelo em *Model Builder*, que realiza uma operação de *Spatial Join* entre a camada com os *buffers* e a camada com as posições AIS. Esta operação gera um campo, com a contabilização de sobreposições. É depois criado um campo, estado, que é classificado de acordo com a seguinte expressão, em *python*:

"Transmitting" if !Join_Count! > 0 else "Suspect"

que atribuí um valor ao campo “estado”, de “Navio a transmitir” caso haja sobreposição e o valor “Suspeito” caso essa sobreposição não exista.

Importa referir que se verificou um desfasamento de uma hora e 10 minutos (1h10m), entre as posições AIS e as imagens óticas e SAR, sendo necessário fazer um ajuste na seleção das posições AIS.

A figura abaixo representa o modelo desenvolvido, em *Model Builder*:




Figura 3.3. Modelo da detecção de dark vessels

3.8 CÁLCULO PRECISÃO

O cálculo da precisão do modelo funciona de igual forma tanto para os sensores óticos tanto para os sensores SAR. Este cálculo é realizado através do F1-score, uma métrica para avaliar a performance de um modelo (Sasaki, 2007).

Na prática, são calculados os valores da precisão e do *recall*, que são utilizados para obter o valor do F1-score, tal como representado pelas fórmulas abaixo:

$$Precisão = \frac{VP}{VP + FP} \quad (3.2)$$

e

$$Recall = \frac{VP}{VP + FN} \quad (3.3)$$

Em que VP é o número de Verdadeiros-Positivos, FP é o número de Falsos-Positivos e FN é o número de Falsos-Negativos que são calculados a partir de uma Matriz de confusão, com a seguinte estrutura:

		Previsto/Modelo	
		Positivo	Negativo
Real/Verdadeiro	Positivo	Verdadeiro-Positivo (VP)	Falso-Negativo (FN)
	Negativo	Falso-Positivo (FP)	Verdadeiro-Negativo (VN)

Assim, seja F1 o valor para o F1-score, temos:

$$F1 = 2 \times \frac{Precisão \times Recall}{Precisão + Recall} \quad (3.4)$$

De acordo com Powers (2011), se um valor de F1 for próximo de 1, é considerado alto e indica que o modelo tem um bom equilíbrio entre precisão e *recall*. Caso tenha um valor baixo (próximo de 0), indica que o modelo pode estar a regerar muitos falsos-positivos ou falsos-negativos.

4. ESTUDO EMPÍRICO

Tal como descrito na estrutura do trabalho, neste capítulo vai-se proceder à realização da prova conceito, seguindo as etapas desenvolvidas na metodologia. Para efeitos de demonstração, vai se realizar o processo de deteção de *dark vessels*, primeiramente através de sensores óticos e em seguida com sensores SAR. Esta prova de conceito é realizada para apenas um dia, sabendo que seria depois replicada para o restante período de observação.

4.1 PROVA DE CONCEITO - ÓTICO


De acordo com a metodologia desenvolvida, o estudo inicia com a seleção do sensor e com a respetiva aquisição de dados. Tal como referido ao longo do trabalho, os dados recolhidos são provenientes do *Sentinel-2*. Concretamente, são utilizados nesta prova de conceito, dados referentes ao dia 30 de setembro de 2024, cuja imagem de satélite foi recolhida às 11h21m19s. Optou-se por utilizar dados deste dia uma vez que temos uma cobertura de 100% da área de estudo e uma percentagem de nebulosidade de 0%. Uma vez mais, não é necessário proceder a algum tipo de pré-processamento, uma vez que os dados já vêm corrigidos.

A prova de conceito, na prática, inicia com a análise exploratória dos dados. Começou por se criar as composições coloridas RGB 432 (cores verdadeiras) e RGB 843 (falsa cor), que se podem observar nas figuras abaixo.


As figuras abaixo representam a composição colorida RGB 432, e temos figuras lado-a-lado, em que nas figuras à esquerda representam a imagem sem distorção e as figuras à direita com uma distorção de “*percent clip*”, por forma a ser analisar a imagem. É possível verificar que temos cerca de 95% de cobertura da área de estudo (figuras (a) e (b)). Na figura (b), verifica-se a presença de faixas, que correspondem a faixas de varrimento ou *stripping*, na obtenção de dados. Nas figuras (c) e (d), que têm uma maior escala, começamos a detetar a presença de navios, bem como a esteira³ por estes gerada. Por fim, na figura (c), temos um destaque de um navio, em que se pode observar com bastante detalhe o formato do navio, verificando-se uma reflectância muito distinta da do mar. De forma geral, podemos verificar, como análise

³ Rasto deixado por um navio, numa forma característica em “V”. Adaptado de: <https://crisp.nus.edu.sg/~research/shipwakes/shipwakes.htm>

exploratória, que é possível a detecção de navios, no entanto só é facilmente distinguível em grandes escalas.



(a)



(b)



(c)



(d)




(e)



(f)

Figura 4.1. Composição colorida RGB 432

No conjunto abaixo, observa-se agora a composição colorida RGB 843 (cores falsas). Verifica-se que os resultados são semelhantes, não se observando particular vantagem na utilização de uma composição ao invés da outra.




(a)



(b)



(c)



(d)





Figura 4.2. Composição colorida RGB 843


Em seguida, é criada uma banda artificial, NDWI, a partir da transformação da banda B04 e B02:

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} = \frac{B02 - B04}{B02 + B04} \quad (4.1)$$


As figuras abaixo representam a nova banda. Uma vez mais, verificam-se faixas de varrimento. Com o NDWI verifica-se uma grande diferença entre os valores, sendo possível distinguir três principais categorias: mar, esteira e navio, conforme se verifica nas figuras. De referir também, a existência de “formigueiro”, resultado da reflectância difusa do mar.



(a)



(b)



(c)

Figura 4.3. Banda artificial NDWI

De seguida, e de acordo a metodologia utilizada, procede-se à deteção navios, através das seguintes etapas: deteção de navios através da abordagem *threshold-based*, suavização de ruído, transformação dos navios detetados em polígonos e criação de *buffers* em torno dos navios, que facilita a sua visualização. As figuras abaixo representam as etapas descritas para a área de estudo. Podemos observar, no interior dos *buffers*, os navios que foram detetados por este método.





Figura 4.4. Navios detetados satélite ótico


No entanto, e como primeiras conclusões, que ainda sucintas, verifica-se que este método não é 100% preciso. Após uma inspeção visual, observam-se casos em que o método não deteta um navio (falso negativo), figuras (a) e (b), bem como casos em que um objeto (na prática, um conjunto de píxeis), são erradamente identificados como um navio (falso positivo), figuras (c) e (d). As figuras abaixo representam estas duas situações.




(a)



(b)



(c)



(d)

Figura 4.5. Erros da detecção de navios, satélite ótico

De acordo com a metodologia, na etapa seguinte, os navios são sobrepostos com as posições AIS. O modelo classifica em seguida os navios em “Navios a transmitir”, a verde, e em “Navio

Suspeito”, a vermelho. As figuras abaixo representam a classificação dos navios para a área de estudo. Observa-se a presença de 04 navios classificados como suspeitos e 18 navios classificados como navio a transmitir.




Figura 4.6. Classificação de navios, satélite ótico

Importa então, realizar o cálculo da precisão deste modelo, no que diz respeito à deteção dos navios. A precisão da deteção dos *dark vessel*, tal como explicado acima, depende sobretudo da base de dados das posições AIS utilizada. Assim, foi construída uma matriz de confusão, com os valores de VP, FP e FN, como representado abaixo. Para obter os valores reais, foi feita uma observação visual pelo analista:

		Previsto/Modelo	
		Positivo	Negativo
Real/Verdadeiro	Positivo	18	2
	Negativo	2	-

Desta forma, podemos calcular os valores para a precisão e para o *recall*:

$$Precisão = \frac{VP}{VP + FP} = \frac{18}{18 + 2} = 0.9 \quad (4.2)$$

e

$$Recall = \frac{VP}{VP + FN} = \frac{18}{18 + 2} = 0.9 \quad (4.3)$$


Que por sua vez, dá-nos o valor do F1-score:

$$F1 = 2 \times \frac{precisão \times recall}{precisão + recall} = 2 \times \frac{0.9 \times 0.9}{0.9 + 0.9} = 0.9 \quad (4.4)$$


4.2. PROVA DE CONCEITO - SAR

Inicia-se a prova de conceito SAR ao obter-se dados do Sentinel-1, referentes ao dia 27 de setembro de 2024. Como referido na metodologia, não é necessário realizar ações de pré-processamento, no entanto, foi necessário juntar dois produtos, um referente às 06h44m01s e o outro às 06h44m26s, uma vez que um só produto não abrange toda a área de estudo.


Inicia-se a análise exploratória, com a criação do compósito RGB (VV, VH, VH), conforme se pode observar as figuras abaixo. Uma grande vantagem que se pode observar é que as imagens recolhidas não são influenciadas pela nebulosidade, reduzindo o número de imagens inválidas. Ainda, verifica-se que é possível ter imagens recolhidas durante o arco noturno. Ao longo das figuras podemos verificar que é fácil de identificar um objeto no mar.



(a)




(b)




(c)
Figura 4.7. Análise exploratória SAR, compósito RGB (VV, VH, VH)


As figuras seguintes representam a composição colorida RGB (VV, (VV-VH), VH), criada por ser útil na identificação de navios e objetos no mar. Verifica-se, agora a rosa, que é possível identificar navios.



(a)



(b)



(c)

Figura 4.8. Análise exploratória SAR, colorida RGB (VV, (VV-VH), VH)

De seguida, utilizou-se o software SNAP para a deteção dos navios. Após criar *buffers* em torno dos mesmos é possível, através das figuras abaixo, verificar quais os navios que foram detetados.




Figura 4.9. Navios detetados, SAR

O funcionamento para a deteção de *dark vessels* funciona de forma idêntica ao caso de estudo para sensores óticos. Após uma análise visual, não se detetaram casos de falsos-positivos nem falsos-negativos pelo que não é necessário o cálculo da matriz de confusão (F1-score = 1).

5. RESULTADOS E DISCUSSÃO

5.1. RESULTADOS

Neste capítulo, vai ser feito um estudo ao longo de três dias para verificar a capacidade de utilizar as duas abordagens que foram desenvolvidas na detecção de *dark vessels*. Para isto, escolheu-se três dias, que pelas limitações dos satélites que foram apresentadas no primeiro capítulo, não é possível serem três dias consecutivos. Ainda assim, este estudo permite avaliar simultaneamente a capacidade dos modelos para serem testadas em casos reais, e também permite obter resultados concretos para a nossa área de estudo.

Como tal, para a abordagem de sensores óticos, foram selecionados os dias 05, 10 e 30 de setembro de 2024, datas em que se tentou maximizar a capacidade da detecção de navios, ao se minimizar a percentagem de nebulosidade. Para a abordagem com sensores SAR, foram selecionados os dias 09, 10 e 21 do mesmo mês e ano. Os modelos foram então executados, seguindo a metodologia e modelos do capítulo anterior.

Os resultados são agora apresentados de duas formas distintas. Em primeiro lugar, para efeitos de representação visual, as figuras abaixo representam a compilação de todos os navios detetados, a sua classificação e as posições AIS correspondentes, em que temos uma figura para cada abordagem (ótico e SAR). Em seguida, foi criada uma tabela, que permite fazer uma análise estatística dos resultados.

Para a análise dos resultados, bem como para a simbologia das figuras, utilizou-se a seguinte terminologia:

- Verdadeiro Positivo (VP) – Navio detetado nas imagens e tem um sinal AIS correspondente – Navio a transmitir;
- Falso Positivo (FP) – Navio detetado nas imagens, mas não tem sinal AIS correspondente. Subdivide-se em:
 - o Dark Vessel (DV) – Navio detetado, sem AIS, confirmado visualmente como navio;
 - o Falsa Detecção (FD) – Navio detetado, sem AIS, confirmado visualmente como falsa deteção;
- Falso Negativo (FN) – Navio com sinal AIS mas não foi detetado nas imagens.

Observa-se agora a figura que representa a compilação, ao longo de três dias, utilizando sensores óticos. Fazendo uma análise à figura, o primeiro aspecto que chama à atenção, é a grande quantidade de falsos-positivos (FP). Realmente, e como se vai observar mais a seguir, este modelo gera um elevado número de falsos-positivos, principalmente quando comparado com uma abordagem SAR. Ainda assim, são vários os navios corretamente detetados, dos quais alguns encontram-se a transmitir a sua posição, e outros, sem sinal AIS. Por fim, e como vai ser discutido mais adiante, existem vários locais com posições AIS, em que o modelo não detetou nenhum navio.




Figura 5.1. Compilação da classificação de navios, sensor ótico

Agora, podemos observar a figura da abordagem SAR. Verifica-se a presença de apenas verdadeiros-positivos e *dark vessels*, que significa que não existem falsas detecções. Verifica-se ainda uma grande quantidade significativa de *dark vessels*.




Figura 5.2. Compilação da classificação de navios, sensor SAR

A tabela abaixo resume os resultados verificados para cada estudo. Foi construída após a verificação visual dos resultados, em que se comparou as classificações do modelo, com as posições AIS e a interpretação visual dos dados. Teoricamente, poderá existir casos em que o

modelo não detetou nenhum navio, não existe dados AIS e mesmo assim existe um navio, no entanto não é possível fazer esta identificação uma vez que a área de estudo tem uma dimensão considerável e seria necessário analisar toda a área, manualmente. Por outro lado, é ir às várias posições AIS e verificar se existe algum navio, na tentativa de identificar falsos-negativos. O conjunto destas técnicas com a interpretação visual dos resultados, permite avaliar a previsão dos modelos.

Na tabela, podemos verificar uma coluna para o tipo do sensor, o dia, a percentagem da nebulosidade, o número de verdadeiros-positivos, de falsos-positivos, em que estes se dividem em *dark vessels* e falsas-deteções e por fim, o número de falsos-negativos.

Em seguida, foram calculados os valores da precisão, *recall* e F1-Score para cada um dos dias.

Tabela 5.1. Resultados obtidos. Fonte: Autor.

Sensor	Dia	% neb.	% area	VP	FP		FN	Prec.	<i>Recall</i>	F1-Score
					DV	FD				
Ótico	05	0.5%	100%	5	0	32	3	13.51%	62.50%	0.22
Ótico	10	5%	100%	3	3	29	0	17.14%	100.00%	0.29
Ótico	30	0%	100%	8	2	0	9	100.00%	52.63%	0.69
SAR	09	-	100%	6	6	0	0	100.00%	100.00%	1
SAR	10	-	60%	8	1	0	0	100.00%	100.00%	1
SAR	21	-	100%	12	0	0	0	100.00%	100.00%	1

5.2. DISCUSSÃO

Entramos agora no último subcapítulo, em que é feita a discussão dos resultados observados. Começando pela discussão das imagens criadas, existem vários aspetos que merecem ser mencionados, nomeadamente:

Verifica-se um elevado número de falsos-positivos ao utilizar sensores óticos. Isto deve-se principalmente a duas situações, uma delas devido à presença de nuvens, em que o modelo tem dificuldades de distinguir dos navios. A abordagem *threshold-based*, uma vez que vai detetar valores extremos, não é suficiente para distinguir a reflectância de uma nuvem, com a reflectância de um navio. A outra, tal como se pode verificar no subcapítulo do caso de estudo de um sensor ótico, é a presença das faixas de varrimento. Na zona onde termina uma faixa e inicia outra, são zonas em que existem valores conspícuos, o que aumenta o erro nessas zonas.

Observando as figuras dos resultados, verifica-se um grande número de falsos-positivos nessas zonas. Verifica-se agora que possivelmente, poder-se-ia ter aplicado algum tipo de filtro para suavizar estas faixas.

Relativamente às nuvens, foram criados polígonos para eliminar grandes porções de nuvens, principalmente nos dias com maior percentagem de nebulosidade. Apesar desta técnica reduzir o número de falsos-positivos, reduz também a área de estudo, criando zonas de “sombra”.

Relativamente aos sensores SAR, verifica-se que os navios foram facilmente identificados e de forma correta. Não se detetaram falsos-positivos nem navios por identificar. Ainda, uma vez que não existem nuvens, a cobertura de área é maior, permitindo a deteção de navios em todas as condições atmosféricas.

Através da análise estatística, podemos observar algumas conclusões:

A metodologia através de sensores óticos tem uma precisão média de 43.55% e um *recall* médio de 71.71%, resultando num F1-score médio de 0.40. Verifica-se então que o modelo apesar de permitir identificar navios, é longe de ótimo. Verifica-se principalmente uma grande deficiência na precisão, significando um elevado número de falsos-positivos. Através do teste de dia 30 verifica-se que para ter uma maior precisão, aumenta o número de falsos-navios, ou navios que não foram identificados, resultando assim uma diminuição do valor do *recall*.

Já para os sensores SAR, temos uma precisão média, *recall* e F1-score de 100%. Observa-se que os sensores SAR são claramente a melhor das duas abordagens.

Por fim, e relativamente aos *dark vessels*, podemos verificar que foram detetados 12 navios como prováveis *dark vessels*. Estes 12 navios representam 22.22% de todos os navios (54, detetados e falsos negativos), sendo uma percentagem significativa.

Termina-se este subcapítulo analisando a questão central e os objetivos de investigação que foram desenvolvidos no primeiro capítulo.

- QC – “Será um modelo baseado em deteção remota eficaz na deteção de *dark vessels*?”.
- OI1 – Desenvolver um processo que utiliza imagens de satélite (ótico), para identificar navios no mar;
- OI2 – Desenvolver um processo que utiliza imagens de satélite (SAR), para identificar navios no mar;
- OI3 – Avaliar a precisão dos processos em detetar navios;

- OI4 – Desenvolver um processo que consiga comprar posições AIS com posições dos navios;
- OI5 – Desenvolver um processo que permita detetar *dark vessels* numa dada área de estudo e período temporal.

Começando pelo OI1, foi desenvolvido um processo de deteção de navios através de imagens de satélite ótico, provenientes do Sentinel-2. No capítulo 4, desenvolveu-se uma prova de conceito verificando-se que em condições ideais, é possível a deteção de navios no mar. Para isto, utilizou-se bandas artificiais como o NDWI e uma metodologia *threshold-based*.

Da mesma forma, o OI2 foi conseguido através de uma prova de conceito com imagens de satélite SAR, proveniente do Sentinel-1. Utilizando um método de CFAR, foi possível obter a identificação de navios, independentemente das condições do mar.

O OI3 revelou-se uma importante etapa, pois permite avaliar cada um dos modelos desenvolvidos. Verifica-se que o OI1, apesar de ser bem conseguido, não é preciso em condições meteorológicas que não perfeitas. Uma abordagem que utiliza imagens de satélite ótico tem várias limitações, como foi logo identificado nas referências bibliográficas. Por outro lado, uma abordagem SAR teve um desempenho perfeito.

O OI4 foi realizado através de um modelo construído em *Model Builder*, que permite sobrepor as posições AIS, depois de pré-processadas em MATLAB, e identifica quando existe ou não sobreposição e atribui um código de cor para cada navio.

O OI5 foi conseguido no quinto capítulo, ao testar os modelos desenvolvidos ao longo de vários dias e permitiu avaliar o funcionamento dos modelos em diversas condições, condições estas que seriam semelhantes às encontradas caso o modelo fosse aplicado em situações reais de monitorização do espaço marítimo.

Todos estes objetivos de investigação, bem como a revisão da literatura permitem responder à questão central. Considera-se que um modelo baseado em SAR é adequado para detetar *dark vessels*, no entanto um modelo baseado em sensores óticos apresenta algumas limitações. Estes modelos baseados em deteção remota permitem a deteção de navios, que de outra forma seria impossível.

6. CONCLUSÕES E INVESTIGAÇÃO FUTURA

Este trabalho demonstra a aplicabilidade de utilizar técnicas de deteção remota, nomeadamente sensores óticos e SAR, na deteção de navios, em concreto, os que não transmitem a sua posição. Esta abordagem permite incrementar a segurança marítima e o controlo da pesca ilegal. Verifica-se ainda que é uma solução inovadora e ainda em desenvolvimento e tem como principal vantagem o facto de não estar dependente de os navios transmitirem a sua posição AIS.

Iniciando com uma análise bibliométrica, verificou-se inúmeros trabalhos na área da deteção de navios com técnicas de deteção remota, no entanto são ainda poucos os estudos diretamente relacionados com os *dark vessel*. Esta análise foi importante uma vez que permitiu verificar que este é um tema emergente.

Relativamente aos testes realizados, verifica-se que o teste ao longo de três dias foi importante, porque um estudo alargado no tempo permite verificar aspetos que não são possíveis de constatar apenas nos casos de estudo, em que as condições são perto de ideais. Nomeadamente, verifica-se que a utilização de sensores óticos na deteção de navios apesar de ser possível, é longe de ser fiável uma vez que é muito afetado pelas condições meteorológicas. A utilização de sensores óticos é sustentada num equilíbrio entre termos um modelo muito sensível, que deteta um maior número de navios, mas em contrapartida tem um elevado número de falsos-positivos, ou um modelo menos sensível e que apesar de não ter muitos falsos-positivos, deixa por identificar alguns navios.

Em contrapartida, verifica-se que uma abordagem SAR permite a deteção, independentemente das condições meteorológicas, mas também durante o arco noturno. Tal como se verificou durante a análise bibliométrica, os sensores SAR são a melhor abordagem, e são fundamentais na deteção de navios.

Importa, como nota de conclusão, referir que os resultados obtidos neste estudo estão sempre dependentes da base de dados AIS utilizada. Por forma a aumentar o número de dados AIS, compilou-se dados de três fontes diferentes. No entanto, alguns navios que foram classificados como possíveis *dark vessels*, podem estar a transmitir a sua posição, mas não constam nestas bases de dados, pelo que os resultados estão sempre relacionados à BD utilizada. Ainda, optou-se por utilizar uma terminologia de “possível *dark vessel*” uma vez que, e tal como se explicou na introdução, o próprio sistema AIS pode ter falhas de transmissão, ou

podem estar sobre uma zona de sombra e não quer necessariamente implicar que o navio é um navio infrator.

Este trabalho apresenta uma solução simples para a problemática da deteção de navios, que não depende de algoritmos complexos e é fácil de implementar e recriar. É fácil de avaliar os navios, depois de detetados, para confirmar se se trata de falsos-positivos, navios a transmitir ou de possíveis *dark vessels*.

Como principais dificuldades sentidas na realização do trabalho, importa referir alguma dificuldade na integração dos dados AIS, até se identificar um desfasamento entre os dados e verificar que existe uma diferença de cerca de 1h10m, possivelmente devido a diferenças entre fusos horários. A maior limitação desta abordagem é a periodicidade dos satélites revisitarem a mesma área de estudo ou a sua resolução temporal. Como verificamos ao longo do trabalho, para a área de estudo definida, num período de um mês é possível obter apenas 10 dias de observação válidos (SAR) e 11 dias para satélites óticos. Destes últimos, importa ainda acrescentar que são altamente afetados pelas condições meteorológicas, que dependendo da altura do ano podem inviabilizar a sua utilização.

Este trabalho levanta um conjunto de outras questões relacionadas com o mesmo tema, nomeadamente o porquê de existirem tantos possíveis *dark vessels*. É possível estarmos perante erros no AIS? Haverá alguma zona de sombra? Deixa-se estas questões como sugestões para trabalhos futuros, em que seria pertinente fazer um estudo com novas bases de dados AIS e possivelmente fazer uma análise estatística (espacial) aos resultados obtidos.

REFERÊNCIAS BIBLIOGRÁFICAS


- Androjna, A., Perkovič, M., Pavić, I., & Mišković, J. (2021). AIS Data Vulnerability Indicated by a Spoofing Case-Study. *Applied Sciences (Switzerland)*, 11(11). <https://doi.org/10.3390/app11115015>
- Alaska Satellite Facility. (2025). *About the Alaska Satellite Facility*. <https://asf.alaska.edu/about-asf/>
- Ashe, J. (2014). Improving the coordination of efforts against trafficking in persons. *President of the 68th Session of the United Nations General Assembly, July*, 1–4. <https://www.un.org/en/ga/president/68/pdf/statements/20140714-traffickinginpersons.pdf>
- Aune, B. R. (1990). Maritime drug trafficking: an underrated problem. *Bulletin on Narcotics*, 42(1), 63–72. https://www.unodc.org/unodc/en/data-and-analysis/bulletin/bulletin_1990-01-01_1_page008.html
- Bala, A., Swafiyudeen, B., & Gbenga Ajayi, O. (2015). Geospatial Information System for Crime Analysis and Crime Zone Identification-Case Study of Katsina, Nigeria. *Journal of Engineering Science and Technology*, 2(1, January). <https://www.researchgate.net/publication/272088001>
- Bellamy, C. (2020). What are maritime crime and maritime security? *International Journal of Maritime Crime & Security (IJMCS)*, 1(1). www.cberuk.com
- Bunwaree, P. (2023). THE ILLEGALITY OF FISHING VESSELS “GOING DARK” AND METHODS OF DETERRENCE. *International and Comparative Law Quarterly*, 72(1), 179–211. <https://doi.org/10.1017/S0020589322000525>
- Caetano, M. (2018). Teoria de Detecção Remota. In *NOVA Information Management School*. Universidade Nova de Lisboa.
- Calder, B. R., & Schwehr, K. (2009). Traffic Analysis for the Calibration of Risk Assessment Methods. *U.S. Hydrographic Conference*, 451. <https://scholars.unh.edu/ccom/451/>
- Centro de Engenharia e Tecnologia Naval e Oceânica. (2025). *Characterization of maritime traffic and safe routes for ships*. MoniRisk. https://monirisk.tecnico.ulisboa.pt/?page_id=773
- Chaltiel, P.-Y. (2021, February 2). *Acoustic Intelligence (ACINT)*. EMSOPEDIA. <https://www.emsopedia.org/entries/acoustic-intelligence-acint/>
- DGRM. (2018). *Zonas Marítimas sob Soberania e ou Jurisdição Portuguesa*. <https://www.dgrm.pt/pt/web/guest/am-ec-zonas-maritimas-sob-jurisdicao-ou-soberania-nacional>
- Donthu, N., Kumar, S., Mukherjee, D., Pandey, N., & Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research*, 133, 285–296. <https://doi.org/10.1016/j.jbusres.2021.04.070>
- EOS. (2021). Normalized Difference Water Index (NDWI). *EOS Data Analytics*. <https://eos.com/make-an-analysis/ndwi/#>
- ESA. (n.d.-a). *Object Detection*. Retrieved May 19, 2025, from <https://step.esa.int/main/wp-content/help/versions/9.0.0/snap-toolboxes/org.esa.s1tbx.s1tbx.op.feature.extraction.ui/operators/ObjectDetection.html>

- ESA. (n.d.-b). *SNAP*. Science Toolbox Exploitation Platform. Retrieved May 19, 2025, from <https://step.esa.int/main/toolboxes/snap/>
- ESA. (2022). *Level 2A Data Quality Report S2 MPC*. <https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2-L2A-Data-Quality-Report>
- ESA. (2025). *Sentinel-1*. Sentiwiki Copernicus. <https://sentiwiki.copernicus.eu/web/s1-mission>
- European Union. (2011). COMMISSION DIRECTIVE 2011/15/EU. *Official Journal of the European Union*, L 49/33. <https://eur-lex.europa.eu/eli/dir/2011/15/oj/eng>
- Gabler, R., & Koch, W. (2012). Detection and Tracking of Non-Cooperative Vessels. *NATO Symposium on Port and Regional Maritime Security 2012*. <https://doi.org/10.24406/publica-fhg-376665>
- Gupta, R., Rajitha, K., Basu, S., & Mittal, S. K. (2012). Application of GIS in Crime Analysis: A Gateway to Safe City. *14th Annual International Conference and Exhibition on Geospatial Information Technology and Applications- India Geospatial Forum*, 1–6. <http://indiageospatialforum.org/2012/proceedings/ppt/Prof%20Gupta,%20Development.pdf>
- INTERPOL. (n.d.). *Maritime crimes have a huge economic and human cost*. Retrieved October 2, 2023, from <https://www.interpol.int/en/Crimes/Maritime-crime/The-issues>
- Kanjir, U., Greidanus, H., & Oštir, K. (2018). Vessel detection and classification from spaceborne optical images: A literature survey. *Remote Sensing of Environment*, 207, 1–26. <https://doi.org/10.1016/j.rse.2017.12.033>
- Marchione, E., & Johnson, S. D. (2013). Spatial, Temporal and Spatio-Temporal Patterns of Maritime Piracy. *Journal of Research in Crime and Delinquency*, 50(4), 504–524. <https://doi.org/10.1177/0022427812469113>
- Menezes, E. (2023). Introduction to Synthetic Aperture Radar. *ArcGIS Blog*. <https://www.esri.com/arcgis-blog/products/arcgis-pro/imagery/introduction-to-synthetic-aperture-radar>
- Mishra, S., Shalu, P., Soman, D., & Singh, I. (2023). Advanced Ship Detection System using Yolo v7. *2023 IEEE 7th Conference on Information and Communication Technology, CICT 2023*, 1–6. <https://doi.org/10.1109/CICT59886.2023.10455662>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 66, Issue 3, pp. 247–259). <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- National Oceanography Centre. (2025). *Research Ships*. <https://noc.ac.uk/facilities/ships>
- NATO. (2021). AIS (Automatic Identification System) overview. *NATO*. <https://shipping.nato.int/nsc/operations/news/2021/ais-automatic-identification-system-overview>
- NATO. (2022). *NATO 22 STRATEGIC CONCEPT*. <https://www.nato.int/strategic-concept/>
- Nguyen, T. (2023). The Challenges of Dark Ships to the Safety and Security of Commercial Shipping and the Way Forward. *Asia-Pacific Journal of Ocean Law and Policy*, 8(2), 310–328. <https://doi.org/10.1163/24519391-08020007>
- National University of Defense Technology. (n.d.). *About - National University of Defense Technology*. Retrieved May 19, 2025, from <https://english.nudt.edu.cn/>

- Nunes, A. C. M. (2022). *Workflow to detect ship encounters at sea with GIS support* [Dissertation in Degree of Master in Geographical Information Systems and Science, Universidade Nova de Lisboa]. <https://run.unl.pt/handle/10362/148429>
- O'Donohue, D. (2023). Exploring the World of Optical Satellites. *Mapscaping*. <https://mapscaping.com/optical-satellites/>
- OECD. (2020). *Sustainable Ocean for All: Harnessing the Benefits of Sustainable Ocean Economies for Developing Countries* (The Development Dimension, Ed.). OECD Publishing. <https://doi.org/10.1787/bede6513-en>
- Oumimoun, B., Nahiri, L., Idmouida, H., Addaim, A., Guennoun, Z., & Minaoui, K. (2022). Software Defined AIS Receiver Implementation Based on RTL-SDR and GNU Radio. *APWiMob 2022 - Proceedings: 2022 IEEE Asia Pacific Conference on Wireless and Mobile*. <https://doi.org/10.1109/APWiMob56856.2022.10014409>
- Öztürk, O., Kocaman, R., & Kanbach, D. K. (2024). How to design bibliometric research: an overview and a framework proposal. *Review of Managerial Science*, 18, 3333–3361. <https://doi.org/10.1007/s11846-024-00738-0>
- Paolo, F., Kroodsmas, D., Raynor, J., Hochberg, T., Davis, P., Cleary, J., Marsaglia, L., Orofino, S., Thomas, C., & Halpin, P. (2024). Satellite mapping reveals extensive industrial activity at sea. *Nature*, 625(7993), 85–91. <https://doi.org/10.1038/s41586-023-06825-8>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Article in Journal of Machine Learning Technologies*, 2(1), 37–63. <https://doi.org/10.9735/2229-3981>
- Revised Guidelines for the Onboard Operational Use of Shipborne Automatic Identification Systems (AIS), Pub. L. No. Resolution A.1106(29) (2015). [https://wwwcdn.imo.org/localresources/en/OurWork/Safety/Documents/AIS/Resolution%20A.1106\(29\).pdf](https://wwwcdn.imo.org/localresources/en/OurWork/Safety/Documents/AIS/Resolution%20A.1106(29).pdf)
- Sasaki, Y. (2007). *The truth of the F-measure*. <https://www.researchgate.net/publication/268185911>
- Schwegmann, C. P., Kleynhans, W., & Salmon, B. P. (2014). Simulated annealing CFAR threshold selection for South African ship detection in ASAR imagery. *Proceedings of the 2014 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 561–564. <https://doi.org/10.1109/IGARSS.2014.6946484>
- Silveira, P. A. M., Teixeira, A. P., & Soares, C. G. (2013). Use of AIS data to characterise marine traffic patterns and ship collision risk off the coast of Portugal. *Journal of Navigation*, 66(6), 879–898. <https://doi.org/10.1017/S0373463313000519>
- SPIRE. (n.d.). *AIS Fundamentals*. Retrieved June 14, 2025, from <https://documentation.spire.com/ais-fundamentals/ais-data-sources/dynamic-ais/>
- Tele, T., Lim, F.-L., & Kang, Y. (2006). Situation Awareness System in a Maritime Port. *OCEANS 2006 - Asia Pacific*, 1–5. <https://doi.org/10.1109/OCEANSAP.2006.4393913>
- Thana, E. (2013). Maritime transport and tourism sustainable development. *1st Annual International Interdisciplinary Conference*, 933–940. <https://eujournal.org/index.php/esj/article/view/1416/1425>
- Tripicchio, P. (2024). Remote Sensing of Target Object Detection and Identification II. In *Remote Sensing* (Vol. 16, Issue 16). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/rs16163106>

- UNODC. (n.d.). *Drugs Monitoring Platform*. Retrieved November 4, 2023, from <https://dmp.unodc.org/>
- UNODC. (2019). *Maritime Crime: A Manual for Crime Justice Practitioners*. United Nations. <https://doi.org/10.5949/upo9781846317064.012>
- Volpe National Transportation Systems Center. (2008, July 10). *M.S.S.I.S. Maritime Safety & Security Information System*. U.S. Department of Transportation. <https://mssis.volpe.dot.gov/Main/index.html>
- Weather Spark. (n.d.). *Clima e condições meteorológicas médias em Calendário no ano todo - Portugal*. Retrieved May 19, 2025, from <https://pt.weatherspark.com/y/32466/Clima-caracter%C3%ADstico-em-Calend%C3%A1rio-Portugal-durante-o-ano>
- Wedler, E., & Worsfold, R. (1978). Satellite Ocean-Related Imagery Applications Program. *Proceedings of the OCEANS '78 Conference*, 427–432. <https://doi.org/10.1109/OCEANS.1978.1151174>

APÊNDICE A



C&SIG
