



CV-MDA: UM FRAMEWORK PARA APOIAR NA AMPLIAÇÃO DA
CONSCIENTIZAÇÃO MARÍTIMA BRASILEIRA

Matheus Emerick de Magalhães

Tese de Defesa de Doutorado apresentada ao Programa de Pós-graduação em Engenharia de Sistemas e Computação, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia de Sistemas e Computação.

Orientadores: Jano Moreira de Souza
Carlos Eduardo Barbosa

Rio de Janeiro
Dezembro de 2023

CV-MDA: UM FRAMEWORK PARA APOIAR NA AMPLIAÇÃO DA
CONSCIENTIZAÇÃO MARÍTIMA BRASILEIRA

Matheus Emerick de Magalhães

EXAME DE DEFESA SUBMETIDO AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM ENGENHARIA DE SISTEMAS E COMPUTAÇÃO.

Examinada por:

Prof. Jano Moreira de Souza, Ph.D.

Prof. Carlos Eduardo Barbosa, D.Sc.

Prof. Geraldo Bonorino Xexéo, D.Sc.

Profa.^a Flávia Maria Santoro, D.Sc.

Prof. Daniel Serrão Schneider, D.Sc.

Prof.^a Kelli de Faria Cordeiro, D.Sc.

Prof.^a Viviane Cunha Farias da Costa, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

DEZEMBRO DE 2023

Magalhães, Matheus Emerick de

CV-MDA: um framework para apoiar na ampliação da conscientização marítima brasileira / Matheus Emerick de Magalhães. – Rio de Janeiro: UFRJ/COPPE, 2023.

X, 88 p.: il.; 29,7 cm.

Orientadores: Jano Moreira de Souza

Carlos Eduardo Barbosa

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia de Sistemas e Computação, 2023.

Referências Bibliográficas: p. 83-88.

1. Coleção de imagens anotadas automaticamente. 2. Realidade aumentada de embarcações. 3. Visão Computacional. I. Souza, Jano Moreira *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Sistemas e Computação. III. Título.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, o único, poderoso e digno, por ter me concedido sabedoria, força de vontade e todas as condições necessárias para a conclusão deste projeto.

À minha mãe, Marilsa, meu mais forte alicerce, por seu apoio constante em todas as decisões e por estar ao meu lado nos momentos difíceis.

Aos amigos e colegas do PESC, pela convivência enriquecedora e pela amizade que fortaleceu minha caminhada.

A todos aqueles que participaram da elaboração e dos testes do CV-MDA, agradeço o tempo, dedicação e seriedade dedicados a este projeto. Em especial, meu profundo agradecimento ao meu amigo e coorientador, Carlos Eduardo Barbosa, ao professor Daniel Serrão Schneider, à comandante Kelli e a todos os companheiros de trabalho da Marinha do Brasil pelo apoio inestimável na realização deste trabalho.

Ao meu orientador, Jano Moreira de Souza, expresso minha gratidão pela disponibilidade, confiança, compreensão e paciência demonstrados ao longo dos anos em que trabalhamos juntos.

Aos demais professores, colegas e funcionários do PESC, assim como a todos que de alguma forma contribuíram para a elaboração deste trabalho, meu sincero reconhecimento.

A todos vocês, o meu muito obrigado por fazerem parte desta jornada e por tornarem este projeto possível

Resumo do Exame de Defesa apresentado à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

CV-MDA: UM FRAMEWORK PARA APOIAR NA AMPLIAÇÃO DA CONSCIENTIZAÇÃO MARÍTIMA BRASILEIRA

Matheus Emerick de Magalhães

Dezembro/2023

Orientadores: Jano Moreira de Souza

Carlos Eduardo Barbosa

Programa: Engenharia de Sistemas e Computação

O aumento da quantidade e tipos de embarcações que trafegam para costa brasileira tem proporcionado diversos desafios relacionados ao monitoramento das embarcações, realizado pela autoridade marítima. Os principais desafios enfrentados no controle do tráfego marítimo estão principalmente relacionados à identificação e a detecção das embarcações. No entanto, a falta de soluções adequadas à realidade brasileira para a detecção visual de embarcações reduz o poder informacional da autoridade marítima.

Essa pesquisa destaca a necessidade de soluções de detecção visual adaptadas ao contexto brasileiro, identificando a importância de coleções de imagens anotadas com informações das embarcações para subsidiar o treinamento de algoritmos relacionado ao aprendizado de máquina, para apoiar na identificação e detecção automática de embarcações.

A solução proposta nesse trabalho automatiza a criação dessas e coleções de imagens contextuais e finamente anotadas de embarcações, ampliando a capacidade da autoridade marítima de identificar e monitorar embarcações, especialmente nas áreas portuárias, resultando em uma ampliação da conscientização do domínio marítimo brasileiro (Maritime Domain Awareness – MDA). Este trabalho propõe um framework para apoiar o processo de ampliação da MDA capaz de automatizar e semiautomatizar o processo de anotação das imagens de embarcações fazendo uso de Visão Computacional e Realidade Aumentada, denominado CV-MDA. A solução CV-MDA foi implementado e avaliado, sob à luz do framework científico de Design Science.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

CV-MDA: A FRAMEWORK TO SUPPORT THE EXPANSION OF BRAZILIAN
MARITIME AWARENESS.

Matheus Emerick de Magalhães

December/2023

Advisors: Jano Moreira de Souza

Carlos Eduardo Barbosa

Department: Systems Engineering and Computer Science

The increase in the quantity and types of vessels traveling to the Brazilian coast has posed several challenges related to vessel monitoring, conducted by maritime authorities. The main challenges faced in maritime traffic control are primarily related to the identification and detection of vessels. However, the lack of suitable solutions for visual vessel detection tailored to the Brazilian context reduces the informational power of maritime authorities.

This research highlights the need for visual detection solutions adapted to the Brazilian context, emphasizing the importance of annotated image collections with vessel information to support machine learning algorithm training for automatic vessel identification and detection. The solution proposed in this work automates the creation of these finely annotated contextual image collections of vessels, enhancing the maritime authority's capability to identify and monitor vessels, especially in port areas, resulting in an expansion of Brazilian Maritime Domain Awareness (MDA). This work proposes a framework to support the MDA expansion process capable of automating and semi-automating the vessel image annotation process using Computer Vision and Augmented Reality, referred to as CV-MDA. The CV-MDA solution has been implemented and evaluated within the scientific framework of Design Science.

SUMÁRIO

1.	INTRODUÇÃO.....	1
1.1.	Problema.....	2
1.2.	Objetivos do Trabalho	3
1.3.	Questões de Pesquisa.....	5
1.4.	Metodologia.....	5
1.5.	Organização da Tese	6
2.	REVISÃO DA LITERATURA.....	7
2.1.	A Conscientização do Domínio Marítimo.....	7
2.2.	Principais Tecnologias Utilizadas na Ampliação da MDA.....	10
2.2.1.	<i>Realidade Aumentada</i>	10
2.2.2.	<i>Visão Computacional</i>	13
2.2.3.	<i>Redes Neurais Artificiais Profundas</i>	14
2.2.4.	<i>Anotação dos Objetos</i>	16
3.	O MODELO CV-MDA.....	22
3.1.	Camada de Dados	22
3.2.	Camada de Visão/Projeção.....	24
3.3.	Camada de Anotação Automática	25
3.4.	Camada de Anotação Semiautomática	26
4.	O MÉTODO CV-MDA.....	27
4.1.	Camada de Dados	27
4.1.1.	<i>Obtenção de Dados</i>	27
4.1.2.	<i>Integração de Dados</i>	30
4.1.3.	<i>Geocodificação de Dados</i>	31
4.2.	Camada de Visão/Projeção.....	33
4.2.1.	<i>Realidade Aumentada</i>	33
4.2.2.	<i>Visão Computacional</i>	34
4.3.	Camada de Anotação Automática	38
4.3.1.	<i>Interseção e Sobreposição de Camadas</i>	38
4.3.2.	<i>Estimativa Adaptativa de Distância (Geohash)</i>	42
4.4.	Camada de Anotação Semiautomática	51
5.	O ARCABOUÇO TECNOLÓGICO CV-MDA	53
5.1.	Instâncias dos Cenários Ilustrativos	53
5.1.1.	<i>Instância do Cenário Ilustrativo 1: Identificação de Embarcação Suspeita</i>	53
5.1.2.	<i>Instância do Cenário Ilustrativo 2: Identificação de Discrepância</i>	54
5.1.3.	<i>Instância do Cenário Ilustrativo 3: Identificação do Tipo de Embarcação</i>	54
5.2.	Utilização do Arcabouço	55
5.2.1.	<i>Instância do Cenário 1 utilizando o CV-MDA</i>	55
5.2.2.	<i>Instância do Cenário 2 utilizando o CV-MDA</i>	56
5.2.3.	<i>Instância do Cenário 3 utilizando o CV-MDA</i>	57
5.2.4.	<i>Discussão dos Cenários Hipotéticos</i>	64
6.	AVALIAÇÃO CV-MDA.....	66
6.1.	A Metodologia da Pesquisa.....	66
6.2.	Avaliação dos Conceitos	69
6.3.	Avaliação do Modelo e Método	69
6.3.1.	<i>Cenário Ilustrativo 1</i>	70
6.3.2.	<i>Cenário Ilustrativo 2</i>	71

6.3.3. <i>Cenário Ilustrativo 3</i>	71
6.4. Avaliação da Implementação	72
6.4.1. <i>Estudo de Caso 1: Cenário Ilustrativo 1</i>	72
6.4.2. <i>Estudo de Caso 2: Cenário Ilustrativo 2</i>	73
6.4.3. <i>Estudo de Caso 3: Cenário Ilustrativo 3</i>	74
7. CONSIDERAÇÕES FINAIS	76
7.1. Revisitando as Questões de Pesquisa	76
7.2. Contribuições.....	78
7.3. Limitações	80
7.4. Trabalhos Futuros.....	81
REFERÊNCIAS BIBLIOGRÁFICAS	83

ÍNDICE DE FIGURAS

Figura 1 - Exemplo de Realidade Aumentada (Fonte: Marine Traffic).	11
Figura 2 - Etapas/Camadas do Método CV-MDA.	22
Figura 3 - Pré-Processamento no Método CV-MDA.	23
Figura 4 - Visão/Projeção dos Dados no Método CV-MDA.	24
Figura 5 - Anotação Automática dos Dados no Método CV-MDA.	25
Figura 6 - Anotação Semiautomática no Método CV-MDA.	26
Figura 7 - Registros de Navegação de Diversas Fontes.	30
Figura 8 - Exemplo e Código de Geocodificação.	32
Figura 9 - Geocodificação dos Registros Consolidados de Navegação.	33
Figura 10 - Visualização de Diferentes Perspectivas em Realidade Aumentada.	34
Figura 11 - Fluxo de Atividades da Etapa de Visão Computacional.	35
Figura 12 - Dashboard de Ajuste do Modelo.	37
Figura 13 - Código de Geração e Aplicação do Raio entre as Camadas.	40
Figura 14 - Exemplo com Três Raios de Interseção.	40
Figura 15 - Detecção da Embarcação Indicada pela Caixa Delimitadora.	41
Figura 16 - Verificação de Interseção das Camadas.	41
Figura 17 - Verificação de Interseção das entre Duas Embarcações.	42
Figura 18 - Subdivisão da área em Geohash, adaptado de GUO et al. (2019).	44
Figura 19 - Geocodificação do Mundo Virtual.	45
Figura 20 - Linha Histórica até a Abordagem Adaptativa.	45
Figura 21 - Geocodificação do Raio em Três Granularidades.	46
Figura 22 - Área de Cobertura em Detrimento da Granularidade.	46
Figura 23 - Geohash do Raio Granularidade 8.	47
Figura 24 - Geohash do Raio Granularidade 7.	47
Figura 25 - Geohash do Raio Granularidade 6.	47
Figura 26 - Distância Angular entre as Embarcações e o Raio.	49
Figura 27 - Visualização da Distância Angular entre as Embarcações “A” e “B”.	50
Figura 28 - Visão Computacional x Realidade Aumentada e Estimativa de Distância.	50
Figura 29 - Fluxo de Anotação Semiautomática.	52
Figura 30 - Ausência de Registro de Navegação da Embarcação.	56
Figura 31 - Ferramenta de Crowdsourcing do Framework CV-MDA.	56
Figura 32 - Identificação de Discrepância na Quantidade de Embarcações.	57
Figura 33 - Embarcações Pré-identificadas com Confiança Mínima de 0,3 e 0,5.	58
Figura 34 - Metadados da Extração da Imagem.	59
Figura 35 - Distribuição das Embarcações (instâncias) Anotadas.	59
Figura 36 - Precision e Recall 10 Épocas.	60
Figura 37 - Matriz de Confusão 10 Épocas.	61
Figura 38 - Precision e Recall 20 Épocas.	61
Figura 39 - Matriz de Confusão 20 Épocas.	62
Figura 40 - Precision e Recall 50 Épocas.	62
Figura 41 - Matriz de Confusão 50 Épocas.	63
Figura 42 - Tipo de Embarcação Automaticamente Identificadas.	64
Figura 43 - Identificação Contextual e Fina x Identificação Genérica.	65

ÍNDICE DE TABELAS

Tabela 1 - Trabalhos Relacionados a Ampliação da MDA.....	9
Tabela 2 - Coleções de Imagens Especialmente Construídos na Ampliação da MDA.....	19
Tabela 3 - Registros de Navegação	27
Tabela 4 - Fontes de Registros de Navegação no Domínio Marítimo Brasileiro.....	29
Tabela 5 - Delimitação Espacial do <i>Geohash</i>	44
Tabela 6 - Experimento Granularidade do Raio.....	47
Tabela 7 - Utilização do CV-MDA em Cenários Hipotéticos.....	55
Tabela 8 - Embarcações Pré-identificadas x Valor de Confiança Mínimo	58
Tabela 9 - Metodologia de Avaliação da Pesquisa dos CV-MDA.....	67
Tabela 10 - Metodologia de Avaliação do CV-MDA	68
Tabela 11 - Principais Publicações.....	79

1. INTRODUÇÃO

A Conscientização do Domínio Marítimo (Maritime Domain Awareness – MDA) é um conceito utilizado para descrever a compreensão informacional dos elementos presentes em uma determinada região marítima, como embarcações e outros ativos. O conceito de MDA foi reformulado após os ataques terroristas de 11 de setembro e desde então tem sido ampliado para incluir a monitoração e controle de ações relacionadas ao tráfego marítimo, especialmente no que diz respeito à segurança marítima e às atividades econômicas como extração de petróleo, pesca e transporte de carga (NATIONAL COMMISSION ON TERRORIST ATTACKS, 2011).

Para apoiar na ampliação da MDA e na condução de atividades relacionadas à segurança marítima, é fundamental que as informações dos elementos sejam obtidas de forma atualizada e precisa, e que sejam disponibilizadas de maneira clara e eficiente aos elementos que compõem a autoridade marítima. A detecção e identificação dos variados tipos de embarcações que transitam em áreas marítimas é crucial para garantir a segurança, sendo constantemente objeto de medidas governamentais, regulação e fiscalização rigorosa por parte das autoridades marítimas. O controle do tráfego de navios é uma preocupação fundamental em áreas marítimas de grande movimentação, principalmente áreas portuárias, visando garantir a segurança e maximizar a eficiência das operações realizadas pela autoridade marítima, nestes domínios os operadores do tráfego marítimo dedicam especial às embarcações presentes (KIM; LEE, 2018).

A ampliação da MDA é necessária para garantir a segurança marítima, enfrentar desafios relacionados à expansão do conhecimento e inteligência, e combater diversas ameaças, como o tráfico de drogas, pesca ilegal, pirataria, derramamentos de petróleo, imigração ilegal e outros (MAGALHÃES et al., 2023). Para superar os desafios envolvidos na extração de conhecimento a partir dos dados, é essencial o uso de múltiplas fontes de informação para obter *insights* mais precisos e completos. Diversos autores têm descrito, em seus trabalhos, soluções de apoio na ampliação da MDA em seus respectivos países em virtude das particularidades encontradas. Nesse contexto, merecem destaque os estudos realizados na Grécia (GIANNAKOPOULOS et al., 2014), no Canadá (BATTISTELLO et al., 2016) e nas Filipinas (VICENTE et al., 2020).

O Brasil também busca iniciativas estratégicas para a ampliação da MDA (BREITINGER; CLUA; FERNANDES, 2021). Diante do aumento da quantidade de embarcações na área portuária brasileira e das complexidades envolvidas na gestão do tráfego

marítimo, a autoridade marítima do país tem procurado adotar soluções que melhorem a eficiência e eficácia das atividades relacionadas à segurança marítima.

Em 2021, os Estados Unidos e o Brasil firmaram um acordo de cooperação com o objetivo de melhor abordar ameaças regionais e globais, principalmente no domínio marítimo (UNITED STATES DEPARTMENT OF STATE, 2022). Essa iniciativa busca fortalecer a segurança marítima mediante ampliação da MDA, além de promover a colaboração entre as autoridades marítimas dos dois países. Contudo, diversos desafios são encontrados neste propósito. Dentre os diversos desafios para a condução de acordos de cooperação para apoiar no monitoramento do domínio marítimo estão à escassez de dados contextuais e a limitada cobertura de informações no Brasil.

1.1. Problema

Não existe uma solução universal capaz de resolver todas as demandas de monitoramento do tráfego marítimo (SIMONSEN et al., 2020). As particularidades do setor marítimo brasileiro, como a extensão territorial e a heterogeneidade de embarcações presentes nas diferentes regiões ao longo da costa e portos, tornam essencial a formação e atualização constante de uma coleção de imagens anotadas não sintéticas capazes de apoiar a autoridade marítima na atividade de detecção de embarcações.

Os principais problemas abordados por este trabalho, relacionados à ampliação da MDA, estão diretamente ligados à ausência de recursos, mais especificamente, a falta de imagens anotadas das embarcações no contexto marítimo brasileiro.

A carência de coleções específicas de imagens com anotações detalhadas compromete a capacidade de desenvolver e aprimorar modelos de aprendizado de máquina para a identificação e detecção de embarcações, limitando as possibilidades de ampliar da conscientização do domínio marítimo brasileiro. Esse desafio implica dificuldades na obtenção de dados contextuais representativos da realidade das embarcações, principalmente presentes na área portuária e costeiras do Brasil. A ausência desses recursos pode impactar diretamente na realização das atividades de monitoramento e controle do tráfego marítimo, tornando essencial a busca por soluções efetivas e não sintéticas para a obtenção de imagens anotadas e contextualizadas das embarcações existentes neste domínio.

Devido à ausência de coleções de imagens contextuais e finamente anotadas e aos desafios encontrados pela autoridade marítima brasileira em obter e manipular imagens de satélite em tempo real, esforços têm sido direcionados a soluções de menor investimento

financeiro e operacional como a utilização de imagens de câmeras espalhadas principalmente pela região portuária. No entanto, o uso dessas imagens de câmeras para apoiar atividades que contribuem para a ampliação da MDA em domínios específicos continua sendo um desafio em aberto, devido a fatores como a falta de dados que reflitam a heterogeneidade do ambiente marítimo (KAUR et al., 2022).

Um dos maiores desafios encontrados na ampliação do domínio marítimo, por meio da identificação e detecção de embarcações, está particularmente relacionado com a disponibilidade da coleção de imagens anotadas existentes, pois em grande maioria não estão adequados a cenários práticos específicos (HAMMEDI et al., 2019).

As coleções de imagem de domínio públicas têm contribuído muito para o desenvolvimento soluções de monitoramento de embarcações relacionadas a detecção visual de embarcações. Essas coleções de imagens são genéricas e incluem muitas categorias de diferentes objetos. Contudo, existe pouca quantidade de coleções de imagens para soluções mais contextuais e finas, e obter uma coleção de imagens anotadas é considerado uma tarefa desafiadora (KIM et al., 2022).

Em geral, a autoridade marítima brasileira realiza a formação da coleção de imagens de forma predominantemente manual ou com pouco grau de automação. Isso envolve a extração de imagens e a anotação manual dos tipos de embarcações presentes em imagens reais e sintéticas. No entanto, a quantidade de imagens anotadas e a representatividade das classes obtidas são limitadas devido ao esforço necessário na criação dessas coleções.

Essa abordagem manual ou pouco automatizada acaba por restringir a capacidade de realizar atividades relacionadas à detecção e identificação automática de embarcações. A escassez de dados anotados e a falta de representatividade podem dificultar a aplicação de modelos de aprendizado de máquina, necessário para a identificação e a detecção de embarcações no território brasileiro.

1.2. Objetivos do Trabalho

Com base na análise da literatura e nas informações obtidas junto à Marinha do Brasil, constata-se que o tema abordado por este trabalho ainda carece de uma abordagem adequada tanto em termos teóricos quanto empíricos. Essa lacuna de conhecimento deixa espaço para importantes questões que necessitam ser exploradas e pesquisadas de maneira mais profunda e especializada ao contexto brasileiro. As informações disponíveis sugerem que há ainda muito a ser descoberto e compreendido no contexto da ampliação da consciência situacional marítima,

especialmente no que diz respeito à formação de uma coleção de imagens contextual e finamente anotadas para apoiar atividades de monitoramento e controle do tráfego marítimo.

A ausência de uma abordagem específica e detalhada pode impactar a eficiência e a eficácia das atividades relacionadas à segurança marítima e à gestão do tráfego, enfatizando a importância de estudos mais aprofundados nessa área. Portanto, existe uma necessidade clara de pesquisas adicionais para preencher essas lacunas e fornecer informações valiosas para a autoridade marítima brasileira, a fim de aprimorar suas estratégias e tomar decisões mais informadas para enfrentar os diversos desafios encontrados no domínio marítimo. O presente trabalho pode servir como um ponto de partida e incentivo para investigações futuras que contribuam para o desenvolvimento de soluções efetivas e abrangentes para a ampliação da MDA no Brasil.

A adoção de abordagens mais automatizadas, como o desenvolvimento de algoritmos de anotação ou o uso de técnicas de aprendizado de máquina para auxiliar na identificação de embarcações, pode contribuir significativamente para ampliar a coleção de dados e melhorar a eficácia das atividades de monitoramento e controle do tráfego marítimo no país.

Nesse contexto, torna-se essencial buscar alternativas e soluções para incrementar a coleção de imagens não sintéticas de embarcações no contexto marítimo brasileiro. Para superar o problema de conjunto de dados pequeno ou inexistente para um domínio específico, um modelo de aprendizado profundo (*Deep Neural Learning* – DNN) pré-treinado pelo conjunto de dados de imagem pública é geralmente adotado para aprendizado por transferência e refinado com uma estratégia de ajuste fino (KIM et al., 2022).

Este trabalho consiste no desenvolvimento de uma metodologia para a criação de um conjunto de dados que contenha imagens reais (não sintéticas) e metadados de anotação provenientes de diversos sensores de navegação das embarcações que navegam, principalmente, na região portuária e costeira do Brasil. Essa metodologia tem como objetivo apoiar a ampliação da MDA por meio da identificação e detecção de embarcações de maneira contextual e finamente anotada. Foi desenvolvido um artefato tecnológico para comprovar a utilidade e relevância da solução apresentada em cenários ilustrativos cotidianos encontrados pela autoridade marítima brasileira.

Utilizamos diversas técnicas baseadas em visão computacional e realidade aumentada, combinadas com algoritmo de aprendizado profundo para lidar com os desafios encontrados na obtenção das imagens das embarcações no cenário real. O uso de soluções utilizando DNN

representa um avanço significativo na área de visão computacional, revolucionando o estado da arte dos trabalhos apresentados na literatura, com foco na ampliação da MDA.

1.3. Questões de Pesquisa

A questão principal de pesquisa consiste em: Como a criação automatizada de coleções de imagens anotadas de maneira automatizada pode contribuir na ampliação da MDA? As questões de pesquisa complementares e descritivas da questão principal são:

QP1: Como a Conscientização do Domínio Marítimo está fundamentado em suas bases teóricas, quais são as principais tecnologias e soluções utilizadas?

QP2: Como a tecnologia pode ser projetada para apoiar em diversos cenários que necessitam da ampliação da MDA?

QP3: Como a interligação de diversas soluções e tecnologias pode ser utilizada para a formação de coleções de dados anotados de maneira automatizada?

QP4: Como a formação de coleções de imagens de maneira contínua e automatizada pode contribuir na ampliação da MDA?

QP5: Como a criação de uma coleção de imagem contextual e fino pode contribuir na ampliação da MDA?

1.4. Metodologia

No âmbito deste trabalho, é empregado o framework de Design Science proposto por MARCH e SMITH (1995) para a construção e avaliação de conceitos, modelos, métodos e instanciações. O processo de avaliação dos artefatos desenvolvidos deve ser apropriado para medir a fidelidade deles com os fenômenos do mundo real e sua completude.

De acordo com March e Smith, o *Design Science* é mais apropriada para representar o conceito de “computação aplicada”, enquanto as ciências naturais são mais adequadas para abordar os assuntos computacionais. O *Design Science* é especialmente relevante para a computação aplicada, pois essa área de estudo se concentra em fenômenos artificiais que só existem em função das criações humanas, como as organizações. Por outro lado, as ciências naturais têm como objetivo explicar como as coisas são e por que ocorrem, enquanto o *Design Science* concentra-se na construção de artefatos com o propósito de atingir objetivos específicos.

O *Design Science* é empregado para a criação de artefatos tecnológicos, os quais podem ser categorizados em quatro tipos distintos: conceitos, modelos, métodos e o artefato

tecnológico. Os conceitos fornecem a base linguística para caracterizar o fenômeno estudado. Um modelo é a combinação dos conceitos organizados de forma a descrever artefatos ou atividades. Métodos são abordagens utilizadas para organizar as atividades visando alcançar um objetivo específico. O artefato tecnológico consiste na materialização dos artefatos anteriores em produtos específicos, que sejam fisicamente acessíveis e potencialmente utilizáveis na prática, ou seja, uma instância concreta.

O *Design Science* envolve duas atividades fundamentais: construção e avaliação. A construção refere-se ao processo de criar um artefato com um propósito específico, enquanto a avaliação envolve a verificação do desempenho do artefato criado (MARCH; SMITH, 1995). A avaliação do artefato é conduzida por meio da análise de sua completude, simplicidade, elegância, inteligibilidade e facilidade de uso. A relevância da contribuição de uma pesquisa em *Design Science* está relacionada à originalidade do artefato proposto e à eficácia com que ele atinge seus objetivos. O avanço no *Design Science* ocorre quando uma tecnologia é substituída por outra mais eficiente, ou seja, quando é encontrada uma solução que supera as abordagens anteriores em termos de eficácia e desempenho.

1.5. Organização da Tese

Este trabalho está organizado em 7 capítulos, organizados da seguinte forma: no capítulo, 2 estão apresentados os principais conceitos que compõem a revisão da literatura utilizada durante esse trabalho e os trabalhos relacionados. Essa revisão fornece a base necessária para que o leitor tenha uma visão geral sobre as técnicas utilizadas e o contexto dos problemas propostos. O capítulo 3 aborda o *framework* de pesquisa utilizada para o desenvolvimento deste trabalho, denominada de *Design Science Research* de MARCH e SMITH (1995), organizada em quatro grupos de atividades: conceitos, modelo, método e o arcabouço tecnológico. Os conceitos utilizados para a formação do *framework* são apresentados no capítulo 2. No capítulo 4, é apresentada uma representação abstrata do modelo proposto neste trabalho, capturando os elementos e comportamentos relevantes de forma a facilitar a compreensão do cenário abordado. No Capítulo 5, é detalhado o método utilizado. No Capítulo 6, é apresentado o arcabouço tecnológico utilizado no desenvolvimento do trabalho. São descritas as soluções computacionais utilizadas para implementar e suportar o modelo e o método proposto. No capítulo 7, são apresentadas as conclusões do trabalho.

2. REVISÃO DA LITERATURA

QPI: Como a Conscientização do Domínio Marítimo está fundamentado em suas bases teóricas, quais são as principais tecnologias e soluções utilizadas?

Neste capítulo, serão abordados os principais conceitos e trabalhos relacionados encontrados na literatura, focados na conscientização do domínio marítimo e nas tecnologias e soluções mais relevantes para o contexto deste trabalho. Serão apresentadas as contribuições de outros estudos que abordam temas similares bem como as abordagens e metodologias utilizadas para enfrentar os desafios na ampliação da MDA. O objetivo é fornecer uma visão abrangente do estado atual da pesquisa nessa área, oferecendo uma base sólida para o desenvolvimento e aprimoramento da solução proposta neste trabalho.

2.1. A Conscientização do Domínio Marítimo (MDA)

O domínio marítimo abrange principalmente as atividades civis e militares realizadas em áreas territoriais específicas de um país ou grupo de nações. Essas áreas territoriais englobam as águas interiores, o mar territorial, a zona contígua, a Zona Econômica Exclusiva (ZEE) e a plataforma continental. Em linhas gerais, o domínio marítimo refere-se à jurisdição e controle exercidos sobre essas áreas, que desempenham um papel crucial em termos de exploração de recursos, segurança, comércio e outras atividades relacionadas a soberania dos mares e oceanos.

No âmbito do domínio marítimo, são requeridas diversas atividades voltadas para o monitoramento de embarcações. O propósito dessas atividades é assegurar a proteção de recursos humanos, ambientais e econômicos, bem como garantir a segurança nacional e fornecer apoio em situações que demandem tomada de decisões em tempo hábil. Essas medidas têm como objetivo principal garantir respostas apropriadas diante de diferentes situações que possam surgir no ambiente marítimo.

Em muitos casos, especialmente em situações de “pronto emprego” ou “pronta ação”, é crucial identificar rapidamente as embarcações envolvidas. Conforme destacado por FONTOURA (1999), “a atividade de pronto emprego é essencial para a implementação de estratégias de defesa nacional”. Algumas das situações que exigem pronto emprego incluem operações de busca e salvamento (*Search and Rescue – SAR*), gerenciamento de acidentes

marítimos (como vazamentos de petróleo), proteção de áreas marinhas restritas (como durante o período de defeso de peixes) e identificação de embarcações suspeitas.

Para auxiliar as autoridades marítimas nas atividades de pronto emprego, é crucial ampliar o conhecimento sobre as embarcações presentes em uma determinada área do domínio marítimo, especialmente em locais estratégicos, como zonas portuárias e costeiras. Isso visa uma maior conscientização do domínio e conseqüentemente, expandir a capacidade de tomada de decisões em diversas situações. De acordo com MURRAY (2018), ter informações precisas e atualizadas é essencial para auxiliar na tomada de decisões em cenários relacionados ao domínio marítimo. Essas informações proporcionam um maior entendimento das atividades realizadas nesse ambiente, possibilitando uma tomada de decisão mais realista.

A MDA, como descrita por BORAZ (2009), também é conhecida como Consciência Situacional Marítima (*Maritime Situational Awareness – MSA*) (CLARAMUNT et al., 2017; SNIDARO; VISENTINI; BRYAN, 2015), está associada ao entendimento e à compreensão das atividades desenvolvidas nas áreas do domínio marítimo, mais especificamente mares e oceanos, em escala geográfica global, nacional ou transnacional. Segundo PLACHKOV et al. (2016), “a consciência do domínio marítimo pode ser entendida como o conhecimento situacional das condições físicas e ambientais que existem dentro ou influenciam uma determinada região marítima”.

O entendimento e ampliação da MDA é diretamente influenciado por comportamentos diretos ou correlatos (indiretos) de elementos que podem afetar as atividades de segurança, econômicas ou meio ambiente de uma determinada localidade espacial (ABIELMONA, 2013). Dentre os elementos envolvidos na MDA estão incluídas as infraestruturas, pessoas, cargas, embarcações e os demais objetos que influenciam de alguma maneira as atividades econômicas ou segurança. Dentre as atividades relacionadas à ampliação da MDA, podemos destacar como as mais relevantes o monitoramento das embarcações, a descoberta de padrões nas trajetórias e a avaliação da intenção de uma embarcação em determinada área do domínio marítimo (BANNISTER; NEYLAND, 2015; PLACHKOV et al., 2016).

A ampliação do conhecimento do domínio marítimo auxilia os órgãos governamentais e privados, relacionadas ao planejamento de atividades, principalmente aquelas relacionadas com ações de pronto emprego. De acordo com o presidente George W. Bush, “O coração do programa de conscientização de domínio marítimo é uma informação precisa, inteligente, em

tempo adequado para vigilância e reconhecimento de embarcações e elementos que utilizam o mar (...)” (BORAZ, 2009).

No contexto relacionado com este trabalho, a literatura traz várias abordagens voltadas para a ampliação da MDA, com objetivos diversos, principalmente no auxílio à tomada de decisão em diferentes cenários de pronto emprego, resumidos na Tabela 1.

Tabela 1 - Trabalhos Relacionados a Ampliação da MDA.

Autor(es)	Trabalho	Ano
(LASO et al., 2022)	ISOLA: An Innovative Approach to Cyber Threat Detection in Cruise Shipping	2022
(SOARES et al., 2019)	CRISIS: Integrating AIS and Ocean Data Streams Using Semantic Web Standards for Event Detection	2019
(ZHAO; SHI; YANG, 2018)	Ship Trajectories Pre-processing Based on AIS Data.	2018
(SANTIPANTAKIS et al., 2018)	A stream reasoning system for maritime monitoring.	2018
(HADZAGIC; SHAHBAZIAN, 2018)	Towards an Optimal Design of a Data Fusion System for Maritime Domain Awareness (Poster).	2018
(CLARAMUNT et al., 2017)	Maritime data integration and analysis: recent progress and research challenges.	2017
(FIORINI; CAPATA; BLOISI, 2016)	AIS Data Visualization for Maritime Spatial Planning (MSP).	2016
(DE SOUZA et al., 2016)	Improving fishing pattern detection from satellite AIS using data mining and machine learning.	2016
(SHELMERDINE, 2015)	Teasing out the detail: how our understanding of marine AIS data can better inform industries, developments, and planning.	2015
(VETTOR; SOARES, 2015)	Detection and analysis of the main routes of voluntary observing ships in the North Atlantic.	2015

Diferentemente dos estudos que se concentram em soluções globais de conscientização do domínio marítimo, conforme apresentado em (CLARAMUNT et al., 2017) e (HADZAGIC; SHAHBAZIAN, 2018), outros trabalhos (GIANNAKOPOULOS et al., 2014), (BATTISTELLO et al., 2016) e (SOARES et al., 2019) têm se dedicado à ampliação da MDA por meio de abordagens voltadas para perspectivas nacionais.

Esses trabalhos nacionais, abordam a conscientização do domínio marítimo em um contexto mais específico e direcionado a nível nacional. Eles levam em consideração as necessidades e desafios particulares de cada país em relação à segurança marítima, proteção de recursos e controle de fronteiras. Ao adotar essa perspectiva nacional, busca-se obter uma compreensão mais aprofundada das atividades marítimas em águas territoriais específicas,

possibilitando uma tomada de decisão mais precisa e eficiente, de acordo com as demandas e prioridades específicas de cada nação.

Além disso, as soluções de MDA nacionais, destacam a importância de adaptar e personalizar as abordagens de MDA para atender aos requisitos de maneira contextual do cenário encontrado. Consideram-se fatores como infraestrutura de vigilância marítima existente, legislação nacional, recursos disponíveis e colaboração entre agências governamentais. Dessa forma, a ampliação da MDA em perspectivas nacionais visa proporcionar uma conscientização marítima mais eficaz e alinhada às necessidades particulares de cada país e autoridade marítima.

2.2. Principais Tecnologias Utilizadas na Ampliação da MDA

A revisão da literatura revela diferentes campos de estudo que abordam a ampliação da MDA de maneiras específicas e complementares. Nesta sessão, descrevemos uma revisão literária das principais áreas relacionadas com o propósito estabelecidos neste trabalho.

No contexto de segurança marítima, as autoridades tendem a limitar a divulgação de informações sobre essas tecnologias e aplicações específicas por razões de segurança nacional. Considerando essa premissa, não há como descrever com exatidão como está o estado da arte nesse meio.

2.2.1. Realidade Aumentada

A realidade aumentada é uma solução tecnológica que combina elementos virtuais com o mundo real, proporcionando uma experiência interativa e imersiva aos usuários, combinando esses dois tipos de elementos em uma única cena, permitindo que o virtual e o real interajam entre si em um cenário determinado (TORI; KIRNER; SISCOOTTO, 2006). Essa solução pode ser utilizada para apoiar informacionalmente na ampliação da conscientização e compreensão do domínio marítimo de várias maneiras, principalmente na visualidade de dados.

Na visualização de dados, a realidade aumentada pode servir como uma poderosa solução para lidar com informações complexas, como informações oceanográficas, movimentação das embarcações, mapas de navegação, rotas de navios e localização de recursos navais. Por meio da exposição destes dados no contexto real, os utilizadores conseguem adquirir uma compreensão mais profunda do padrão de atuação e adquirir informações pertinentes a respeito das ações das embarcações, tornando mais simples o processo de tomar decisões.

No âmbito militar a apresentação de aplicações de realidade aumentada está mais restrita de publicações, em virtude da natureza do negócio. Esta limitação, impossibilita ter exatidão do estado da arte desta solução para este cenário.

No contexto de ampliação da MDA, utilizando realidade aumentada em localidades específicas, destacam os trabalhos de (BREITINGER; CLUA; FERNANDES, 2021) e (MARTELLI et al., 2021). Esses estudos convergem na utilização da realidade aumentada como ferramenta para enriquecer e expandir as informações sobre as embarcações, proporcionando uma visão informacional mais abrangente. Outras soluções de mercado, como o MarineTraffic¹ e RayMarine², também têm se destacado ao oferecer ampliação da MDA por meio da utilização da realidade aumentada.

Essas plataformas fornecem informações em tempo real sobre a localização e a movimentação das embarcações, tanto em portos quanto em alto-mar, conforme ilustrado na Figura 1. Através da utilização da tecnologia de realidade aumentada, os utilizadores conseguem explorar os dados ligados à circulação naval de maneira mais completa e interativa. Isso resulta em uma aprofundada percepção do cenário marinho, fortalecendo a administração e possibilitando uma tomada de decisões de maior eficácia e precisão.



Figura 1 - Exemplo de Realidade Aumentada (Fonte: Marine Traffic).

A realidade aumentada e o rastreamento em tempo real são duas tecnologias complementares que podem ser combinadas para criar experiências interativas e imersivas.

¹ <https://www.marinetraffic.com/>

² <https://www.raymarine.com/en-us>

O rastreamento em tempo real possibilita o monitoramento e controle das embarcações em tempo real. Isso pode ser realizado por meio de sensores, câmeras, sistema de posicionamento global (GPS) ou outras tecnologias de rastreamento. O rastreamento em tempo real permite que os sistemas identifiquem e acompanhem a localização, movimento e outras características dos elementos em questão.

A utilização de câmeras de vigilância e algoritmos avançados pode apoiar o rastreamento em tempo real, em inglês *Real-time Tracking*, de embarcações em movimento, a estimativa de sua posição e velocidade bem como a identificação de possíveis situações de risco. Segundo (HAMMEDI et al., 2019), a existência de soluções promissoras em detectar, classificar e rastrear objetos no domínio fluvial em tempo quase real, utilizando soluções promissoras como as abordagens de aprendizado profundo enfrenta a falta de disponibilidade de não existir dados acessíveis para este fim na literatura.

Contudo, a utilização de soluções de rastreamento de embarcações utilizando câmeras encontra diversos tipos de desafios relacionados com as condições meteorológicas, iluminação e a sobreposição (occlusão) entre as embarcações. Diferentes de outros objetos como os automóveis, em geral, as embarcações não possuem placas ou marcadores de registro visual que permita sua identificação única.

No entanto, as embarcações apresentam características visuais únicas, como as cores, as posições das boias, bandeiras, dentre outras características que as tornam um objeto original (único). Outro desafio encontrado do rastreamento em tempo real está relacionado em estimar a posição real em coordenadas geográficas das embarcações rastreadas.

A estimativa de posição, em inglês como "*Position Estimator*", é uma atividade que calcula a posição de um objeto ou área com referência ao sistema de coordenadas. A definição precisa da área de visualização da imagem capturada pela câmera pode ser desafiadora para determinar o polígono que permitirá identificar as coordenadas das embarcações detectadas pela visão computacional, além de permitir inserir os registros de navegação correspondentes.

Foram propostas várias técnicas na literatura para estimar a posição de embarcações no mundo real utilizando imagens de câmeras. No trabalho de SIMONSEN et al. (2020), foram apresentadas algumas técnicas para estimar as coordenadas de uma determinada área. A proposta de solução fundamenta-se na implementação de visão computacional, empregando uma Rede Neural Convolutiva (CNN) para detecção e uma rede pré-treinada específica para

embarcações. Além disso, é utilizada uma técnica de *ray-casting* para identificar a localização das embarcações que não possuem dados de navegação de imagens ópticas e térmicas.

No trabalho de AGARWAL et al. (2005), foi proposto um método alternativo para localização que utiliza a técnica de homografia. Uma das principais vantagens desse método é a capacidade de estimar a posição dos objetos usando apenas uma câmera. O funcionamento desse método ocorre ao mapear as coordenadas da imagem para as coordenadas de um plano conhecido. Isso é realizado por meio da identificação e correspondência de pontos-chave na imagem e no plano de referência. A técnica de homografia permite estabelecer uma relação entre as duas coordenadas, possibilitando a estimativa precisa da posição dos objetos.

2.2.2. *Visão Computacional*

A visão computacional é uma vertente da área de inteligência artificial que está relacionada com a interpretação de imagens e vídeos por máquinas. O objetivo é fazer com que os computadores possam enxergar e compreender o mundo visual de maneira semelhante aos seres humanos.

A visão computacional é uma área de pesquisa em constante evolução, com inúmeras aplicações em diferentes setores. Na área médica, a visão computacional pode ser utilizada para análise de imagens de tomografia computadorizada ou ressonância magnética, auxiliando na identificação de patologias com maior precisão e rapidez se comparada com a utilização convencional de imagens computadorizadas (ESTEVA et al., 2021).

Na indústria, a visão computacional pode ser usada em linhas de produção automatizadas para inspecionar produtos e detectar possíveis falhas de fabricação, reduzindo custos e aumentando a eficiência. Em segurança, a visão computacional é amplamente utilizada em sistemas de vigilância para detecção de comportamentos suspeitos ou reconhecimento facial.

A visão computacional também é usada em diversas aplicações de entretenimento, como jogos e realidade virtual, permitindo interações mais naturais entre o usuário e o ambiente virtual (BREITINGER; CLUA; FERNANDES, 2021). Para possibilitar a interpretação de imagens e vídeos, a visão computacional utiliza técnicas avançadas de processamento de imagens, aprendizado de máquina e reconhecimento de padrões. Essas técnicas permitem que as máquinas identifiquem objetos, rostos, gestos e outras características visuais, além de possibilitar a análise de movimentos, reconhecimento de voz e outras funcionalidades.

A detecção de embarcações é uma tarefa importante em muitos cenários, incluindo a gestão do tráfego marítimo e a segurança portuária em diversas situações, desde o controle de tráfego marítimo até a segurança em fronteiras. A visão computacional tem sido amplamente utilizada para detectar embarcações em imagens e vídeos de satélite, drones e câmeras instaladas em portos e navios.

A utilização da visão computacional no tráfego marítimo, permite utilizar algoritmos e técnicas para processar imagens e vídeos e identificar embarcações de diferentes tipos e tamanhos em tempo real (YANG; YAN; WANG, 2022). Na monitoração do tráfego marítimo, a visão computacional é utilizada para identificar navios em movimento, estimar sua posição e velocidade e prever possíveis colisões ou outras situações de risco. Essa tecnologia também é utilizada em operações de busca e salvamento, ajudando a localizar embarcações em perigo ou em emergências.

Além disso, a visão computacional também é utilizada em operações de controle de fronteiras marítimas, onde é capaz de identificar embarcações que se aproximam da costa e avaliar o risco potencial de entrada ilegal no país. Essa tecnologia é capaz de detectar embarcações que se aproximam de forma furtiva ou que navegam em áreas restritas, alertando as autoridades e permitindo que sejam tomadas medidas preventivas (KIEFER et al., 2023).

De maneira geral, a visão computacional tem se mostrado uma tecnologia eficiente na detecção de embarcações em diversas situações, proporcionando maior segurança e eficiência nas operações marítimas. Com a evolução contínua da tecnologia, espera-se que a visão computacional se torne ainda mais sofisticada e possa contribuir cada vez mais para a segurança e a eficiência do tráfego marítimo, possibilitando apoiar na ampliação da MDA.

2.2.3. *Redes Neurais Artificiais Profundas*

A utilização de modelos de inteligência artificial baseados em aprendizado profundo, como as Redes Neurais de Aprendizado Profundo, em inglês *Deep Learning Neural Network* (DNN), tem se mostrado promissor para apoiar na ampliação da MDA. Esses modelos de DNN são capazes de identificar e classificar objetos com uma alta taxa de velocidade e assertividade de predição. No contexto marítimo, soluções DNN têm sido usadas em vários desafios de MDA, incluindo a detecção e classificação de tipos de embarcações usando imagens sintéticas e não sintéticas (BREITINGER; CLUA; FERNANDES, 2021; KIM et al., 2022).

A visão computacional, utilizando modelos DNN, tem sido empregada como uma solução para auxiliar na interpretação e compreensão visual do domínio marítimo (KIM et al.,

2022). Os modelos DNN são capazes de identificar e classificar objetos com precisão e capacidade de detecção e classificação de diferentes tipos de embarcações por meio de imagens sintéticas ou reais.

Um tipo específico de DNN, as CNN revolucionaram o estado da arte na detecção e reconhecimento de objetos, alcançando resultados mais rápidos e precisos (SIMONYAN; ZISSERMAN, 2014). Diferentemente das tradicionais DNN, as CNN usam menos parâmetros (pesos), permitindo um treinamento significativamente mais rápido.

Dentre as arquiteturas de CNN mais populares e bem-sucedidas atualmente utilizadas para a detecção e identificação de objetos, cada uma possui suas próprias vantagens e desvantagens, apresentando níveis variados de precisão e velocidades de execução. A escolha da arquitetura mais adequada depende do contexto específico da aplicação e das necessidades do sistema de detecção de objetos em questão. Alguns modelos destacam-se por sua alta precisão, enquanto outros se destacam pela rápida velocidade de processamento, proporcionando uma gama de opções para atender às demandas específicas de diferentes cenários e aplicações de detecção.

Uma das arquiteturas de CNN mais rápidas e precisas do estado da arte utilizando CNN é o “*You Only Look Once*” (YOLO) (BOCHKOVSKIY; WANG; LIAO, 2020). O YOLO atende aos requisitos em algumas propostas de trabalho de Redmon et al. (REDMON et al., 2016), Redmon e Farhadi (REDMON; FARHADI, 2018) para processamento em tempo real e é robusto a mudanças de iluminação em imagens não sintéticas mantendo uma rede neural simples, usando uma única GPU com um tamanho menor de lote para treinar um modelo.

A literatura apresenta outras arquiteturas de redes CNN alternativas ao framework YOLO, como *Histogram of Oriented Gradients* (HOG) (SURASAK et al., 2018), Fast R-CNN (GIRSHICK, 2015), Faster R-CNN (JIANG; LEARNED-MILLER, 2017), Single Shot Detector (SSD) (LIU et al., 2016) e RetinaNet (WANG et al., 2019).

Na atividade de detecção de embarcações utilizando CNN, a abordagem de transferência de aprendizado, inglês *Transfer Learning*, de aprendizado é uma das mais utilizadas (PAN; YANG, 2010). A abordagem de transferência de aprendizagem combinada com uma estratégia de ajuste fino (*Fine Tunning*), possibilita especificar (refinar) a perspectiva de detecção de embarcações e especializá-lo para a utilização em contextos mais específicos (AHMED et al., 2021).

Um exemplo de abordagem de ajuste fino para a detecção de embarcações é descrito no trabalho de LEELA et al. (2020), os autores usaram uma CNN com abordagem *Transfer Learning* e ajustaram o classificador com a estratégia *Fine Tunning* para ampliar a classificação específica de alguns tipos de embarcações.

No estudo conduzido por LI et al. (2019), com o título “Detecção de Navios em Imagens de Radar de Abertura Sintética com Base em Resnet e Aprendizado por Transferência”, os autores empregaram uma Rede Neural Convolutiva (CNN) pré-treinada e a adaptaram para a tarefa de identificação de embarcações em imagens de satélite de alta definição. Os pesquisadores inicialmente submeteram a CNN a um treinamento utilizando um conjunto de dados específico de embarcações. Posteriormente, aplicaram uma abordagem de detecção de objetos para delimitar as áreas de interesse nas imagens de satélite. Nesse ponto, as características dessas regiões foram extraídas por meio da CNN ajustada. Por fim, empregaram um modelo classificador para reconhecer e categorizar as áreas delimitadas como sendo representativas de embarcações

Em ambos os trabalhos (LEELA; ROH; OHB, 2020; LI et al., 2019, 2019), os resultados do estudo mostraram que o modelo de ajuste fino produziu resultados significativamente melhores do que um modelo de CNN treinado do zero para a detecção de imagens das embarcações. Os autores também mostraram que a adição de dados de treinamento aumentou o desempenho do modelo.

Em resumo, o ajuste fino é uma técnica poderosa para melhorar a detecção de embarcações por meio de visão computacional. As abordagens de ajuste fino podem melhorar o desempenho dos modelos de detecção de embarcações por meio da utilização de redes neurais pré-treinadas e de conjuntos de dados de treinamento adicionais. Essas melhorias são essenciais para aprimorar a segurança e a eficiência do transporte marítimo e para a aplicação da lei em portos e águas territoriais.

2.2.4. Anotação dos Objetos

A atividade de anotação ou rotulação das imagens das embarcações é fundamental em sistemas baseados em visão computacional. A atividade de anotação de objetos pode ser realizada de maneira automática ou manual, dependendo de fatores como o tamanho da coleção de dados e a existência de uma fonte contextual de informações dos objetos.

As ferramentas de anotação manual de imagens são utilizadas para rotular objetos de interesse em imagens e vídeos, fornecendo informações valiosas para treinar as CNN. Em geral,

essas anotações são realizadas por humanos, que identificam e delimitam os objetos desejados nas imagens, utilizando as diversas ferramentas encontradas na literatura. Dentre as principais ferramentas utilizadas na área de visão computacional, destacam-se Labelme (RUSSELL et al., 2008), *Computer Vision Annotation Tool* (CVAT) (SEKACHEV et al., 2020) e o Roboflow (DWYER; NELSON; SOLAWETZ, 2022).

No contexto de ampliação da MDA, devido à necessidade de anotar um grande conjunto de imagens a tarefa de anotação manual pode envolver a participação colaborativa de um grupo de pessoas, utilizando *crowdsourcing* (VONDRICK; PATTERSON; RAMANAN, 2013). O *Crowdsourcing* é um modelo de produção colaborativa que envolve a contribuição de uma grande quantidade de pessoas para solucionar um problema ou realizar uma tarefa, e isso pode ser feito por meio de plataformas online que permitem que os usuários rotulem imagens em troca de uma forma de incentivo, financeiro ou não.

A aquisição de rótulos como uma tarefa de *crowdsourcing* tem sido extensivamente estudada para apoiar na formação de coleções de dados de treinamentos para utilizando em DNN (HAMMEDI et al., 2019). No trabalho de DENG et al. (2014), o autor realiza uma pré-filtragem das embarcações relevantes para a formação da coleção de dados e aplica os resultados às atividades de *Crowdsourcing*, utilizando a interface do *Amazon Mechanical Turk*, para obter as anotações das embarcações.

O *Crowdsourcing* tem sido empregado em cenários onde os conjuntos de dados utilizados para treinamento apresentam um alto grau de similaridade entre os objetos, dificultando a formação de coleção de dados adequada para a detecção e o rastreamento de objetos (KUMAR; SHERLY, 2017).

No contexto de ampliação da MDA, a anotação automática de imagens de embarcações geralmente requer o uso de informações contextuais das próprias embarcações, juntamente as suas respectivas imagens. As informações contextuais são frequentemente provenientes de sensores de navegação que fornecem registros de atividade das embarcações, conhecidos como registros de navegação.

Para obter uma cobertura e veracidade no uso dos registros de navegação, a literatura apresenta diversos trabalhos que utilizam técnicas de fusão de dados para ampliar a MDA. A fusão de dados de sensores é uma técnica essencial na visão computacional, com aplicações em sistemas de segurança, robótica e detecção de objetos em veículos autônomos. Na literatura, existem diversos estudos que abordam a fusão de dados no contexto da MDA, como

demonstrado em CLARAMUNT et al., (2017), GARCÍA et al., (2010), (ZHAO; SHI; YANG, 2018), (FIORINI; CAPATA; BLOISI, 2016), (DE SOUZA et al., 2016), (SHELMERDINE, 2015), (VETTOR; SOARES, 2015) e (FALCON et al., 2014). Esses trabalhos ainda destacam a importância da fusão de múltiplas fontes de dados para ampliar a MDA. Ao utilizar a fusão de dados de diferentes sensores, é possível obter informações mais precisas e completas sobre o ambiente, o que pode apoiar na tomada de decisões.

De acordo com BATTISTELLO et al., (2016), para melhorar a conscientização do ambiente marítimo, é essencial realizar a fusão de dados provenientes de diversas fontes, a fim de aprimorar as atividades de monitoramento e rastreamento de embarcações. Especialmente no contexto utilizando dados de sensores, a fusão de dados pode ser entendida como um processo de múltiplas atividades, que envolva as tarefas de identificação, associação e correlação entre os dados para alcançar objetivos relevantes e importantes (STEINBERG; BOWMAN; BOWMAN, 2017).

A fusão de dados de sensores pode melhorar a precisão e a confiabilidade do rastreamento de embarcações em sistemas de visão computacional, permitindo que os algoritmos de detecção e rastreamento tenham uma compreensão mais completa do ambiente marítimo em tempo real. Ao combinar os dados fusionados com as imagens das câmeras, é possível identificar uma embarcação específica em uma cena e rastreá-la com maior precisão (ZWEMER et al., 2021).

A utilização da anotação de imagens, seja manualmente ou automaticamente, pode viabilizar a criação de coleções de imagens especialmente construídas para um propósito específico. As coleções de imagens especialmente construídas desempenham um papel fundamental no campo da Visão Computacional aplicada ao domínio marítimo. Essas coleções consistem em conjuntos de imagens selecionadas e organizadas de forma estratégica para fins específicos, como treinamento e avaliação de algoritmos de aprendizado de máquina.

Nos últimos tempos, tem ocorrido um aumento significativo na disponibilidade de coleções de imagens específicas para aprimorar o desempenho de tarefas de visão computacional. Essas coleções de imagens têm desempenhado um papel crucial no desenvolvimento e aprimoramento de algoritmos e modelos de aprendizado de máquina, aplicados à visão computacional no domínio marítimo, especificamente nas áreas de detecção, classificação e rastreamento de objetos. A Tabela 2, sumariza alguns trabalhos relacionados a

construção de o uso de sensores de navegação e visão computacional para rotular imagens de embarcações.

Tabela 2 - Coleções de Imagens Especialmente Construídos na Ampliação da MDA.

Trabalho	Descrição	Abordagem de Anotação
Sea Situational Awareness (SeaSAW) Dataset (KAUR et al., 2022)	A utilização de câmeras para a formação de um conjunto de dados marítimos para detecção, classificação e rastreamento refinados de embarcações na costa leste dos Estados Unidos e na Europa.	A anotação das classes é feita utilizando a multidão (humana), através do serviço fornecido pela empresa ScaleAI ³ . Cada objeto anotado possui uma caixa delimitadora, um ID exclusivo e uma classe (tipo).
SeaShips: A Large-Scale Precisely Annotated Dataset for Ship Detection (SHAO et al., 2018)	Criação de uma coleção com 31.455 imagens de 6 tipos embarcações obtidas de câmeras de monitoramento na costa da China. As imagens são utilizadas para apoiar no treinamento e avaliar algoritmos de detecção de embarcações.	Assim como outros conjuntos de dados grandes, foi utilizado a anotação e delimitação dos objetos de maneira manual para rotular as imagens detectadas. Para obter uma representação equilibrada de seis tipos de embarcações, com cada tipo representando entre 10% a 17% do total da coleção de dados. Isso permitiu um balanceamento adequado do conjunto de dados.
Video Processing From Electro-Optical Sensors for Object Detection and Tracking in a Maritime Environment: A Survey (PRASAD et al., 2017)	Criação de uma coleção de imagens RGB obtidas em terra e a bordo de embarcações na área de Cingapura.	As imagens são anotadas manualmente por voluntários não relacionados ao projeto.
ARGOS-Venice Boat Classification (BLOISI et al., 2015)	Uma coleção de dados públicos contendo imagens e vídeos capturados por câmeras RGB em um cenário real de monitoramento marítimo na cidade de Veneza, na Itália, foi criada com o objetivo de fornecer estatísticas de tráfego	Com o propósito de garantir maior veracidade na rotulação das classes em uma grande quantidade de imagens capturadas, a anotação é realizada manualmente por um especialista em tráfego

³ <https://scale.com/>

	marítimo com base nos tipos de embarcações (classes)	marítimo. Depois que um conjunto mínimo de dados é coletado, um modelo é criado para realizar uma pré-classificação, permitindo que o operador confirme ou corrija a classe da embarcação com facilidade.
--	--	---

Em um período de quatro anos, KAUR et al., (2022) construíram o maior conjunto de dados marítimos para detecção, classificação e rastreamento refinados de objetos, composto por 1,9 milhão de imagens associadas a 12 classes de objetos incluindo os tipos de embarcação de pesca, draga entre outros. Esse conjunto de dados foi obtido a partir de 9 câmeras RGB montadas em diferentes embarcações em movimento. O autor apresenta que a formação de uma coleção de dados na área portuária é desafiadora em virtude da sobreposição e alta de densidade de embarcações nas imagens.

No trabalho de SHAO et al. (2018), a coleção de imagens de embarcações foi adquirida por meio da utilização de 156 câmeras em 50 localizações distintas próximas à costa da China. A anotação das classes (tipos) de embarcações e a delimitação (*boundary boxes*) dos objetos foram feitas manualmente. Para garantir uma representação equilibrada dos seis tipos diferentes de embarcações presentes nas imagens, foi realizada uma adequada balanceamento do conjunto de dados.

No trabalho de PRASAD et al. (2017) foi desenvolvido um conjunto de imagens de embarcações em Singapura. Esse conjunto é composto por imagens RGB adquiridas em terra e a bordo de embarcações na área de Singapura. Ao todo, o conjunto de imagens RGB contém 20.367 imagens, abrangendo um total de 157.668 objetos presentes nas cenas marítimas. Para garantir a precisão das informações sobre os objetos nas imagens, as anotações são realizadas manualmente por voluntários que não possuem relação direta com o projeto.

O trabalho de BLOISI et al. (2015) aborda a formação de uma coleção de dados contendo imagens e vídeos capturados por câmeras RGB em um cenário real de monitoramento marítimo na cidade de Veneza, na Itália, criada com o objetivo de fornecer estatísticas de tráfego marítimo com base nos tipos de embarcações (classes). A anotação das classes é realizada manualmente por um especialista em tráfego marítimo garante a precisão da rotulação das classes em imagens capturadas. Depois que um conjunto mínimo de dados é coletado, um modelo de pré-classificação é utilizado e o operador confirma ou efetua a correção da classe da embarcação.

A literatura também apresenta a formação de coleção de imagens de embarcação utilizando dados capturados na Internet. O primeiro trabalho que se destaca é o conjunto de dados, que consiste em imagens e vídeos, coletados em diversos pontos de vista e locais variados, com 13 classes de navios (ZHENG; ZHANG, 2020). Outra coleção de imagens é apresentada por GUNDOGDU (2017) contendo 2 milhões de imagens de 109 classes de navios, obtidas a partir do site de cadastro de embarcações chamado *Shipspotting*⁴. O objetivo principal desse conjunto de dados é possibilitar a classificação de imagens de embarcações em situações ideais de visibilidade. Em uma pesquisa realizada em 01/04/2023, foram contabilizadas 20.031 fotos de embarcações brasileiras disponíveis no referido site.

⁴ <https://www.shipspotting.com/>

3. O MODELO CV-MDA

QP3: Como a interligação de diversas soluções e tecnologias pode ser utilizada para a formação de coleções de dados anotados?

Neste capítulo, apresentamos o modelo CV-MDA, projetado para enfrentar o desafio de criação de coleções de dados de maneira automática e semiautomática utilizando registros de navegação para apoiar na ampliação da consciência do domínio marítimo.

O método CV-MDA é composto pelas etapas/camadas de dados, visão/projeção, anotação automática, anotação semiautomática e suas respectivas atividades apresentadas na Figura 2.

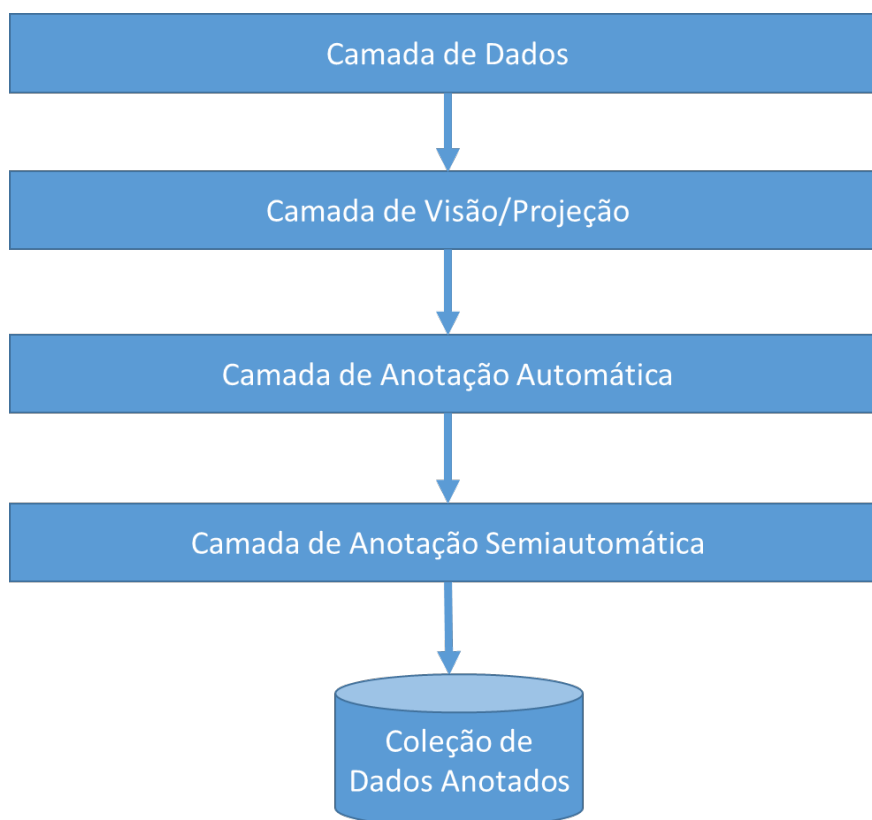


Figura 2 - Etapas/Camadas do Método CV-MDA.

3.1. Camada de Dados

A etapa/camada de dados consiste na obtenção, integração e geocodificação dos registros de navegação das diversas fontes de dados, criando um fluxo de dados consolidado de dados de navegação. A Figura 3, apresenta os processos que compõem essa etapa.




Figura 3 - Pré-Processamento no Método CV-MDA.

Obtenção de dados: nessa etapa, os dados de navegação são coletados a partir de diferentes fontes. Cada fonte pode fornecer diferentes tipos de informações, suplementares e relevantes para o processo de anotação automática de imagens de embarcação, como diferentes tipos/classes de embarcações em diferentes ou na mesma área de coberturas espacial.

A heterogeneidade decorrente da utilização de diferentes fontes de dados permite uma análise mais completa das embarcações em uma determina região marítima. Essas informações podem ser utilizadas para apoiar nas tarefas de detecção, classificação e anotação automática de imagens de embarcação, permitindo uma compreensão mais precisa e detalhada do ambiente marítimo.

Integração de dados: uma vez que os dados são coletados, eles precisam ser integrados em um único fluxo de dados. Isso envolve a padronização dos formatos de dados, a resolução de conflitos e inconsistências e a criação de uma estrutura unificada que possa ser utilizada nas etapas subsequentes.

Geocodificação: A geocodificação é o processo de associar as coordenadas geográficas dos registros de navegação em uma representação alfanumérica compacta. O processo/atividade consiste em converter uma coordenada geográfica (latitude e longitude) em uma sequência de caracteres que representa a localização.

3.2. Camada de Visão/Projeção

A etapa/camada de visão/projeção consiste na criação de uma estrutura baseada em realidade aumentada e outra estrutura de visão computacional. A Figura 4, apresenta os processos que compõem essa etapa.



Figura 4 - Visão/Projeção dos Dados no Método CV-MDA.

A estrutura baseada na área de Realidade Aumentada utilizada neste trabalho foi criada com o intuito de melhor compreender e visualizar os dados de registros de navegação consolidados, criando uma interface de realidade virtual. Os registros de navegação possuem a descrição das embarcações, como suas coordenadas geográficas e o as informações sobre a dimensão das embarcações. As embarcações são digitalmente inseridas na interface gráfica (mapa) onde podemos interagir com elas em tempo real.

A utilização da realidade virtual para visualização de embarcações está relacionada com a exploração detalhada dos dados consolidados das diversas fontes de dados de navegação e a experiência imersiva no contexto de MDA. A exploração detalhada utilizando realidade virtual permite oferecer uma maneira do usuário explorar o cenário de dados encontrados em um nível mais detalhado do que seria possível em uma visualização 2D convencional, como os mapas e cartas náuticas. Além disso, a experiência imersiva utilizando realidade virtual, possibilita criar uma sensação de presença e imersão no contexto apresentado pelos dados.

A estrutura baseada na área de Visão Computacional lida com o processamento e análise das imagens e vídeos do ambiente de tráfego marítimo, importante para a ampliação da MDA. A visão computacional neste contexto permite que uma solução computacional “enxergue”,

processar e analisar as embarcações em movimento, semelhante ao comportamento de uma visão humana.

3.3. Camada de Anotação Automática

A etapa/camada de anotação automática consiste na fusão entre as camadas de visão computacional e a camada de realidade aumentada para produzir uma coleção de dados fino e contextual. Ilustrado pela Figura 5, apresenta os processos que compõem essa etapa.

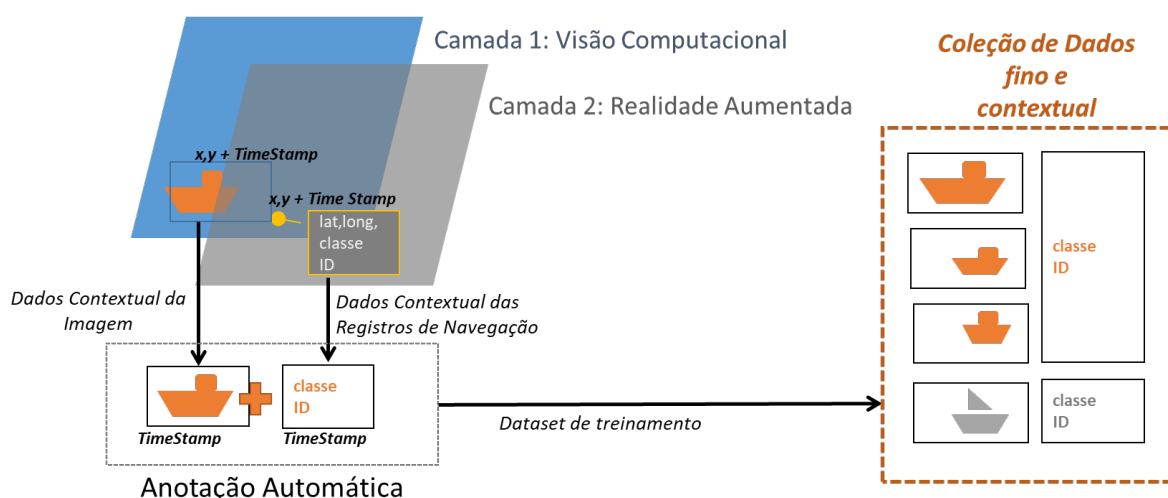


Figura 5 - Anotação Automática dos Dados no Método CV-MDA.

Contudo, devido à existência de múltiplas embarcações em uma mesma região marítima, representada nas visualizações virtual e real dos dados, é necessário a formação de uma abordagem para estimar qual é a embarcação que está sendo clicada ou detectada, para estabelecer a fusão entre as camadas. Essa abordagem é fundamental para garantir uma fusão adequada e precisa das informações entre as camadas virtual e real.

Propomos uma abordagem para a anotação automática de imagens de navegação estruturada em duas etapas, interseção/sobreposição e a estimativa adaptativa de distância. Essa abordagem de estabelecimento da relação entre as camadas de visão computacional e realidade aumentada para fusionar os dados seguiu como referência o trabalho apresentado de LEE e JANG (2018).

As duas atividades utilizadas neste trabalho visam enfrentar o desafio de fusionar as imagens das embarcações com os registros de navegação, proporcionando relacionar informações contextuais das embarcações com o objeto de formar uma coleção de dados fino e contextual.

3.4. Camada de Anotação Semiautomática

A etapa/camada de anotação semiautomática está basicamente organizada em duas atividades. Na primeira atividade, denominada de validação da coleção de imagens anotadas automaticamente, é realizada a validação das imagens anotadas automaticamente utilizando uma solução de *Crowdsourcing*. Nesta atividade, as imagens anotadas automaticamente e validadas pelo *Crowdsourcing* são utilizadas como entrada para a formação de uma solução contextual e fino do modelo de detecção de embarcações. Essa atividade visa garantir a precisão das anotações por meio da revisão manual e validação das classificações realizadas pelo modelo.

A segunda atividade consiste na anotação semiautomática, mediante a validação das classificadas pelo classificador utilizando a coleção de imagens das embarcações obtida da atividade de anotação automática. A Figura 6 ilustra as atividades de anotação semiautomática.




Figura 6 - Anotação Semiautomática no Método CV-MDA.

4. O MÉTODO CV-MDA

QP4: Como a formação de coleções de imagens de maneira contínua e automatizada pode contribuir na ampliação da MDA?

Neste capítulo, apresentamos o método CV-MDA, projetado para enfrentar o desafio de criação de coleções de dados automaticamente e semiautomaticamente utilizando registros de navegação para apoiar na ampliação da consciência do domínio marítimo.

4.1. Camada de Dados

4.1.1. Obtenção de Dados

Para este trabalho, os termos registros de navegação, dados de navegação ou pontos de navegação são sinônimos e podem ser caracterizados como dados brutos únicos de determinado sensor ou sistema de informação com registros de tempo p_1, p_2, \dots, p_n .

O i -ésimo ponto é representado minimamente como uma tripla, denotado por $p_i = (x_i, y_i, t_i)$, onde x_i e y_i é uma localização bidimensional (latitude e longitude, por exemplo) e t_i registra o carimbo de data e hora (*timestamp*) do registro. Para enriquecer circunstancialmente os registros com informações contextuais sobre as embarcações, foram incluídas outras informações como o nome da embarcação, o tipo da embarcação e o nome da fonte dos registros de navegação. A Tabela 3, apresenta exemplos de registros de pontos de navegação.

Tabela 3 - Registros de Navegação.

Pontos de Navegação					
Nome Embarcação	Latitude	Longitude	Identificador de Embarcação	Fonte Específica	Timestamp
NAZARÉ	38,63	-80,73	IRIN:16161	Fonte1	14/05/2023 18:00:00
NAZARÉ	39,99	-88,12	IMO 4555 e IRIN:16161	Fonte2	14/05/2023 18:30:00
MARIA II	39,02	-76,63	MMSI:101010	Fonte3	14/05/2023 18:00:00

Na Tabela 3, podemos observar que as linhas 1 e 2 apresentam diferentes fontes de dados representando informações sobre a mesma embarcação chamada “NAZARÉ”. Isso indica que

múltiplas fontes de dados estão registrando e fornecendo informações sobre essa embarcação específica.

Por outro lado, na linha 3, apenas uma única fonte de dados está referenciando a embarcação “MARIA II”. Isso significa que, nesse caso, somente uma fonte de dados está registrando e fornecendo informações sobre essa embarcação em particular.

Essa variação na quantidade de fontes de dados referenciando cada embarcação pode ocorrer devido a vários fatores, como a disponibilidade e acessibilidade das fontes de dados em relação a determinadas embarcações, a cobertura de monitoramento das diferentes fontes de dados em áreas específicas ou até mesmo a preferência dos operadores ou proprietários das embarcações em utilizar certas fontes de dados.

É importante levar em consideração essa disparidade na quantidade de fontes de dados referenciando as embarcações ao realizar a análise dos registros de navegação. Isso pode influenciar a disponibilidade e a qualidade das informações disponíveis para cada embarcação, bem como a confiabilidade e a precisão das estimativas e análises baseadas nesses dados.

Na Tabela 4, são apresentadas algumas das fontes de dados encontradas no domínio marítimo brasileiro que foram utilizadas neste trabalho específico. É importante ressaltar que a escolha dessas fontes de dados utilizadas pode variar dependendo do contexto e dos recursos disponíveis. A seleção das fontes de dados deve considerar a disponibilidade, confiabilidade e relevância das informações para os objetivos da análise e anotação das imagens de embarcações.

Tabela 4 - Fontes de Registros de Navegação no Domínio Marítimo Brasileiro

Nome (sigla)	Descrição	Unidade de Medida de Localização Geográfica	Tipo de Sensor	Privacidade da Fonte	Contexto Geográfico
AIS	Sistema de Identificação Automática de Monitoramento costeiro de curto alcance utilizado em navios.	GMS	Terrestre	Pública	Mundo
SISTRAM	Sistemas de Informações sobre o Tráfego Marítimo do Brasil	HEXADECIMAL	Sistema de Informação	Privada	Brasil
SIMMAP	Sistema de Monitoramento Marítimo de Apoio às atividades do Petróleo	GMS	Terrestre	Privada	Brasil
LRIT	Sistema de Monitoramento Global de Longa Distância	GMS	Satélite	Pública	Mundo
PREPS	Programa de Rastreamento de Embarcações de Pesca via Satélite	GMS	Satélite	Privada	Brasil
VRMTC (TRMN)	Virtual Regional Maritime Traffic	GMS	Terrestre	Privada	Brasil
MSSIS	The Maritime Safety & Security Information System	GMS	Terrestre	Privada	Brasil
PRENAV	Programa de Rastreamento de Embarcações que operam nas navegações reguladas pela ANTAQ	DECIMAL	Satélite	Privada	Brasil

Para fins de confidencialidade de dados neste trabalho, foram utilizadas as fontes com a privacidade pública. Os dados passaram por um processo simples de anonimização em relação ao nome da embarcação, os identificadores e a classe/tipo da embarcação, a fim de não expor a identidade dos meios navais. Ao remover ou mascarar certos elementos dos registros de navegação, é possível garantir que as informações sejam utilizadas de forma anônima, preservando a privacidade dos indivíduos ou das organizações envolvidas.

Por meio da anonimização dos dados de navegação, buscamos garantir a proteção da privacidade das informações das embarcações e atender aos requisitos de privacidade de dados.

4.1.2. Integração de Dados

Para este trabalho, a integração dos dados de navegação das diversas fontes de dados é realizada utilizando o identificador da embarcação como um dos elementos básicos de formação da trajetória. No entanto, é importante destacar que não existe um identificador de embarcação único comum a todas as fontes de dados.

No contexto marítimo, os identificadores mundialmente utilizados pelas embarcações incluem o IRIN (*International Radio Call Sign*), o IMO (*International Maritime Organization Number*) e o MMSI (*Maritime Mobile Service Identity*). Esses identificadores são usados para rastrear e identificar as embarcações em diferentes sistemas de monitoramento.

Foi necessário estabelecer e selecionar as embarcações que apresentem um registro de embarcação completo em relação as informações de identificação das embarcações.

Conduzimos um estudo com 25.618.290 registros de navegação de diversas fontes de dados, relacionados a um cadastro com 57.372 embarcações previamente cadastradas, apresentados na Figura 7. O objetivo deste estudo era de analisar/verificar a existência dos três principais identificadores de embarcação (IRIN, IMO e MMSI).

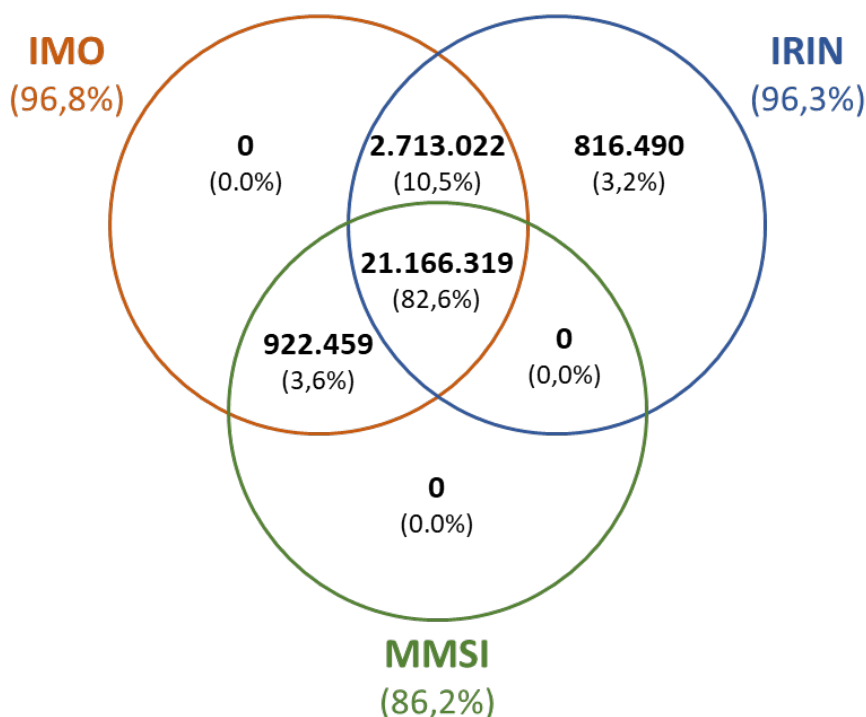


Figura 7 - Registros de Navegação de Diversas Fontes.

Conforme apresentado na Figura 7, podemos apresentar os identificadores de embarcação mais frequentes nos registros de pontos de navegação:

1. O identificador de embarcação IMO é utilizado em 96,8% dos registros.
2. O identificador de embarcação IRIN é utilizado em 96,3% dos registros.
3. O identificador de embarcação MMSI é utilizado em 86,2% dos registros.

Conforme apresentado no estudo, 82,6% dos registros possuem a capacidade de fusão adequada, ou seja, utilizando pelo menos um dos 3 elementos de interligação é possível, formar uma trajetória. Considerando apenas os identificadores IRIN e IMO temos um total percentual de 93,1% dos registros para realizar a fusão, enquanto utilizando apenas os identificadores MMSI e IRIN temos 0% dos registros para fusão.

Este estudo apresenta que o identificador IMO possui a melhor capacidade de fusionar, pois é o identificador mais frequentes entre os registros de navegação, portanto os mais adequados para efetuar a interligação entre os registros de navegação com os dados de embarcações. No entanto, com o objetivo de obter resultados mais precisos e uma melhor integração entre as fontes de dados, este trabalho optou por realizar a integração dos dados utilizando os registros que possuem o identificador MMSI.

A decisão de priorizar o uso do identificador MMSI na integração dos dados pode ter sido influenciada pela disponibilidade dos registros que o possuem, pela confiabilidade das informações fornecidas por esse identificador ou pela relevância desse atributo na análise e no contexto específico do estudo.

Cada trabalho pode ter suas próprias considerações e critérios ao realizar a integração de dados, levando em conta os objetivos específicos, as limitações dos dados disponíveis e as necessidades do domínio em questão. É importante adaptar a abordagem de integração de dados às particularidades e características do problema em estudo, buscando sempre obter resultados mais verídicos e uma melhor capacidade de integração entre as fontes de dados.

4.1.3. Geocodificação de Dados

A geocodificação utilizando *geohash* é um método de codificação de localização geográfica em uma sequência alfanumérica. Essa técnica é usada para representar coordenadas geográficas (latitude e longitude) de forma compacta e eficiente. Os passos básicos envolvidos na geocodificação são:

- Coletar as coordenadas de latitude e longitude da localização desejada.
- Escolher a precisão desejada para o *geohash* (número de caracteres).

- Utilizar uma função ou biblioteca de geocodificação para converter as coordenadas em um código correspondente com a precisão desejada.

Em decorrência da simplicidade de implementação e entendimento na atividade de geocodificação das coordenadas dos registros de navegação, este trabalho, seguiu outros trabalhos GUO et al. (2019) e optou pela utilização da solução denominada de “geohash geocodificação” (NIEMEYER, 2008).

A geocodificação das coordenadas geográficas é uma sequência alfanumérica que representa a localização geográfica com a precisão especificada. A principal vantagem da geocodificação utilizando *geohash* é que a sequência resultante pode ser facilmente compartilhada, armazenada e processada em sistemas que não lidam diretamente com coordenadas geográfica.

Na Figura 8, apresentamos um exemplo da aplicação do processo de geocodificação de coordenadas específicas, como no caso de latitude -22.900429 e longitude -43.167572, com uma precisão de 8 caracteres no *geohash*.

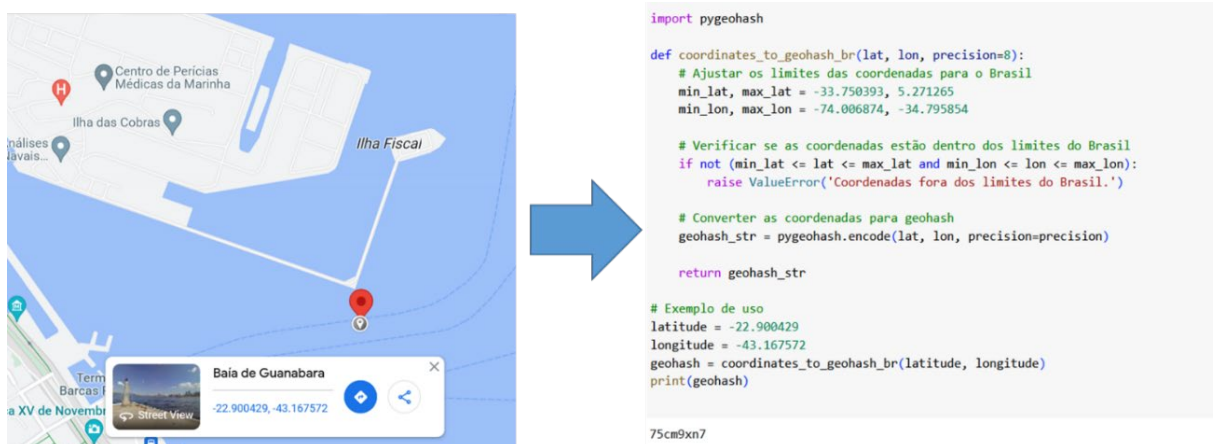


Figura 8 - Exemplo e Código de Geocodificação.

Ao utilizar a geocodificação com *geohash*, é possível associar rapidamente uma localização geográfica a um código único, simplificando a manipulação e busca de dados espaciais. Essa abordagem é amplamente utilizada em diversas aplicações, como geolocalização, análise espacial, indexação e pesquisa de pontos de interesse, entre outros.

No contexto deste trabalho, os registros de navegação consolidados foram transformados em geocodificação *geohash*. Isso permite que cada localização seja representada por um código *geohash* único. Essa transformação simplifica o armazenamento e a manipulação dos dados,

além de facilitar a busca e a análise espacial. A Figura 9 apresenta o processo utilizado neste trabalho para a transformação dos registros de navegação em geocodificação *geohash*.

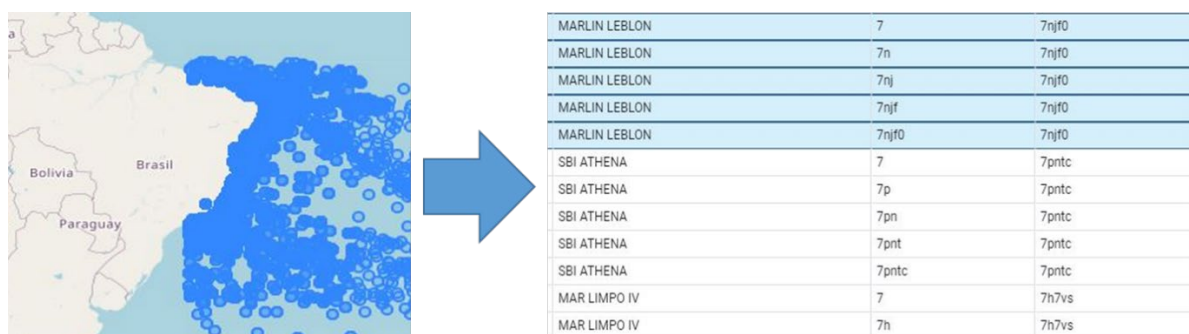


Figura 9 - Geocodificação dos Registros Consolidados de Navegação.

4.2. Camada de Visão/Projeção

4.2.1. Realidade Aumentada

A calibração da câmera no mundo virtual é um processo diferente da calibração da câmera no mundo real. Na calibração da câmera virtual, os parâmetros a serem ajustados estão relacionados à perspectiva, campo de visão e distorção da câmera virtual no ambiente virtual. Esses parâmetros influenciam a forma como a cena virtual é projetada para a exibição.

Neste trabalho utilizamos o *framework* Cesium⁵ para a criação do ambiente de realidade virtual. O Cesium foi selecionado como a plataforma subjacente do sistema, pois é voltado para mapeamento geoespacial e oferece grande flexibilidade e desempenho no processamento de soluções de realidade aumentada (DE PAOR; WHITMEYER; BENTLEY, 2016). Diferentemente da utilização de uma abordagem de visualização de um ponto no globo em uma perspectiva oblíqua, criamos também uma visualização baseada nos parâmetros das câmeras existentes no mundo real, permitindo a formação de uma perspectiva panorâmica de visualização do cenário marítimo.

A calibração da câmera no mundo virtual utilizando parâmetros do mundo real é uma solução importante para obter uma visualização realista do cenário marítimo. Ao usar os parâmetros corretos, como ângulo de visão, distorção da lente e posição da câmera, é possível simular a visualização a partir de uma câmera real.

Essa abordagem permite que você obtenha uma perspectiva mais imersiva e precisa do ambiente marítimo no mundo virtual. Em vez de depender exclusivamente de imagens de satélite, que são difíceis de ser processadas em decorrência do tamanho das imagens e da

⁵ <https://cesiumjs.org/>

difficuldade de obtê-las, é possível representar o cenário com mais realística e mais factível devido as atuais condições encontradas no cenário marítimo brasileiro, considerando as mesmas condições de uma câmera existente no mundo real. A Figura 10 apresenta a diferença entre as visualizações entre a perspectiva da câmera (panorâmica) e uma perspectiva da área (oblíqua).



Figura 10 - Visualização de Diferentes Perspectivas em Realidade Aumentada.

Conforme podemos observar na Figura 10, os retângulos amarelos representam os registros de embarcação existentes no mundo virtual, consolidados anteriormente. Esses retângulos são uma representação visual das embarcações, incluindo suas dimensões. A cor amarelo, utilizada para representar as embarcações, foi selecionada para destacar e identificar os retângulos que representam as embarcações na interface de realidade virtual. Cada retângulo amarelo representa uma embarcação específica, identificada pelo seu número MMSI. Além do MMSI, outros atributos como o nome da embarcação, sua localização geográfica e seu tamanho foram utilizados para criar uma representação visual das embarcações no mundo virtual.

Essa representação visual dos registros de embarcação consolidados permite uma melhor compreensão e visualização dos dados. Os retângulos amarelos ajudam a identificar rapidamente a localização das embarcações no mapa e fornecem uma representação intuitiva das suas dimensões. Essa abordagem permite explorar os dados de forma interativa na interface de realidade virtual, facilitando a análise espacial, o acompanhamento de movimentos das embarcações e outras tarefas relacionadas à visualização do tráfego marítimo brasileiro.

4.2.2. *Visão Computacional*

Neste trabalho as atividades relacionadas à visão computacional desempenham um papel fundamental na detecção automática de embarcações, por meio da utilização de algoritmos e técnicas de processamento de imagem para analisar dados visualmente e, em tempo real, as imagens de câmeras no ambiente marítimo e detectar as embarcações presentes no momento.

São empregados algoritmos de classificação para distinguir as embarcações de outros elementos presentes nas imagens, eliminando ruídos. Esses algoritmos podem se basear em características como forma, cor, textura e tamanho das embarcações para realizar a classificação. A detecção automática de embarcações em tempo real permite monitorar o tráfego marítimo, contribuindo no aprimoramento do controle do tráfego marítimo mediante a ampliação da MDA. A Figura 11, representa as atividades que foram utilizadas nesta etapa.

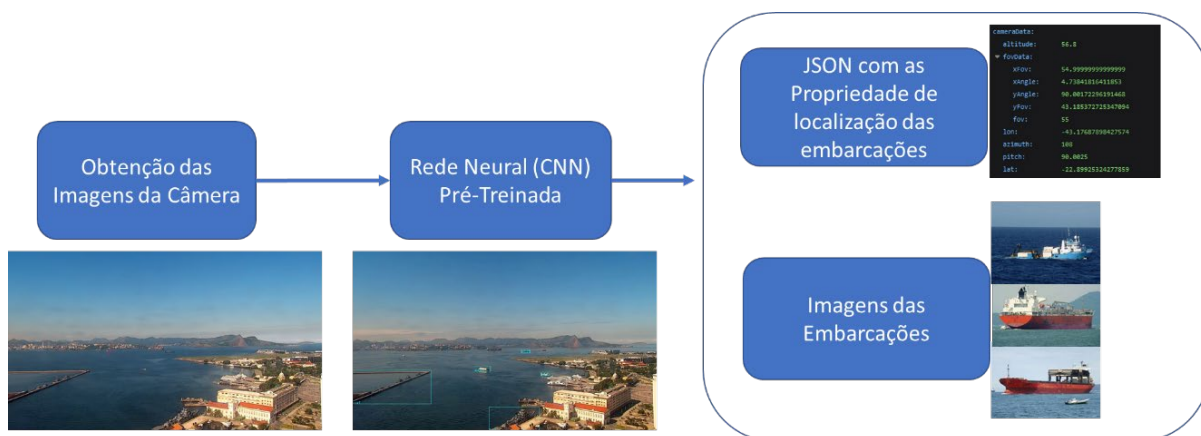


Figura 11 - Fluxo de Atividades da Etapa de Visão Computacional.

Inicialmente, foi necessário criar uma aplicação de obtenção do fluxo (*streaming*) da câmera. Originalmente, as imagens trafegam na rede utilizando o RTSP (*Real-Time Streaming Protocol*). Esse fluxo é convertido utilizado como entrada de imagens para a CNN pré-treinada com imagens públicas de embarcação e modelos de rede. Utilizando a coleção de dados público que contém imagens de embarcação, denominada de COCO⁶ (*Common Objects in Context*), fornecido pela empresa Microsoft.

A rede neural YOLOv5 foi a escolha deste trabalho devido sua capacidade de detecção de embarcações devido à sua velocidade em tempo real, alta precisão na detecção e capacidade de detectar múltiplos objetos. Além disso, o YOLO oferece flexibilidade para treinamento em diferentes conjuntos de dados, o que o torna uma opção eficiente para aplicações de detecção de embarcações. Sua precisão e acurácia na detecção de objetos, incluindo embarcações, permitem identificar e delimitar com precisão a localização das embarcações na imagem, proporcionando uma detecção confiável.

Contudo, diferentes redes YOLOv5 podem ser encontradas. As principais são a YOLOv5s (*Small*), a YOLOv5m (*Medium*) e a YOLOv5l (*Large*). A YOLOv5s é a versão mais

⁶ <https://cocodataset.org/>

leve do YOLOv5, projetada para oferecer uma detecção rápida e eficiente em dispositivos com recursos limitados. Ela tem um desempenho mais baixo em termos de precisão, mas é ideal para casos em que a velocidade é um fator crítico. A YOLOv5m é a versão que oferece um equilíbrio entre precisão e velocidade. Ela tem um desempenho melhor em relação à versão *small* em termos de acurácia, mas ainda mantém uma boa velocidade de detecção.

A YOLOv5l é uma versão mais poderosa que possui maior capacidade de detecção e acurácia em comparação com as versões *small* e *medium*. No entanto, ela é mais lenta em relação à velocidade de detecção.

A escolha da YOLOv5 para este trabalho levou em consideração diversos aspectos. Primeiramente, foram analisados os requisitos específicos do projeto, como velocidade de processamento, precisão de detecção e recursos computacionais disponíveis. Além disso, o conjunto de dados utilizado para o treinamento, no caso da coleção de imagens (*dataset*) COCO, foi considerado para verificar a compatibilidade e desempenho das diferentes versões da YOLOv5.

Visando a realização de uma experimentação que auxilie na escolha do modelo adequado da YOLOv5 para o trabalho em questão, foi desenvolvido um *Dashboard Web* interativo. Essa ferramenta permite a manipulação e seleção das principais configurações relacionadas à detecção de objetos, visando subsidiar a escolha do modelo YOLOv5 a ser utilizado.

O *Dashboard* proporciona a possibilidade de ajustar diferentes configurações, das três versões disponíveis da YOLOv5 (*small*, *medium* e *large*). Além disso, é possível personalizar parâmetros importantes como os limiares de confiança e a interseção sobre união (IoU), conforme ilustrado pela Figura 12. Ao utilizar o *Dashboard*, é possível explorar de forma interativa essas configurações, fornecendo uma análise mais detalhada dos resultados obtidos, facilitando a seleção do modelo YOLOv5 mais apropriado além de ajustar e otimizar a detecção de objetos e contribuindo na busca de um modelo adequado para o cenário apresentado.

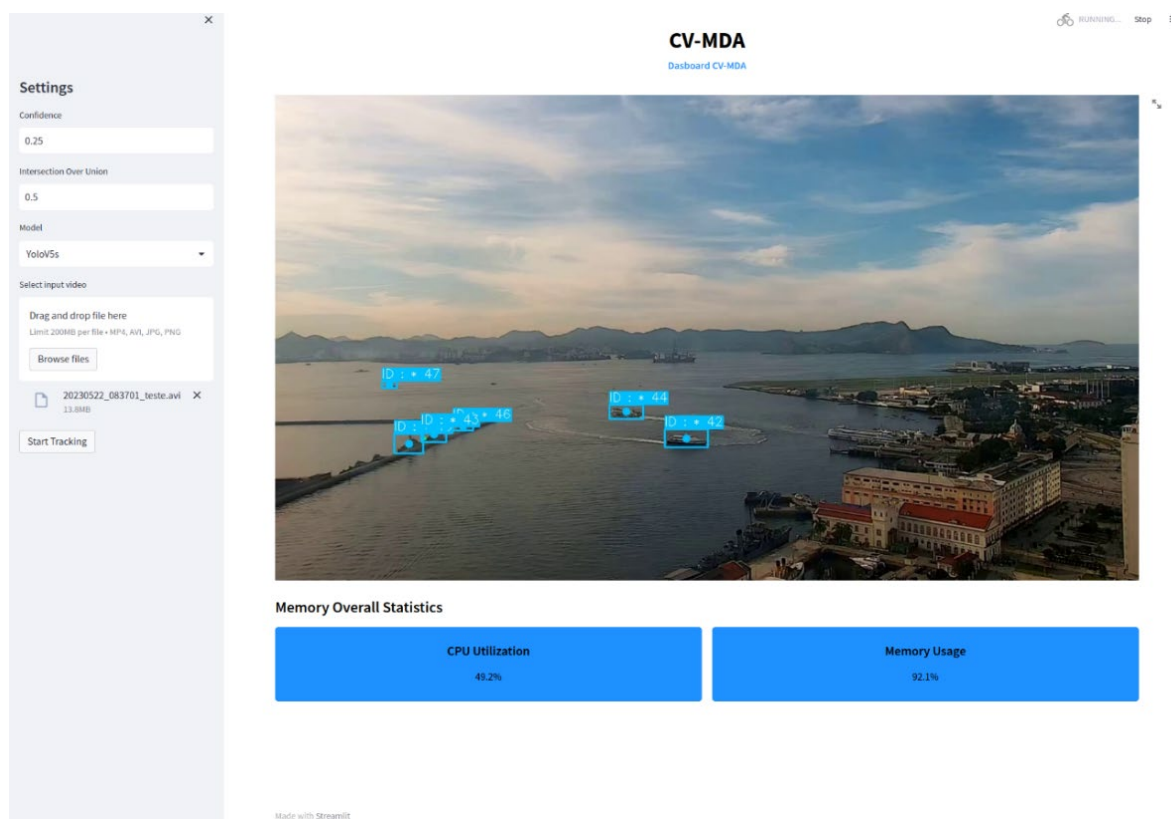


Figura 12 - Dashboard de Ajuste do Modelo.

Usando o *Dashboard CV-MDA*, é possível encontrar o modelo adequado para este trabalho e configurá-lo de forma a obter resultados satisfatórios na detecção de embarcações, considerando os recursos computacionais disponíveis e o cenário em questão. Nesse sentido, a escolha da versão levou em consideração os requisitos do projeto e o desempenho observado nos experimentos, buscando a combinação ideal entre velocidade, precisão e adequação aos dados utilizados.

É importante ressaltar que a escolha do modelo da YOLOv5 pode variar de acordo com as necessidades e especificidades de cada projeto, portanto, é recomendável realizar experimentos e avaliações para determinar qual versão melhor atende aos requisitos específicos.

A partir do experimento realizado, considerando as especificidades de processamento em tempo real (*streaming*) e os recursos computacionais disponíveis, foi decidido utilizar a versão intermediária da YOLOv5, conhecida como YOLOv5m. Essa escolha foi feita levando em consideração um equilíbrio entre desempenho da detecção e recursos computacionais.

Conforme o experimento realizado, devido às especificidades e recursos computacionais, optamos pela utilização de uma versão intermediária, ou seja, a versão

YOLOv5m. No entanto, ressaltamos que para a utilização YOLOv5 com outros recursos computacionais é recomendável realizar novos experimentos e avaliações específicas para determinar a versão mais adequada.

O resultado do *streaming* de vídeo, após a detecção de embarcações, é disponibilizado em um servidor web dedicado, que foi especialmente configurado para publicar os resultados por meio do protocolo HTTP (*Hypertext Transfer Protocol*). O servidor web é responsável por receber o vídeo resultante da detecção, processá-lo e disponibilizá-lo de forma acessível para os usuários. Isso permite que os resultados da detecção de embarcações sejam transmitidos em tempo real ou sob demanda, por meio de um navegador web ou outros dispositivos conectados à Internet.

O uso do protocolo HTTP torna o *streaming* de vídeo acessível em diferentes dispositivos e plataformas, permitindo que os resultados da detecção de embarcações sejam compartilhados e visualizados de forma conveniente e amplamente distribuída, contribuindo para a ampliação da MDA.

Implementamos uma solução para delimitar as embarcações detectadas, utilizando caixas de delimitação (*boundary boxes*). Essas caixas de delimitação representam visualmente a localização das embarcações nas imagens e permitem uma identificação mais precisa. Além disso, as imagens das embarcações são armazenadas e as informações contextuais, como a posição da embarcação na imagem, são armazenadas em formato JSON, permitindo que as informações contextuais da imagem sejam facilmente acessadas, manipuladas e compartilhadas entre diferentes sistemas.

4.3. Camada de Anotação Automática

4.3.1. Interseção e Sobreposição de Camadas

A interseção/sobreposição de camadas neste trabalho é necessária para estabelecer relação entre as embarcações no mundo real (câmera) e o mundo virtual (realidade aumentada), permitindo a fusão entre os dados contextuais de ambas as camadas. Para a consecução desta atividade, utilizamos uma técnica de “colisão” entre o mundo virtual e as imagens da câmera denominada de *Ray Picking* (LEE; JANG, 2018). A “colisão” refere-se à atividade de interseção/sobreposição entre as embarcações detectadas na camada de visão computacional e as embarcações (registros de embarcações) da camada de realidade aumentada.

Existem diversos modelos que podem ser utilizados para realizar a interseção/sobreposição de camadas, como o *Ray Picking* e o *Pin-hole*. Contudo, observamos

que o modelo *Pin-hole* (RICOLFE-VIALA; SÁNCHEZ-SALMERÓN, 2011) não está totalmente à interseção ou sobreposição de camadas, mas está mais adequado apenas na projeção de objetos tridimensionais em uma imagem bidimensional. A escolha do *Ray Picking* em detrimento do modelo *Pin-hole*, neste trabalho foi baseada na necessidade de uma interação interativa e precisa com objetos em um ambiente 3D, na flexibilidade na seleção de objetos, na eficiência da implementação e na busca por uma experiência intuitiva e imersiva para o usuário. As etapas principais do processo de *Ray Picking* utilizadas neste trabalho estão:

- Geração do raio: O raio é gerado a partir de uma posição específica no espaço real, como as coordenadas de um ponto de origem, como a posição do cursor do mouse ou as coordenadas das embarcações detectadas e pré-classificadas pela camada de visão computacional.

- Conversão do raio: O raio é convertido do mundo real para o mundo virtual, alinhando-o com a cena 3D da camada de realidade aumentada. Isso envolve a transformação das coordenadas do raio para o sistema de coordenadas da camada de realidade aumentada.

- Verificação de interseção: O raio é verificado para determinar se atinge os objetos 3D na câmera de realidade aumentada. Isso permite estabelecer uma relação ou fusão entre as camadas, identificando quais objetos foram atingidos pelo raio.

Estas etapas permitem a interação entre o mundo real e o mundo virtual, possibilitando estabelecer uma relação de interseção da camada de realidade aumentada com base em interações provenientes da camada de visão computacional.

Para a realização das atividades de geração do raio e conversão entre as camadas, criamos um código, representado pela Figura 13, que recebe como entrada as coordenadas cartesianas do pixel desejado, juntamente aos valores máximos e mínimos da imagem, o campo de visão da câmera, a inclinação da câmera em relação ao plano, a altura da câmera, as coordenadas geográficas e a orientação em relação ao norte geográfico (azimute).

```

double pixelWidthInv = imageWidth - pixelWidth;
double yawAngleInv = 180 - yawAngle;
double yawRadians = Math.toRadians(yawAngleInv);
aspectRatio = imageWidth / imageHeight;
double fov = Math.toRadians( cameraFov );
yFov = 2 * Math.atan( Math.tan( fov / 2 ) * 1 / aspectRatio );
double newAspectRatio = aspectRatio * Math.tan(yFov / 2);
double yAngle = Math.toRadians(0.5 * yFov - ((pixelHeight + 0.5) / imageHeight - 0.5) * yFov + pitchAngle);
xFov = 2 * Math.atan( Math.tan( fov / 2 ) );
xAngle = Math.toRadians( ( pixelWidthInv / imageWidth - 0.5 ) * xFov * 180 / Math.PI );
double[] direction = new double[] { -Math.sin(xAngle), Math.cos(xAngle) * Math.sin(yAngle), Math.cos(xAngle) * Math.cos(yAngle) };
double[][] rotationMatrix = new double[][] {
    {Math.cos(yawRadians), -Math.sin(yawRadians), 0},
    {Math.sin(yawRadians), Math.cos(yawRadians), 0},
    {0, 0, 1}
};
};
double[] result = new double[3];
for (int i = 0; i < 3; i++) {
    double sum = 0;
    for (int j = 0; j < 3; j++) {
        sum += rotationMatrix[i][j] * direction[j];
    }
    result[i] = sum;
}
direction = result;
double[] worldCoords = new double[3];
double multiplier = cameraHeight / Math.tan(yAngle) * newAspectRatio / aspectRatio;
double distanceLon = ( direction[0] * multiplier ); // Em grau decimal
double distanceLat = ( direction[1] * multiplier ); // Em grau decimal

worldCoords[0] = cameraPosition[0] + distanceLon; // Longitude
worldCoords[1] = cameraPosition[1] + distanceLat; // Latitude
worldCoords[2] = 0; // Altitude

```

Figura 13 - Código de Geração e Aplicação do Raio entre as Camadas.

Neste trabalho, na realização da atividade de verificação de interseção entre as camadas, foram inseridas duas maneiras de lançamento do raio, a primeira é manual e nos permite entender o comportamento da solução no nosso cenário. O usuário clica em uma determinada região da imagem da câmera, disponibilizada pelo servidor web criado para este trabalho. A Figura 14 apresenta a geração do raio e a conversão de três distintos pontos da camada de visão computacional em o raio correspondente na camada de visão aumentada.




Figura 14 - Exemplo com Três Raios de Interseção.

A segunda etapa é realizada de forma automática, utilizando as caixas de delimitação das embarcações previamente classificadas. Uma vez que os barcos estão sempre localizados na água e o plano do solo pode ser definido como o nível da água, a posição de um barco detectado pode ser definida pelo ponto central mais baixo da caixa delimitadora estimada, desconsiderando a altura dos objetos em relação ao solo SIMONSEN et al. (2020). A Figura 15 ilustra a segunda etapa.




Figura 15 - Detecção da Embarcação Indicada pela Caixa Delimitadora.

O ponto em amarelo representa a posição estimada da embarcação no mar e é utilizado para estabelecer a interseção entre a visão computacional em o raio correspondentes na camada de visão aumentada, fornecendo uma estimativa da posição da embarcação. Posteriormente, com o objetivo de melhor compreender o comportamento da interseção de um raio entre as camadas de visão computacional e realidade aumentada, manualmente selecionamos um ponto conhecido no mundo real e verificamos sua respectiva correspondência no mundo virtual, representado pela Figura 16.




Figura 16 - Verificação de Interseção das Camadas.

Após analisar Figura 16, verificamos que a formação do raio no mundo virtual não produziu os resultados esperados. No entanto, notamos que o erro está mais relacionado à

profundidade do objeto do que à sua largura. É importante ressaltar que o objeto se aproximou significativamente do alvo lateralmente.

Realizamos um novo teste/experimento para verificar a capacidade da solução em realização a “colisão” entre as embarcações. Conforme apresentado pela Figura 17, constatamos que a projeção do raio, ao clicar na imagem da câmera na embarcação “B”, resultou em um cálculo incorreto da posição geográfica do pixel desejado na realidade virtual, não sendo suficiente para determinar qual a embarcação corresponde ao alvo desejado, neste caso a embarcação “GAVEA”.



Figura 17 - Verificação de Interseção das entre Duas Embarcações.

Constatamos que o método utilizado se mostrou ineficiente em calcular corretamente a distância do pixel em relação à posição geográfica da câmera, optamos por uma solução adaptativa ao método de *Ray Picking*. Considerando que os resultados da linha de visão estavam melhor espacialmente ajustados em direção ao alvo (a embarcação “GAVEA”) e que a falha na estimativa estava principalmente relacionada à estimativa da distância.

4.3.2. Estimativa Adaptativa de Distância (Geohash)

Em detrimento dos resultados encontrados no *Ray Picking*, propomos a utilização de uma abordagem não determinística de estimativa para determinar a distância dos alvos (na realidade aumentada), levando em consideração que a linha de visada estava correta em direção e que a imprecisão estava restrita à distância.

Neste trabalho, foi adotada uma abordagem adaptativa de estimação de distância com o objetivo de criar uma estrutura para apoiar na estimação da distância do raio até o objeto selecionado, para distinguir a embarcação intersectada “colisão” entre cenário marítimo com a presença de outras embarcações, mais próximas ou mais distantes do alvo. Essa abordagem permite ao usuário selecionar entre uma estimativa de distância mais específica ou mais abrangente, dependendo das necessidades e do contexto da situação.

A estimação de distância desempenha um papel importante na identificação de possíveis colisões entre a embarcação em foco e outras embarcações nas proximidades. A abordagem adaptativa utilizada neste trabalho oferece uma maior flexibilidade, permitindo que escolha o nível de precisão da estimativa de distância desejada. Isso significa que é possível optar por uma estimativa mais precisa e específica. Por outro lado, também é possível escolher uma estimativa mais abrangente, que considera uma margem de segurança maior e leva em conta uma área de influência mais ampla ao determinar a distância do raio até o objeto selecionado.

Essa abordagem adaptativa proporciona uma maior flexibilidade e controle ao usuário, permitindo que ele ajuste a estimativa de distância de acordo com a situação e o nível de precisão desejado, contribuindo para uma melhor compreensão do cenário marítimo. Neste trabalho, para a utilização/implementação da abordagem adaptativa foi necessária a execução de 2 passos, a construção de uma estrutura hierárquica no mundo virtual e a codificação do raio (*Ray Picking*).

O primeiro passo consiste em utilizar/construir uma estrutura hierárquica para organizar/estruturar o mundo virtual (realidade aumentada) em diversas granularidades de delimitação e visualização espacial. Semelhante ao processo de geocodificação dos registros de navegação, apresentados na Camada de Dados, utilizamos uma solução derivada do *Geohash*, o *Geohash Grid* (GUO et al., 2019).

O *Geohash grid* é formado pelo particionamento e subdivisão do espaço geográfico em células retangulares de tamanho fixo. No contexto do *Geohash*, utilizamos o método o “Z-order”, aplicado para atribuir uma ordem linear aos códigos *Geohash*. Ele é usado para organizar as células *Geohash* em uma sequência que preserva a proximidade espacial. Isso significa que duas células *Geohash* que são vizinhas no Z-order também são vizinhas no espaço geográfico, reduzindo o número de comparações necessárias para identificar vizinhos ou realizar buscas em uma área específica (ZHOU et al., 2017).

As células são formadas progressivamente de maneira *top-down*, ampliando a granularidade e a abstração ou *bottom-up* reduzindo a granularidade e a abstração. A Figura 18 exemplifica o processo de particionamento e divisão do espaço para a formação das células na granularidade (nível) 2 e 3 respectivamente.




Figura 18 - Subdivisão da área em Geohash, adaptado de GUO et al. (2019).

A Tabela 5 sumariza a relação de coberturas das células em *Geohash* em diversos níveis de comprimento (granularidade), o número de bits usados para latitude e longitude, o erro correspondente em latitude e longitude e o erro aproximado em quilômetros.

Tabela 5 - Delimitação Espacial do *Geohash*

Comprimento (granularidade) do Geohash	Bits de Latitude	Bits de Longitude	Erro de Latitude	Erro de Longitude	Erro em Quilômetros
1	2	3	±23	±23	±2.500 km (1.600 mi)
2	5	5	±2,8	±5,6	±630 km (390 mi)
3	7	8	±0,70	±0,70	±78 km (48 mi)
4	10	10	±0,087	±0,18	±20 km (12 mi)
5	12	13	±0,022	±0,022	±2,4 km (1,5 mi; 2.400 m)
6	15	15	±0,0027	±0,0055	±0,61 km (0,38 mi; 610 m)
7	17	18	±0,00068	±0,00068	±0,076 km (0,047 mi; 76 m)
8	20	20	±0,000085	±0,00017	±0,019 km (0,012 mi; 19 m)

Essa abordagem de integração de geocodificação *geohash* (geocódigo) com realidade virtual proporciona uma nova perspectiva na análise e visualização de dados espaciais, permitindo uma melhor compreensão dos padrões de navegação e facilitando a tomada de decisões informadas no contexto marítimo. A Figura 19 apresenta um exemplo da estrutura hierárquica do mundo virtual em células *Geohash* com uma granularidade de níveis.



Figura 19 - Geocodificação do Mundo Virtual.

Podemos observar na Figura 20, traçando uma linha histórica, que neste trabalho iniciamos com o mundo real (visão computacional) utilizando os *pixels* das imagens, posteriormente na camada virtual (realidade aumentada) os *pixels* utilizados em conjunto com as coordenadas geográficas (latitude e longitude) e por final na abordagem adaptativa de estimação de distância os *pixels* e as coordenadas são utilizados em conjunto um geocódigo que representa uma determinada região (célula) espacial.

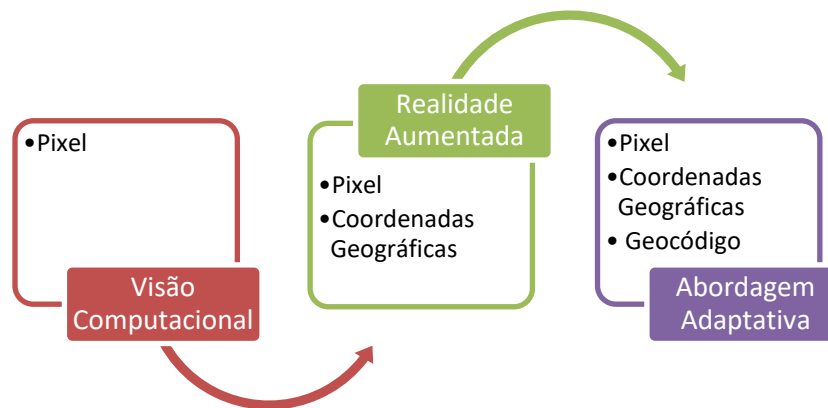


Figura 20 - Linha Histórica até a Abordagem Adaptativa.

O segundo passo da formação da abordagem adaptativa de estimação da distância está relacionado com a geocodificação do raio para a realização de interseções das células em uma determinada granularidade com os as embarcações (registros geocodificados). A Figura 21, ilustra a atividade de geocodificação do raio em duas diferentes granularidades, níveis de granularidade: 8, 7 e 6.

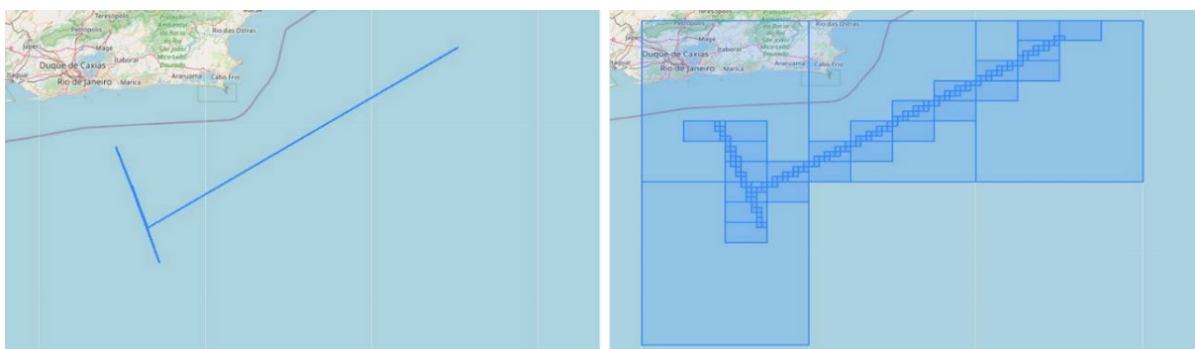


Figura 21 - Geocodificação do Raio em Três Granularidades.

Na Figura 22, é possível perceber que a granularidade do raio afeta a área de busca e cobertura no espaço geográfico. À medida que a granularidade do raio diminui, ou seja, o nível de codificação aumenta, o raio se torna mais restrito e preciso, abrangendo uma área geográfica menor. Isso significa que a busca por embarcações “candidatas” alvo será mais precisa, com uma área de interseção menor entre o raio e os registros de navegação.

Por outro lado, quando a granularidade do raio aumenta, ou seja, o nível de codificação diminui, o raio se torna mais generalista, abrangendo uma área geográfica maior. Isso significa que a busca por embarcações “candidatas” alvo será menos precisa, com uma área de interseção maior entre o raio e os registros de navegação.




Figura 22 - Área de Cobertura em Detrimento da Granularidade.

Conduzimos um experimento para analisar o impacto da granularidade das células dos raios na identificação das embarcações alvo, conforme apresentado na Tabela 6, na Figura 23, na Figura 24 e na Figura 25.

Tabela 6 - Experimento Granularidade do Raio.

Granularidade do Raio	Tamanho da célula (m ²)	Quantidade de células em cruzamento com o raio	Possíveis Alvos
8	19 metros quadrados	0	0
7	76 metros quadrados	2	2
6	610 metros quadrados	8	10




Nome	MMSI	Tipo	Lat	Lon	Desvio Az.	Ind.	Hash	Pixel	Azimute
------	------	------	-----	-----	------------	------	------	-------	---------

Figura 23 - Geohash do Raio Granularidade 8.



Nome	MMSI	Tipo	Lat	Lon	Desvio Az.	Ind.	Hash	Pixel	Azimute
ODN 1	311041200	Other	-22.910189	-43.14168	-1.28°	C6YP6	75cmdm34	210,111	108.64522725640211
URCA III	710019710	Passenger	-22.901356	-43.16702	4.33°	PS8854	75cm9uyt	2318,5460	103.03506477178234

Figura 24 - Geohash do Raio Granularidade 7.



Nome	MMSI	Tipo	Lat	Lon	Desvio Az.	Ind.	Hash	Pixel	Azimute
ODN 1	311041200	Other	-22.91022	-43.14172	-1.50°	C6YP6	75cmdm34	263,294	108.71249483608415
FUNIAO	710467000	MilitaryOps	-22.911974	-43.144573	-5.94°	PMJN	75cmdjpb	316,317	113.15137507677565
HARPIA	710128371	OtherNoAdditionalInfo	-22.902153	-43.171753	-14.35°	JC1402	75cm9wg3	609,332	121.55489388853391
INGA II	710102038	Passenger	-22.902565	-43.171528	-16.69°	PS8972	75cm9weq	604,329	123.89606694930775
CORCOVADO	710023770	Passenger	-22.902693	-43.171307	-16.62°	PR7637	75cm9weu	601,328	123.82578516639302
APOLO I	710102031	Passenger	-22.903105	-43.171055	-18.47°	PS6878	75cm9weg	596,324	125.67538640696188
NPA MARACANA	710487000	MilitaryOps	-22.897896	-43.17037	29.96°	PMWC	75cm9xs6	620,377	77.24865723623304
NPA WURUPA	709354424	SearchAndRescueVessel	-22.899416	-43.168533	15.99°	PMGE	75cm9xm9	356,25,257.23333740234375	91.21419636381108

Figura 25 - Geohash do Raio Granularidade 6.

A utilização do *Geohash* como uma seleção adaptativa no cenário marítimo demonstrou ser uma abordagem adequada. No entanto, é importante observar que podem ocorrer ambiguidades na seleção e interação da embarcação alvo, conforme ilustrado pela Figura 17 e Figura 24. Nessas figuras, é possível notar que, mesmo com a solução adaptativa de estimação de distância, ainda existem embarcações adicionais que são consideradas “candidatas” a serem o alvo. Essas embarcações podem estar mais próximas ou mais distantes do alvo, o que pode levar a interpretações errôneas ou imprecisas.

No entanto, a utilização da solução adaptativa de estimação de distância auxilia na redução dessas embarcações candidatas, fornecendo uma estimativa de distância mais específica ou mais abrangente, de acordo com a escolha do usuário. Essa abordagem permite uma melhor compreensão do cenário marítimo e ajuda a distinguir a embarcação intersectada (“colisão”) entre as demais embarcações presentes na área.

É importante destacar que, apesar das ambiguidades apresentadas, a solução adaptativa ainda traz benefícios ao reduzir o número de candidatos e proporcionar uma estimativa de distância mais refinada. Isso pode auxiliar nas decisões e análises relacionadas à segurança marítima e evitar possíveis colisões.

Com o objetivo de aprimorar os resultados da estimativa de distância e refinar os resultados encontrados para eliminar as ambiguidades (embarcações candidatas) na interseção/colisão e possibilitar encontrar a embarcação alvo, utilizamos cálculos de distância angular. O cálculo de distância angular é realizado levando em consideração a distância angular entre o raio e as embarcações que obtiveram intersecção no *Geohash*.

A distância angular é um parâmetro crucial para eliminar ambiguidades na determinação da embarcação-alvo. A distância é calculada com base na diferença angular entre as embarcações “candidatas” em relação ao raio, servindo com ponto de referência. A Figura 26 mostra a distância angular. Essa medida pode variar de -180° a 180° , sendo 0° a distância angular mínima. Um valor próximo de zero indica que os objetos estão alinhados na mesma direção, enquanto valores maiores ou menores indicam uma maior separação angular.

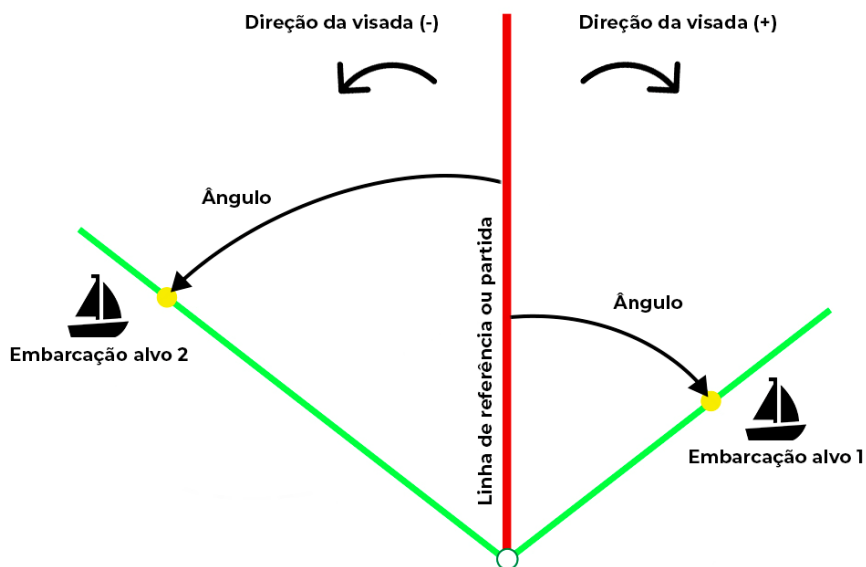


Figura 26 - Distância Angular entre as Embarcações e o Raio.

Para realizar o cálculo da distância angular em coordenadas geográficas (em graus), podemos adotar a seguinte situação hipotética:

EC_1 (lat_1, lon_1) a localização da embarcação candidata 1, EC_2 ($lat_2, long_2$) a localização da embarcação candidata 2 e O ($lat_0, long_0$) a localização da visada da câmera (ponto de referência).

A distância angular entre as duas embarcações em relação ao ponto de referência pode ser calculada usando a seguinte fórmula:

$$\theta = atan2(\sin(long_2 - long_0) * \cos(lat_2), \cos(lat_1) * \sin(lat_2) - \sin(lat_1) * \cos(lat_2) * \cos(long_2 - long_0)),$$

Onde $atan2$ é uma função trigonométrica arcotangente de dois argumentos, que retorna o ângulo no intervalo $[-180^\circ, 180^\circ]$ formado pelos argumentos. Nessa fórmula, as coordenadas geográficas estão em graus e a função trigonométrica seno(\sin) e cosseno(\cos) devem receber os ângulos em radianos. Portanto, antes de aplicar a fórmula, é necessário converter as coordenadas geográficas de graus para radianos.

Considerando o exemplo apresentado pela Figura 24, com duas embarcações “candidatas” representadas pelas duas linhas na cor verde e o raio representado pela linha na cor vermelha, após realizado o cálculo da distância angular teremos uma visualização conforme apresentada na Figura 27.



Figura 27 - Visualização da Distância Angular entre as Embarcações “A” e “B”.

A Figura 28 apresenta um o fluxo visual entre as etapas de visão computacional, realidade aumentada e a anotação automática, representada pela estimativa de distância (distância angular). No entanto, é importante destacar que essa estimativa de distância angular não reflete diretamente a distância física entre os objetos, mas sim a relação angular entre eles. Portanto, outras análises devem ser realizadas para uma compreensão mais completa das distâncias reais e das possíveis colisões no cenário marítimo.



Figura 28 - Visão Computacional x Realidade Aumentada e Estimativa de Distância.

A abordagem de estimativa de distância angular apresentou eficiência na maioria dos casos, com exceção daqueles em que duas embarcações ocupam exatamente a mesma posição na linha traçada. Nessas situações, é difícil determinar, com certeza, qual embarcação foi selecionada ao clicar na imagem da câmera, devido à sobreposição das duas embarcações.

No entanto, nos demais casos em que as embarcações estão próximas, mas não sobrepostas, o método mostrou-se eficiente. Isso significa que mesmo quando duas ou mais

embarcações estão muito próximas relativamente na imagem da câmera, o método conseguiu identificar corretamente as embarcações alvo.

No geral, o método utilizado demonstrou eficiência na maioria das situações, proporcionando uma interação interativa e precisa entre as embarcações em um ambiente virtual. A sobreposição exata de embarcações na imagem da câmera representa um caso específico que requer considerações adicionais para melhorar a precisão da seleção. Contudo, a utilização de estratégias de como a anotação semiautomática de embarcações pode ser utilizada para refinar as anotações realizadas automaticamente, possibilitando a anotação precisa e detalhada das embarcações que não podem ser anotadas automaticamente devido a circunstâncias específicas. Além disso, a anotação semiautomática pode apoiar na anotação de embarcações que não possuem registros de navegação ou por alguma situação adversa suas informações contextuais não estão disponíveis.

4.4. Camada de Anotação Semiautomática

A camada de anotação semiautomática possibilita anotar de maneira semiautomática as imagens de embarcações que não foram anotadas automaticamente. Devido às circunstâncias específicas como a falta de registros de navegação ou a suspeitas de ilícitos ou crimes, algumas embarcações (tipos) podem não ter sua representatividade na coleção de dados formado neste trabalho, podendo comprometer a variedade das imagens que compõem a coleção de imagens de navegação.

Neste trabalho, a atividade de anotação automática consiste em utilizar os dados automáticos como entrada para criar um modelo contextual que apoie na identificação das embarcações que não foram automaticamente anotadas. Posteriormente, utilizando uma solução de *Crowdsourcing*, proposta por este trabalho, as pessoas (multidão) realizam a avaliação das predições dos tipos de embarcação para o armazenamento ou descarte das imagens, a Figura 29 apresenta o fluxo desta atividade.

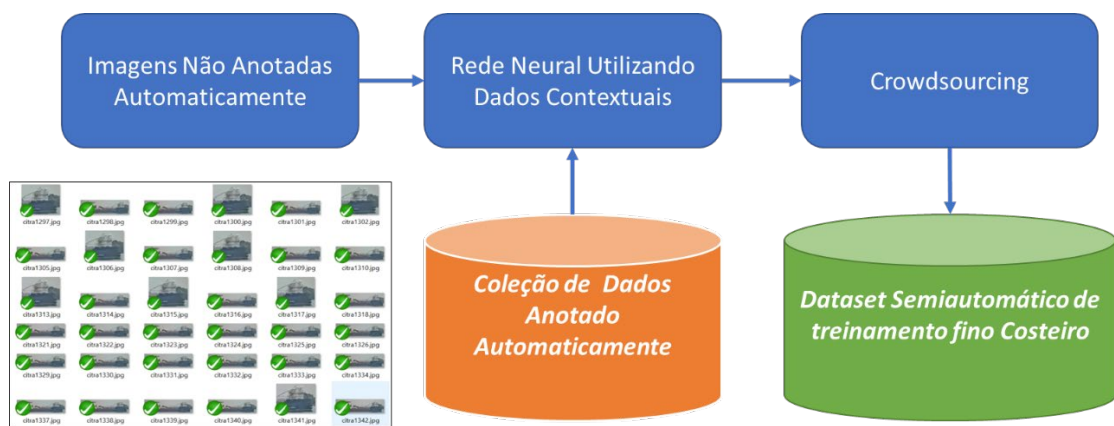


Figura 29 - Fluxo de Anotação Semiautomática.

5. O ARCABOUÇO TECNOLÓGICO CV-MDA

QP5: Como a criação de uma coleção de imagem contextual e fino pode contribuir na ampliação da MDA?

Neste capítulo, apresentamos o arcabouço CV-MDA, projetado para enfrentar o desafio de criação de coleções de dados automaticamente e semiautomaticamente para apoiar na detecção de embarcações, contribuindo para a ampliação da MDA.

Com o intuito de ilustrar a solução proposta neste trabalho, neste capítulo são apresentados cenários ilustrativos que permitem apoiar na compreensão tanto da importância quanto a aplicabilidade deste trabalho no apoio da ampliação da MDA. Posteriormente, demonstramos como o *framework* CV-MDA é capaz de cumprir os objetivos propostos neste trabalho para realizar a atividade de anotação automática e semiautomática de embarcações em um cenário real da Marinha do Brasil.

5.1. Instâncias dos Cenários Ilustrativos

Nesta seção, exploraremos diversas situações que servirão como ilustrações dos elementos apresentados neste trabalho, utilizando instancias ilustrativas de diversos cenários encontrados pela autoridade marítima. Estas instâncias são essenciais para uma compreensão mais profunda e aplicada do tema em questão, pois oferecem *insights* valiosos sobre como as teorias e abstrações se traduzem na realidade. Através da análise das instâncias dos cenários ilustrativos, buscamos enriquecer nossa compreensão e promover discussões informadas sobre as aplicações e implicações práticas das ideias apresentadas neste trabalho.

5.1.1. Instância do Cenário Ilustrativo 1: Identificação de Embarcação Suspeita

O cenário hipotético 1 inicia quando uma embarcação da Marinha do Brasil, avista uma embarcação com uma bandeira suspeita. O comandante desta embarcação solicita ao centro de controle de tráfego marítimo mais informações sobre a embarcação, passando as coordenadas. Utilizando a solução de Realidade Aumentada do CV-MDA, o operador de tráfego verifica que não possui nenhum registro de navegação para aquela localidade. O operador ainda verifica no sistema *Marine Traffic* a existência de um registro de navegação naquela localização, contudo sem sucesso.

Utilizando a solução de Visão Computacional, podemos ver que essa embarcação desconhecida foi detectada e suas imagens foram coletadas (armazenadas). As imagens foram

submetidas a um sistema de detecção de embarcações que utiliza a coleção de dados criado automaticamente e semiautomaticamente do *framework* CV-MDA. Atividade de detecção utilizando a coleção de dados criado automaticamente permite identificar a embarcação.

5.1.2. Instância do Cenário Ilustrativo 2: Identificação de Discrepância

A região portuária do Rio de Janeiro é conhecida como uma área com um intenso tráfego marítimo, conhecida por ser uma rota de comércio movimentada e por atrair atividades pesqueiras. A autoridade marítima realiza atividade de monitoramento desta região para garantir a segurança marítima, evitar a pesca ilegal e identificar outras atividades suspeitas.

Durante uma análise do tráfego marítimo, o operador de tráfego observou uma discrepância significativa entre o número esperado de embarcações com base nas rotas comerciais e nos registros de navegação e o número real de embarcações detectadas pelo sistema de monitoramento de câmeras. A discrepância indica que há mais embarcações presentes na região do que o esperado.

Tendo encontrada essa discrepância, a autoridade marítima pode conduzir, em tempo real, uma resposta imediata para identificar a presença de atividades suspeitas, como embarcações não identificadas, embarcações não conformes com as regulamentações ou até mesmo atividades ilegais, como pesca ilegal ou contrabando de mercadorias.

5.1.3. Instância do Cenário Ilustrativo 3: Identificação do Tipo de Embarcação

Um navio petroleiro está programado para atracar no porto do Rio de Janeiro. No entanto, devido a um erro de classificação, ele é designado para uma área de ancoragem inadequada, que não possui a infraestrutura e os equipamentos necessários para lidar com embarcações desse tamanho. Essa classificação incorreta resulta em atrasos significativos e dificuldades operacionais, causando um impacto negativo nas operações realizadas em todo o porto.

Considerando que a classificação do tipo da embarcação fosse correta, os resultados encontrados no cenário hipotético seriam completamente diferentes. Com a classificação adequada, o navio petroleiro seria direcionado para a área de ancoragem adequada as suas dimensões, onde a autoridade marítima poderia prover os recursos necessários para lidar com embarcações deste tipo.

O cenário hipotético apresentado destaca a importância da classificação correta do tipo de embarcação para a ampliação da MDA. A classificação adequada do tipo de embarcação

proporciona à autoridade marítima uma base informacional para ser empregada em diversas atividades marítimas.

5.2. Utilização do Arcabouço

Demonstrar a aplicabilidade da criação de uma coleção de imagens contextual e fina pode ser complicado sem realizar a detecção de embarcação porque a detecção de embarcação é uma aplicação tangível e visível das coleções de imagens anotadas, é uma tarefa com resultados visualmente identificáveis, o que torna mais fácil para as pessoas entenderem a importância da criação e utilização de coleções de imagens.

No entanto, conforme descrito neste trabalho, a criação de uma coleção de dados vai além da detecção de objetos e é um processo fundamental em várias áreas: realidade aumentada, visão computacional, fusão de dados, *crowdsourcing* e pesquisas em geral. Na Tabela 7, foi relacionado as diversas áreas utilizadas no *framework* CV-MDA que apoiam a realização das atividades relacionadas à detecção/identificação de embarcações nos três cenários hipotéticos apresentados anteriormente.

Tabela 7 - Utilização do CV-MDA em Cenários Hipotéticos.

Cenário Ilustrativo	Camadas do Framework CV-MDA			
	Realidade Aumentada	Visão Computacional	Anotação Automática	Anotação Semiautomática
Instância do Cenário Ilustrativo 1		X		X
Instância do Cenário Ilustrativo 2	X	X	X	
Instância do Cenário Ilustrativo 3	X	X	X	

5.2.1. Instância do Cenário 1 utilizando o CV-MDA

Ao utilizar o *framework* CV-MDA com o modelo pré-treinado de detecção utilizando na camada de visão computacional, foi identificado (quadrado amarelo) a presença de uma embarcação. Contudo, conforme apresentado na Figura 30 (mapa) não existe registro de navegação naquela localidade. Esta situação sugere a possibilidade de que não haja registros de navegação para aquela embarcação.

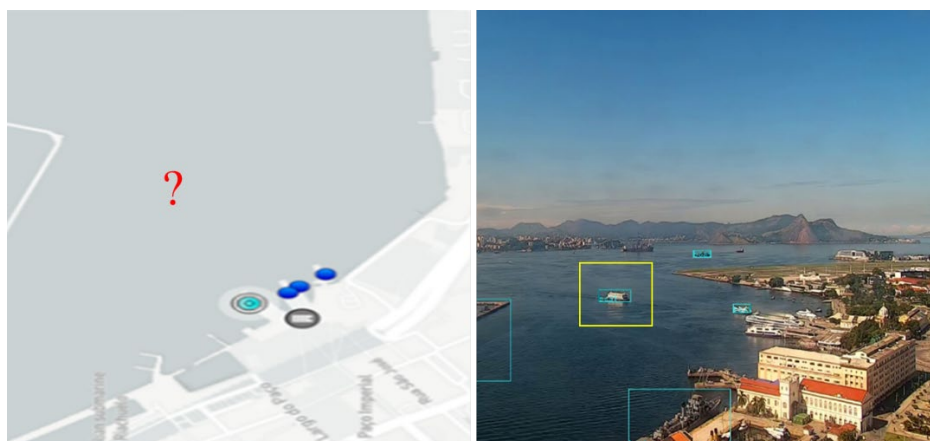


Figura 30 - Ausência de Registro de Navegação da Embarcação.

A imagem da embarcação é submetida ao modelo de anotação automático, contudo devido não ter registro de navegação relacionado, esta imagem não pode ser automaticamente anotada. A imagem é enviada para a atividade de anotação semiautomática.

A atividade de anotação semiautomática utilizando uma coleção de imagens, contextual e fina, realiza a classificação das imagens da embarcação e das demais embarcações detectadas e que não foram automaticamente anotadas. O resultado desta para a autoridade marítima consiste na predição da embarcação, segundo o modelo de detecção utilizado. Para o *framework* CV-MDA, as imagens das embarcações são submetidas à solução de *crowdsourcing* CV-MDA proposto neste trabalho, com o objetivo de ampliar as imagens anotadas como ilustrado na Figura 31.




Figura 31 - Ferramenta de Crowdsourcing do Framework CV-MDA.

5.2.2. Instância do Cenário 2 utilizando o CV-MDA

Com o uso das camadas de realidade aumentada, visão computacional e anotação automática do CV-MDA, é possível não apenas realizar a anotação automática das embarcações, mas também identificar discrepâncias na quantidade de embarcações em uma determinada região marítima.

Ao utilizar a quantidade de registros de embarcações distintas apresentadas na camada de visão computacional e compará-la com a quantidade de embarcações identificadas pela visão

computacional, podemos ilustrar um cenário hipotético e estabelecer uma relação entre o número de embarcações discrepantes.

A camada de anotação automática foi empregada para apoiar a ilustração desse cenário, pois realiza a fusão entre as embarcações encontradas nas camadas de realidade aumentada e visão computacional.

A utilização dessa camada foi necessária, pois além de permitir a contagem do número de objetos (embarcações), é possível distinguir as embarcações que não possuem registros ou apresentaram alguma discrepância, tornando impossível sua anotação automática.

Na Figura 32, é apresentado o *framework* CV-MDA em ação, mostrando a atividade de extração dos objetos (embarcações) e dos registros de navegação. Essa etapa foi fundamental para demonstrar a identificação de discrepâncias na quantidade de embarcações em uma determinada região marítima.

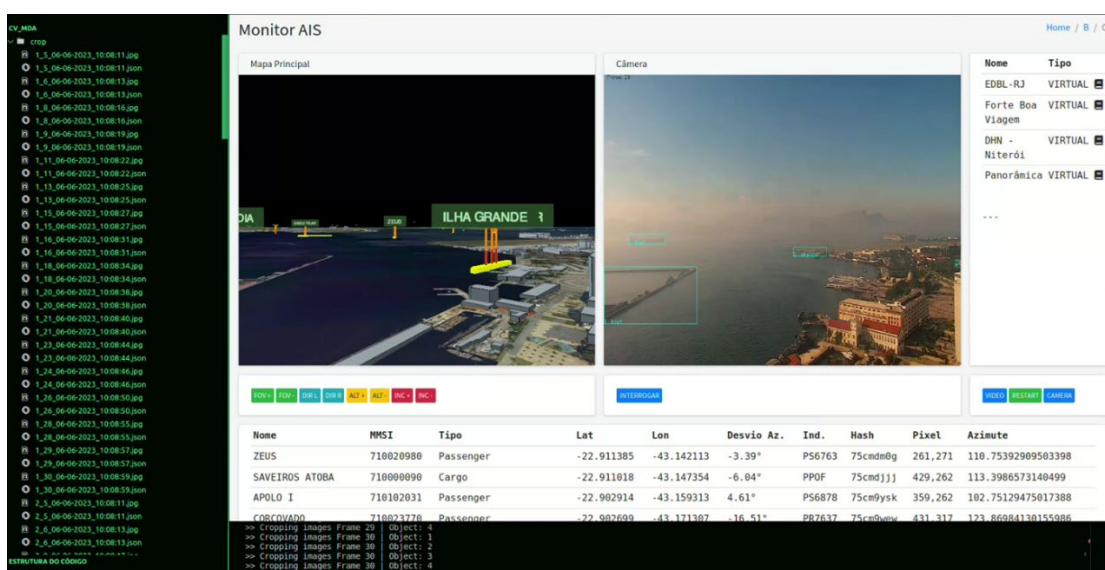


Figura 32 - Identificação de Discrepância na Quantidade de Embarcações

5.2.3. Instância do Cenário 3 utilizando o CV-MDA

Para ilustrar o cenário hipotético 3 na classificação visual do tipo de embarcações, o *framework* CV-MDA foi utilizado para a criação de uma coleção de imagens de embarcação contextual e fino. A coleção de imagens criada pelo CV-MDA foi utilizada como fonte de dados de imagens de embarcação no contexto marítimo brasileiro para realizar o treinamento de uma CNN que possibilite a classificação do tipo de embarcação que existe em um determinado domínio marítimo.

No uso do framework CV-MDA, realizamos a anotação automática de 980 imagens de embarcações. A Tabela 8 fornece informações sobre a contagem de embarcações pré-detectadas, usando diferentes níveis de confiança do modelo “Yolov5m”. Na Figura 33, é possível visualizar um exemplo de embarcações pré-identificadas com duas confianças distintas, 0,3 e 0,5.

Tabela 8 - Embarcações Pré-identificadas x Valor de Confiança Mínimo.

Quantidade	Imagens Capturadas	Detecção Objetos Tipo “Boat” x Valores de Confiança			
		0,3	0,4	0,5	0,8
	980	910764	4634	4035	228




Figura 33 - Embarcações Pré-identificadas com Confiança Mínima de 0,3 e 0,5.

Durante a coleta das imagens, foram incorporados metadados relacionados à posição na imagem da câmera, data e hora da captura, *bounding box* (caixa delimitadora) e classe identificada. A Figura 34 mostra um exemplo ilustrativo dos metadados anexados à imagem da embarcação, permitindo visualizar as informações relacionadas a cada imagem capturada.

```
[
  {
    "id": "1_3_06-05-2023_16:36:44.jpg",
    "frame_obj": 3,
    "start_record": "06-05-2023_16:36:44",
    "BBox": [
      0.429,
      0.539,
      0.382,
      0.647
    ],
    "click": [
      447,
      506.5
    ],
    "label": "boat"
  }
]
```

Figura 34 - Metadados da Extração da Imagem.

A fim de preservar a privacidade dos dados e facilitar a disponibilização futura dessa coleção de imagens, os tipos de embarcações foram anonimizados como *Ship0*, *Ship1*, *Ship2* até *Ship8*, juntamente com outras características que permitem a identificação do objeto (embarcação). A Figura 35 apresenta a distribuição das embarcações anotadas para cada tipo.




Figura 35 - Distribuição das Embarcações (instâncias) Anotadas.

Nesta instância do cenário hipotético, realizamos o treinamento da coleção de imagens que foram anotadas pelo *framework* CV-MDA, utilizando diferentes “épocas” no treinamento. A escolha do número de épocas a serem executadas durante o treinamento do modelo de detecção de embarcação depende de vários fatores, como o tamanho e a complexidade do conjunto de dados, a taxa de aprendizado e a convergência do modelo.

É comum realizar experimentos com diferentes números de épocas para determinar qual oferece o melhor desempenho. O primeiro treinamento foi realizado com 10 épocas, conforme mostrado na Figura 36 e Figura 37; o segundo, com 20 épocas, como evidenciado na Figura 38 e Figura 39; e o terceiro, com 50 épocas, conforme ilustrado na Figura 40 e Figura 41.




Figura 36 - Precision e Recall 10 Épocas.




Figura 37 - Matriz de Confusão 10 Épocas.




Figura 38 - Precision e Recall 20 Épocas.




Figura 39 - Matriz de Confusão 20 Épocas.




Figura 40 - Precision e Recall 50 Épocas.




Figura 41 - Matriz de Confusão 50 Épocas.

Após o treinamento com diferentes épocas, avaliamos os modelos utilizados utilizando as métricas *precision* e *recall*, além da matriz de confusão.

A avaliação em termos de *precision* tem como objetivo quantificar a capacidade do modelo de acertar as predições realizadas, ou seja, avalia com que frequência o agente classifica uma embarcação corretamente. Já a métrica *recall* visa avaliar o modelo em relação aos erros em cenários relevantes, medindo a variabilidade com que o modelo retorna predições, enquanto a *precision* reflete a qualidade das predições realizadas.

Ao utilizarmos essas métricas em conjunto, podemos avaliar a confiança do modelo ao testar a hipótese de classificação de uma embarcação como pertencente à classe predita. Além disso, a matriz de confusão permitiu visualizar claramente a quantidade de erros e acertos para cada classe em relação às demais.

Ao analisar os gráficos apresentados na Figura 36, Figura 38 e Figura 40, é possível observar que a reintrodução da coleção de dados resultou em uma melhoria contínua na qualidade do classificador. Ao avaliar o comportamento médio e as classes que possuem mais exemplos *Ship2*, *Ship5* e *Ship7*, percebe-se que o limiar de *precision* tende a se aproximar do valor máximo e a curva torna-se mais suave, o que indica um aumento da área sob a curva com a reintrodução da coleção dados no treinamento. Contudo, ao analisarmos as Figura 37, Figura

39 e Figura 41, que apresentam as matrizes de confusão, podemos notar um espalhamento quase uniforme dos erros (falsos negativos), com exceção das classes *Ship4* e *Ship8*, cujos erros podem ser explicados pela baixa quantidade de exemplos disponíveis para o treinamento (zero e 50 exemplos, respectivamente).

A Figura 42 ilustra o cenário hipotético 3, onde um navio petroleiro tem o tipo de embarcação identificado automaticamente representado pelo objeto identificado pelo rótulo *Ship2*.



Figura 42 - Tipo de Embarcação Automaticamente Identificadas.

5.2.4. Discussão dos Cenários Hipotéticos

A detecção de objetos é uma aplicação concreta e visualmente identificável dos dados coletados, o que facilita a compreensão de sua importância. No entanto, a criação de uma coleção de dados é necessária em muitas outras áreas e tarefas, que podem envolver dados abstratos, complexos ou específicos do contexto. Portanto, pode ser complicado demonstrar a necessidade da coleção de dados sem realizar diretamente a detecção de objetos, pois isso não abrange toda a amplitude e variedade de aplicações que exigem a coleta de dados.

Na Figura 43, apresentamos lado a lado a identificação das embarcações utilizando a coleção de dados anotados pelo CV-MDA, com confiança mínima de 0,25, comparado a utilização de um modelo não contextual e fino (coleção de imagens COCO) na identificação das embarcações.




Figura 43 - Identificação Contextual e Fina x Identificação Genérica.

Na terceira instância, após conduzir experimentos exploratórios, é possível inferir que o conjunto de dados utilizado exibe um desequilíbrio significativo entre suas classes. As categorias *Ship4* e *Ship8* demonstram baixa precisão devido à insuficiência de exemplos disponíveis para o treinamento. Contrastando com isso, a categoria *Ship8*, mesmo sendo a mais numerosa, alcança uma precisão notável em torno de 99%.

Outras categorias apresentam precisões médias, aproximadamente 60%, apesar das limitações inerentes ao conjunto de dados, como o desequilíbrio e a incompletude. Essas precisões se assemelham aos resultados obtidos no cenário 2, no qual não é viável identificar o tipo de embarcação com precisão.

Vale destacar que o fluxo metodológico delineado para essa situação pode ser repetido ao lidar com novas imagens, permitindo, desse modo, um refinamento contínuo do algoritmo de detecção de embarcações. É importante notar, entretanto, que essa abordagem careceu de validação durante os experimentos conduzidos nesta fase. Para aprimorar de forma contínua a coleção de dados, é imperativo empregar técnicas de gerenciamento de qualidade dos dados, contudo essa abordagem não faz parte do escopo deste trabalho.

6. AVALIAÇÃO CV-MDA

QP2: Como a tecnologia pode ser projetada para apoiar em diversos cenários que necessitam da ampliação da MDA?

Neste capítulo, são apresentados os resultados da avaliação do CV-MDA, seguindo os princípios do *Design Science*. A metodologia de avaliação é descrita em detalhes, abrangendo a avaliação dos conceitos, modelos, métodos e o arcabouço tecnológico. Após a descrição da metodologia utilizada, são apresentadas as avaliações individuais de cada artefato, aplicando a metodologia de avaliação estabelecida.

6.1. A Metodologia de Avaliação

Conforme mencionado na seção 1.4, este estudo adota o *framework* de *Design Science* proposto por MARCH e SMITH (1995), que divide o processo de *Design Science* em construção e avaliação de conceitos, modelos, métodos e arcabouço tecnológico. O processo de avaliação dos artefatos desenvolvidos visa medir sua fidelidade ao mundo real e sua completude.

O *framework* de MARCH e SMITH (1995) harmoniza as atividades de pesquisa com seus resultados, que podem ser aplicados tanto nas ciências naturais quanto no *Design Science*. Vale ressaltar que uma pesquisa não precisa abranger todas as atividades relacionadas. A avaliação realizada neste estudo de tese é apresentada na Tabela 9.

Tabela 9 - Metodologia de Avaliação da Pesquisa dos CV-MDA.

	Construir	Avaliar	Teorizar	Justificar
Conceitos	Definição dos conceitos básicos para a ampliação da MDA na formação de uma coleção de dados de apoio à identificação de embarcações.	Investigar sua fidelidade com o cenário real da autoridade marítima brasileira.		
Modelo	Definição do modelo CV-MDA, que apoia este trabalho.	Investigar se o modelo é capaz de descrever uma solução de apoio na ampliação da MDA.		
Método (Processo)	Definição do método de ampliação da MDA a partir do modelo CV-MDA.	Investigar se o método é capaz apoiar na ampliação da MDA na área marítima brasileira.	O modelo criado pela coleção de imagens de navegação é capaz de apoiar na detecção de embarcações no domínio marítimo brasileiro.	As instâncias do processo CV-MDA operam de maneira satisfatória.
Arcabouço Tecnológico (Implementação)	Prototipação (arcabouço tecnológico) do sistema CV-MDA	Utilizar o protótipo em um estudo de caso.		

Com o intuito de tornar mais claro o entendimento da metodologia de avaliação empregada neste estudo, dividimos o processo de construção em objetivos e seus respectivos resultados, ou seja, os artefatos desenvolvidos. Da mesma forma, o processo de avaliação foi dividido em métricas e metodologias utilizadas para a avaliação. A Tabela 10 fornece uma ilustração detalhada da metodologia de avaliação aplicada ao CV-MDA.

Tabela 10 - Metodologia de Avaliação do CV-MDA.

	Construção		Avaliação	
	Objetivo	Resultados	Métricas	Metodologias
Conceitos	Identificar questões pertinentes na ampliação da MDA para a autoridade marítima brasileira.	Obter os conceitos relacionados com a ampliação da MDA.	Compleitude	Argumento Lógico
Modelo	Descrever como as partes da formação de coleção de imagens de embarcação estão organizadas.	O modelo CV-MDA.	Fidelidade com o mundo real e completude.	Cenário Ilustrativo
Método (Processo)	Descrever um processo de formação de coleção de imagens de embarcação	O processo CV-MDA.	Fidelidade com o mundo real e completude	Cenário Ilustrativo
Arcabouço Tecnológico (Implementação)	Utilizar o arcabouço em uma aplicação real.	O protótipo de sistema CV-MDA.	Aplicabilidade	Protótipo

Quanto à seleção de metodologias de avaliação, utilizamos a revisão sistemática apresentado no trabalho de PEFERS et al. (2012) como referência, que analisou os tipos de métodos de avaliação, os tipos de artefatos produzidos e o histórico de aplicação de cada método de avaliação para cada artefato produzido. A revisão do autor foi realizada com o objetivo de identificar os métodos de avaliação mais adequados para cada tipo de artefato produzido em pesquisas de *Design Science*.

Com base na análise da aplicabilidade de cada método para os artefatos produzidos nesta pesquisa (conceitos, modelos, métodos e artefato tecnológico), foram selecionados os métodos listados na Tabela 10 e definidos como:

- Argumento Lógico: um argumento com validade aparente.
- Cenário ilustrativo: a aplicação de um artefato em um ambiente real ou simulado com o propósito de demonstrar sua adequação ou utilidade.
- Protótipo: a construção de um artefato com o objetivo de ilustrar sua adequação ou utilidade.

6.2. Avaliação dos Conceitos

O processo de avaliação dos conceitos do CV-MDA foi realizado utilizando a metodologia de Argumento Lógico, com o objetivo de demonstrar a completeza dos conceitos apresentados.

O principal conceito a ser analisado é a “Conscientização do Domínio Marítimo”. O termo é comumente relacionado com a expressão “Consciência Situacional Marítima”. Embora esses termos sejam frequentemente usados de forma intercambiável, eles têm algumas particularidades distintas.

A Conscientização do Domínio Marítimo é um conceito mais amplo e abrangente, que se concentra na compreensão completa de todos os aspectos do ambiente marítimo, geralmente relacionado ao conhecimento informacional e não é reativo a uma situação em específico, envolvendo situações de planejamento e preparação de atividades.

Por outro lado, a Consciência Situacional Marítima é mais específica e se refere à compreensão necessariamente em tempo real do ambiente marítimo em um determinado momento, reativa e pouco planejada.

No contexto da autoridade marítima, a percepção da completeza depende de vários fatores. Esses conceitos visam fornecer uma compreensão abrangente, mas alcançar uma completa conscientização pode ser um desafio devido à complexidade e dinâmica do ambiente marítimo.

A completeza na conscientização do domínio marítimo pode ser avaliada pela extensão em que todas as informações relevantes são coletadas, analisadas e integradas de forma a fornecer uma visão particular do ambiente marítimo. Isso inclui a compreensão das atividades computacionais e humanas envolvidas nas atividades de ampliação da MDA. A obtenção de uma completa conscientização do domínio marítimo requer colaboração e coordenação efetivas de várias agências, organizações e sistemas de coleta de dados, o que reforça a nossa percepção de sua completeza.

6.3. Avaliação do Modelo e Método

O modelo e método CV-MDA foram avaliados conjuntamente utilizando as metodologias de Cenário Ilustrativo, com o objetivo de verificar sua fidelidade com o mundo real e completude.

Nesta seção são descritos três Cenário Ilustrativos. Os Cenários Ilustrativos são relativos a autoridade marítima, com o objetivo de demonstrar aplicações típicas em que o modelo e

método CV-MDA podem ser utilizados. Os cenários são relativos à autoridade marítima, representada pela Marinha do Brasil.

No primeiro cenário ilustrativo, é apresentada uma situação em que existem embarcações sem registros de navegação disponíveis para a autoridade marítima. Nesse contexto, a perspectiva visual é o principal recurso utilizado para identificar as embarcações em uma determinada região marítima.

No segundo cenário ilustrativo, a situação apresentada é aquela em que há uma discrepância entre a quantidade de embarcações observadas na perspectiva visual e os registros de navegação disponíveis para uma determinada região marítima.

Enquanto o terceiro cenário ilustrativo, é o mais representativo da principal aplicação do *framework* CV-MDA. Neste cenário, o principal objetivo consiste na classificação dos tipos de embarcações, possibilitando a maior compreensão e ação da autoridade marítima em virtude das embarcações encontradas.

Estes exemplos mostram que o modelo e o método CV-MDA podem ser aplicados em diferentes cenários do domínio marítimo brasileiro. Contudo, o modelo e o método CV-MDA não estão limitando às aplicações descritas nesta pesquisa.

6.3.1. Cenário Ilustrativo 1

O cenário Ilustrativo 1, aborda a existência de embarcações sem registro de navegação, é um desafio para o monitoramento e controle do tráfego marítimo, pois elas não podem ser facilmente detectadas e monitoradas em tempo real, uma vez que os registros disponibilizam informações das embarcações como a identificação (MMSI, IRIN ou IMO), a posição (latitude e longitude), a velocidade e outras informações que podem ser relevantes para as autoridades marítimas e outras embarcações próximas.

As embarcações que não possuem registros de navegação podem representar um risco significativo para a segurança marítima. O contexto de segurança marítima para MDA refere-se à proteção contra ameaças que podem afetar a segurança das embarcações, do tráfego marítimo, das instalações (portos, plataformas de petróleo e instalações militares) e das atividades marítimas.

As atividades de risco devido à ausência de registros de navegação incluem a pirataria, terrorismo marítimo, tráfico de drogas e armas, contrabando, imigração ilegal e outros atos criminosos que podem ocorrer em ambiente marítimo. Nestes cenários, as atividades de ampliação da MDA podem envolver a implementação de medidas de segurança física,

vigilância costeira, controle de acesso às áreas portuárias, sistemas de identificação e rastreamento de embarcações, cooperação internacional para combater ameaças transnacionais, entre outras.

Portanto, a detecção de embarcações na situação de ausência de registros de navegação torna-se fundamental para apoiar nas atividades de segurança marítima. A criação de uma coleção de imagens contextual e fina anotadas é uma maneira de apoiar no desenvolvimento de solução de detecção automática capaz de detectar essas embarcações que principalmente trafegam em uma determinada área marítima.

6.3.2. Cenário Ilustrativo 2

O cenário Ilustrativo 2 mostra a identificação de discrepância na quantidade de embarcações em uma determinada região marítima, refere-se ao processo de analisar e detectar diferenças entre o número esperado de embarcações em uma determinada região marítima, representado pelos registros de navegação, e o número real de embarcações observadas, mediante a visualização das embarcações.

A análise desse tipo de cenário pode ser útil para a autoridade marítima brasileira em diversas situações, como o monitoramento do tráfego marítimo, segurança marítima e controle de atividades ilegais. Portanto, a fusão entre os dados de navegação e as imagens das embarcações detectadas torna-se fundamental para apoiar no monitoramento do tráfego marítimo, segurança marítima e controle de atividades ilegais, possibilitando encontrar de maneira automática discrepâncias na quantidade de embarcações entre as duas maneiras de visualização o ambiente marítimo.

6.3.3. Cenário Ilustrativo 3

O cenário Ilustrativo 3 representa ampliação da MDA, para apoiar na identificação dos tipos de embarcações. Sobretudo em uma região específica, reconhecer o tipo de embarcação é fundamental para garantir a segurança do tráfego marítimo. Os distintos tipos de embarcações possuem características específicas, como tamanho, manobrabilidade e capacidade de resposta, que influenciam diretamente a segurança das atividades marítimas.

A classificação correta dos tipos de embarcações, a autoridade marítima pode tomar medidas de segurança apropriadas para cada tipo de embarcação, minimizando o risco de acidentes, colisões e incidentes. Além disso, a classificação correta dos tipos de embarcações permite que as autoridades marítimas identifiquem e monitorem as embarcações de acordo com

suas características e finalidades específicas. Com essa informação, é possível aplicar as regulamentações e regras de navegação apropriadas, garantindo a ordem, a eficiência e a segurança do tráfego marítimo.

Pensando sobre o âmbito administrativo de controle do tráfego marítimo, a classificação correta dos tipos de embarcações possibilita aplicar as regulamentações e regras de navegação apropriadas para cada tipo de embarcação, garantindo a ordem, a eficiência e a segurança do tráfego marítimo.

No cenário Portuário, a classificação correta do tipo de embarcação é essencial para o planejamento e a gestão eficientes das operações portuárias. Ela permite que os terminais aloquem recursos adequados, como áreas de atracação, equipamentos de movimentação de carga e pessoal, de acordo com as necessidades específicas de cada tipo de embarcação. Isso resulta em um fluxo mais eficiente de mercadorias, redução de tempos de espera e melhoria geral na produtividade portuária.

De maneira geral, podemos dizer que a classificação correta do tipo de embarcação é de suma importância para garantir a segurança, a eficiência e o controle adequado das atividades marítimas, desempenhando um fundamental na prevenção de acidentes, no cumprimento das regulamentações, no planejamento portuário, contribuindo para a ampliação da MDA em uma determinada região marítima.

6.4. Avaliação da Implementação

Para avaliar a implementação do CV-MDA, foram empregadas a metodologia baseada em prototipagem. A avaliação da implementação por prototipagem para ampliação da conscientização do domínio marítimo é fundamental para garantir que o protótipo desenvolvido atenda aos requisitos e objetivos estabelecidos para melhorar a percepção e compreensão do ambiente marítimo.

Por meio dessas avaliações, é possível obter informações valiosas sobre a implementação por prototipagem para ampliação da conscientização do domínio marítimo, permitindo refinamentos e melhorias antes da implementação final.

6.4.1. Estudo de Caso 1: Cenário Ilustrativo 1

No primeiro estudo de caso representado pelo cenário ilustrativo 1, a prototipagem foi utilizada para avaliar a capacidade do arcabouço tecnológico por meio da prototipagem, principalmente, nas camadas de visão computacional e anotação semiautomática.

O estudo teve como objetivo analisar a eficácia da implementação na detecção de embarcações, incluindo a captura de imagens das embarcações não identificadas. Além disso, o sistema pré-classificou as embarcações detectadas antes de fornecer essas imagens para a solução CV-MDA de *crowdsourcing*. Essa abordagem permitiu a anotação semiautomática das embarcações, combinando o poder do processamento automatizado com a contribuição humana para obter resultados mais precisos.

No estudo de caso do cenário ilustrativo 1, o CV-MDA mostrou capacidade de auxiliar na detecção de embarcações. No entanto, devido à falta de um modelo robusto para a identificação precisa das embarcações, o sistema apresentou limitações em sua aplicabilidade no cenário real, o que restringe o potencial do protótipo. As principais conclusões do estudo são as seguintes: (1) a utilização de camadas de visão computacional para detectar e visualmente identificar as embarcações é viável, especialmente ao utilizar imagens de câmeras na região portuária; (2) o CV-MDA pode ser aplicado com êxito como uma nova fonte de dados para o registro e monitoramento do movimento das embarcações.

Em resumo, o estudo destaca que a implementação de técnicas de visão computacional pode ser promissora para a detecção de embarcações, mas são necessários aprimoramentos no modelo de identificação para melhorar a aplicabilidade do sistema em cenários reais. Além disso, demonstra que o CV-MDA pode ser uma valiosa ferramenta complementar para o registro de dados de movimentação de embarcações, contribuindo para a melhoria da gestão e monitoramento nesse contexto.

6.4.2. Estudo de Caso 2: Cenário Ilustrativo 2

No segundo estudo de caso representado pelo cenário ilustrativo 2, a prototipação foi utilizada para avaliar a capacidade do arcabouço tecnológico por meio da prototipação, principalmente, nas camadas de realidade aumentada, visão computacional e anotação automática. O estudo teve como objetivo analisar a eficácia da implementação na identificação de discrepâncias na presença de embarcações, ao comparar os dados dos registros de navegação com as imagens capturadas das embarcações em tempo real.

No contexto desse estudo de caso, o CV-MDA demonstrou a capacidade de detectar e apresentar embarcações que não constavam nos registros de navegação, fornecendo informações valiosas para aumentar a conscientização no domínio marítimo. O CV-MDA também proporcionou meios para identificar discrepâncias no número de embarcações, permitindo detectar aquelas com problemas ou suspeitas, uma vez que não havia registros de

navegação correspondentes para tais embarcações. Além disso, as imagens das embarcações foram capturadas e relacionadas com os registros de embarcação, possibilitando a anotação automática da coleção de imagens.

Essas descobertas destacam o potencial do CV-MDA como uma ferramenta útil para auxiliar no monitoramento e controle de atividades marítimas, especialmente no que diz respeito à identificação de situações irregulares ou preocupantes, em que a ausência de registros pode indicar atividades ilícitas ou não autorizadas. Dessa forma, o sistema mostrou-se como uma ferramenta valiosa para aprimorar a segurança e a eficiência no âmbito marítimo.

As principais limitações identificadas no estudo estão relacionadas ao fato de que certas embarcações, especialmente as menores como as pesqueiras e embarcações de passeio, não são obrigadas a fornecer registros de navegação. Isso cria uma lacuna na disponibilidade de informações precisas sobre essas embarcações. As principais conclusões do estudo são as seguintes: (1) formação de uma coleção de imagens contextual e fina das embarcações de maneira automática. (2) A utilização do CV-MDA para a identificação de discrepância entre as imagens e os registros das embarcações.

De maneira geral, o estudo destaca a implementação de realidade aumentada no entendimento da realidade das informações dos registros das embarcações em tempo real, enquanto as técnicas de visão computacional podem ser utilizadas para a detecção de embarcações que não possuem registros, além de permitir fusionar as imagens com os registros para a formação de uma coleção de imagens anotadas automaticamente, fina e contextual. Essas conclusões sugerem que a combinação de realidade aumentada e visão computacional pode ser uma abordagem eficaz para melhorar a conscientização do domínio marítimo neste cenário e extensível a outros cenários.

6.4.3. Estudo de Caso 3: Cenário Ilustrativo 3

No terceiro estudo de caso, a prototipação foi utilizada para avaliar a capacidade do arcabouço tecnológico por meio da prototipação, principalmente, nas camadas de realidade aumentada, visão computacional e anotação automática. O estudo teve como objetivo analisar a eficácia da implementação por meio da representação de uma solução de apoio a autoridade marítima, na região portuária, mediante identificação automática do tipo de embarcação, para iniciar atividades relacionadas ao tráfego e segurança marítima.

Neste estudo de caso, podemos analisar com maior clareza as funcionalidades do *framework* CV-MDA, representada pelo seu protótipo. O CV-MDA demonstrou a capacidade

de identificar os tipos das embarcações que permeiam a região portuária do Rio de Janeiro. A identificação dos tipos de embarcações com a utilização do CV-MDA proporciona a autoridade marítima uma maior agilidade e clareza para controlar o tráfego marítimo e apoiar as embarcações no fundeio das embarcações.

As principais limitações identificadas no estudo estão relacionadas à ausência de uma ontologia específica para os tipos de embarcações. Essa falta de uma ontologia adequada dificulta a identificação clara e precisa das embarcações, tornando desafiador delimitar os diferentes tipos de embarcações e reduzir as ambiguidades visuais que podem surgir. A ausência de uma ontologia apropriada pode levar a confusão na identificação das embarcações, especialmente quando existem características visuais semelhantes entre diferentes tipos de embarcações. Isso pode afetar a precisão da detecção e classificação das imagens das embarcações, gerando resultados incorretos ou ambíguos.

Este estudo obteve duas conclusões principais. Inicialmente, destacou-se a criação de uma estrutura que possibilita a identificação automática dos tipos de embarcações, considerando o contexto do cenário marítimo apresentado. A concepção de um framework de Monitoramento de Atividades Marítimas através de Visão Computacional (CV-MDA), integrando diversas atividades correlacionadas, revelou-se fundamental para alcançar esse propósito. Em segundo lugar, observou-se uma notável ampliação na capacidade preditiva por parte da autoridade marítima, resultando em maior agilidade no tempo de resposta em relação às embarcações que desejam atracar. A implementação do *framework* CV-MDA possibilitou uma análise mais rápida e precisa das embarcações presentes no cenário marítimo, fornecendo informações valiosas para tomadas de decisões mais eficientes.

De maneira geral, o estudo ressalta a importância de utilizar abordagens de visão computacional para identificar automaticamente os tipos de embarcações em um contexto marítimo. Além disso, enfatiza que a formação do *framework* CV-MDA envolve uma série de atividades interligadas, as quais são cruciais para alcançar resultados confiáveis e úteis na identificação das embarcações.

7. CONSIDERAÇÕES FINAIS

A Conscientização do Domínio Marítimo é uma atividade interdisciplinar, fragmentada em diversos contextos, específicos ou genéricos, com objetos e metodologias distintas. Este trabalho de pesquisa tenta construir uma bagagem teórica e prática para a construção de um *framework* específico de apoio na ampliação da MDA.

O *framework* CV-MDA, principal artefato desenvolvido nesta pesquisa, é composto pelo modelo CV-MDA e pelo método CV-MDA. O modelo CV-MDA representa a estrutura organizacional, em camadas, das atividades envolvidas na ampliação da MDA. Já o método CV-MDA organiza e descreve as atividades de cada camada de acordo com as soluções e técnicas utilizadas neste trabalho para apoiar na ampliação da MDA.

Com relação à avaliação dos artefatos construídos nesta pesquisa, foi utilizado o *framework* de *Design Science* proposto por MARCH e SMITH (1995), que organiza as atividades de *Design Science* na construção e na avaliação de conceitos, modelo, método, e artefato tecnológico. O processo de avaliação dos artefatos desenvolvidos deve ser apropriado para medir a sua fidelidade com o mundo real e sua completeza. Os conceitos, o modelo CV-MDA, o processo CV-MDA e o arcabouço tecnológico CV-MDA foram avaliados segundo as metodologias de Argumento Lógico, Cenário Ilustrativo e Protótipo (PEFFERS; ROTHENBERGER; KUECHLER, 2012).

Este último capítulo, iniciando na seção 7.2, revisita as questões de pesquisa levantadas no Capítulo 1, mostrando como a pesquisa realizada nesta tese abordou cada uma delas. Na seção 7.3, as principais contribuições de pesquisa são apresentadas e a originalidade deste trabalho é discutida. Na seção 7.4, as limitações desta pesquisa são apresentadas. Finalmente, na seção 7.5, algumas oportunidades de trabalho futuro são apresentadas.

7.1. Revisitando as Questões de Pesquisa

No primeiro capítulo foi apresentado um conjunto de Questões de Pesquisa (QP), visando especificar os principais objetivos desta Tese. Nesta seção, será revisitada cada uma destas questões, analisando os resultados obtidos durante o trabalho.

QP1: Como a Conscientização do Domínio Marítimo está fundamentado em suas bases teóricas, quais são as principais tecnologias e soluções utilizadas?

A revisão da literatura apresentada no capítulo 2 identificou as principais bases teóricas para caracterizar a Conscientização do Domínio Marítimo, apresentando soluções específicas

de algumas localidades geográficas e soluções genéricas. A questão sobre as principais tecnologias e soluções utilizadas na ampliação da MDA escolhidas foi realizada em detrimento do estado da arte das soluções encontradas na literatura, face ao contexto do objetivo principal deste trabalho.

A condução deste levantamento bibliográfico foi a base para a formulação e implementação do modelo, método e arcabouço tecnológico que compõem o *framework* CV-MDA. Apesar de não termos realizado uma varredura de todos os artigos dos periódicos – uma tarefa inviável devido ao grande número de publicações, este trabalho conseguiu cobrir as principais áreas atualmente ligadas a MDA com a finalidade proposta do trabalho.

QP2: Como a tecnologia pode ser projetada para apoiar em diversos cenários que necessitam da ampliação da MDA?

Os conceitos, o modelo, o processo e o arcabouço tecnológico CV-MDA, descritos nos capítulos 3, 4, 5 e 6, permitiram a criação e a execução de cenários ilustrativos que permitiram representar a utilização da tecnologia na instanciação de diversos contextos demonstrativos. Além das instâncias dos cenários apresentados na sessão 6.1, o arcabouço tecnológico CV-MDA mostrou sua capacidade em apoiar outras aplicações, diferentes das apresentadas.

QP3: Como a interligação de diversas soluções e tecnologias pode ser utilizada para a formação de coleções de dados anotados de maneira automatizada?

Conforme abordado no capítulo 4, para realizar a anotação de dados utilizando os registros de navegação e as imagens das embarcações é necessário interligar as camadas que compõem as diversas atividades e soluções encontradas neste trabalho para apoiar na ampliação da MDA.

Esta interligação se torna mais evidente quando detalhamos cada uma das atividades e soluções propostas, cada qual responsável pela realização de uma tarefa necessária para a formação de uma coleção de imagens anotada de maneira automatizada.

QP4: Como a formação de coleções de imagens de maneira contínua e automatizada pode contribuir na ampliação da MDA?

O estudo apresentado no capítulo 5 nos permitiu obter uma compreensão sobre as diversas soluções e técnicas de integração de dados, realidade aumentada, visão computacional e anotação de imagens utilizadas nesta pesquisa. A solução apresentada no capítulo 5

proporciona a produção contínua e automatizada de imagens anotadas de embarcações, utilizando registros de navegação.

QP5: Como a criação de uma coleção de imagem contextual e fino pode contribuir na ampliação da MDA?

Conforme visto no capítulo 2, existem soluções de MDA específicas para uma determinada localidade. A utilização de soluções específicas atua com informações particulares de uma determinada região ou cenário marítimo.

Além disso a criação de uma coleção de imagem contextual e fino possibilita um resultado interessante na detecção de embarcações, conforme apresentado no cenário ilustrativo e instância 3 nos capítulos 3 e 6, pois diferentemente das coleções de dados normalmente disponibilizados onde a detecção é realidade em classes ou categorias de maneira mais genérica, as classes especializadas permitem criar um modelo especialista de detecção.

7.2. Contribuições

A principal contribuição deste trabalho está em fornecer um *framework* contínuo e incremental para a formação de coleção de imagens anotadas de embarcação fina e contextual de maneira automatizada. A criação dessa coleção de imagens visa apoiar na ampliação da MDA e no subsídio de diversas tarefas relacionadas a identificação e detecção visual de embarcações com imagens reais.

No aspecto de novidade, destacamos a contribuição deste trabalho em produzir um conjunto de dados exclusivo para treinar modelos de detecção visual profunda para detecção de objetos em águas internas utilizando imagens de câmeras no domínio marítimo brasileiro, uma vez que não há um conjunto de dados especializado público disponível. As principais contribuições deste trabalho podem ser destacadas da seguinte maneira:

- Integração dos diversos tipos de registros de navegação.
- Anotação automatizada das imagens com perspectiva fina e contextual das embarcações.
- Criação de uma solução de visualização dos registros de embarcação integrados em tempo real.
- Formação de uma sequência de etapas (*pipeline*) para a detecção de embarcações.
- Desenvolvimento de uma ferramenta de *crowdsourcing* para semiautomatizar a anotação de imagens.

- Desenvolvimento de um *framework* de apoio na ampliação da MDA com um novo modelo, método e arcabouço tecnológico.

Como consequência do trabalho realizado durante esta pesquisa, destaca-se, ainda, uma significativa contribuição para a academia, realizada por intermédio da publicação do escopo deste trabalho em um importante periódico indexado no *Journal Citation Reports (JCR)*. A publicação destacada, demonstra a originalidade deste trabalho frente a outros trabalhos existentes na literatura, além de permitir que outros pesquisadores e profissionais tenham acesso aos resultados do estudo, que possam aprender com as metodologias utilizadas e até mesmo reproduzir o trabalho em suas próprias pesquisas.

Um resultado notável desta tese foi a publicação de um segmento deste trabalho intitulado "A Heterogeneous Data Integration for Vessel Activity Monitoring in Territorial Waters", que inclusive foi reconhecido como o melhor artigo no congresso "The Latin American Workshop on Information Fusion – LAFUSION 2023". Outra importante publicação foi no periódico *JMIR Public Health and Surveillance*, também indexado no JCR, que proporcionou grande experiências e apoio na condução deste trabalho.

A Tabela 11 complementa as contribuições listadas acima com as principais publicações que foram aceitas e publicadas durante o período desta pesquisa, relacionadas direta ou indiretamente à pesquisa desta tese.

Tabela 11 - Principais Publicações.

#	Título	Periódico e Ano de Publicação
	A Heterogeneous Data Integration for Vessel Activity Monitoring in Territorial Waters	The Latin American Workshop on Information Fusion – LAFUSION 2023
1	Improving Maritime Domain Awareness in Brazil Through Computer Vision Technology	Journal of Marine Science and Engineering – 2023.
2	Supporting Distributed and Integrated Execution of Future-Oriented Technology Analysis	Futures & Foresight Science – 2022.
3	A Utilização De Machine Learning Na Identificação De Elementos Textuais Geográficos	Publicação de Livro Especializado – 2022.
3	Development of an Index for the Inspection of <i>Aedes aegypti</i> Breeding Sites in Brazil: Multi-criteria Analysis	JMIR Public Health and Surveillance – 2021.

4	Collaboration Challenges of Professional eSports Players in Brazil	Brazilian Symposium on Computer Games and Digital Entertainment – SBGames 2021
5	Bioinformática Contexto Computacional e Aplicações	Revisor Livro Especializado – 2020.
6	Um Modelo Computacional Para Otimização Do Mix De Afretamento De Embarcações De Apoio Marítimo	XIX Simpósio de Pesquisa Operacional & Logística da Marinha – SPOLM 2020

7.3. Limitações

Realizando uma análise crítica sobre esta pesquisa de tese, após a construção artefatos dos e suas avaliações realizadas, é possível identificar algumas limitações organizadas em limitações de pesquisa, limitações relacionadas ao *framework* CV-MDA.

Entre as limitações da pesquisa, podemos destacar a falta de estudos relacionadas com a calibração de imagens de câmeras e estimativa de posição espacial. Estudos de soluções mais específicos nestes contextos forneceriam um respaldo maior a concepção de perspectivas de visualização das embarcações no mundo real e virtual.

As limitações relacionadas ao *framework* CV-MDA estão diretamente ligadas à detecção de objetos. Embora o objetivo do trabalho seja subsidiar atividades como a detecção de embarcações por meio da formação de coleções de dados contextuais e detalhados, é importante ressaltar que a simples criação da coleção de dados não garante a aplicação prática da detecção.

Existem diversas etapas e atividades envolvidas na detecção e identificação de embarcações e a utilização de coleções de imagens é um dos aspectos relevantes para o sucesso dessas tarefas. Outros fatores, como o ajuste de parâmetros de redes neurais, o balanceamento do conjunto de dados, o ajuste dos modelos, o *fine-tuning* e outros, podem ser decisivos na obtenção de resultados satisfatórios.

Portanto, é necessário considerar que a criação da coleção de dados é apenas o primeiro passo para o desenvolvimento de um sistema de detecção de embarcações eficiente. A aplicação prática do CV-MDA requer uma abordagem abrangente, considerando todas as etapas necessárias e os desafios específicos relacionados à detecção e identificação de embarcações nas águas interiores do Brasil.

Neste trabalho, outro fator de limitação foi a disponibilidade das câmeras na formação da coleção de imagens. A coleta de imagens com uma elevada heterogeneidade de embarcações

nas águas brasileiras pode exigir um período considerável, dependendo da disponibilidade das câmeras e da frequência de captura de imagens. A limitação de tempo pode afetar a quantidade de imagens coletadas e, conseqüentemente, a representatividade das diversas classes (tipos de embarcação) na coleção de imagens. Uma quantidade limitada de imagens pode afetar a capacidade do modelo de detectar com precisão os diferentes tipos de embarcações bem como sua generalização para diferentes condições ambientais.

Além disso, a disponibilidade das câmeras pode ser um desafio, especialmente devido a área de cobertura espacial extensa do Brasil. A instalação e manutenção de câmeras ao longo das águas interiores do Brasil podem exigir recursos financeiros e logísticos significativos. É importante considerar as limitações apresentadas ao ponderar os resultados e as conclusões obtidos do trabalho.

A quantidade limitada de imagens e a restrição de tempo podem afetar a representatividade e a aplicabilidade da coleção de imagens, bem como a formação do modelo de detecção de embarcações. No entanto, conforme ilustrado no trabalho, foi possível mitigar essas limitações buscando formas criativas de coleta de imagens, otimizando o tempo disponível e considerando as técnicas e soluções encontradas para ampliar informacionalmente a MDA.

As limitações metodológicas na ciência do design são intrínsecas à complexidade e à natureza contextual dos problemas abordados, nos quais a aplicação de soluções é altamente dependente do ambiente específico. No contexto deste trabalho, a avaliação dos resultados pode envolver um grau de subjetividade, sendo frequentemente utilizada como critério para medir o sucesso de uma solução. No entanto, essa abordagem também apresenta desafios, pois métricas objetivas podem não capturar completamente a eficácia em termos de aceitação do usuário e adaptação ao ambiente. Tais limitações destacam a importância de uma abordagem flexível e adaptativa, reconhecendo a necessidade de ajustes e refinamentos ao longo do processo de desenvolvimento para garantir uma solução apropriada ao contexto real em questão.

7.4. Trabalhos Futuros

Os conhecimentos obtidos por meio do desenvolvimento desta pesquisa podem ser ampliados e aprofundados mediante novos estudos dos diversos cenários de ampliação da MDA, aplicando o *framework* CV-MDA em diversos outros contextos, não abordados por este trabalho.

Relacionados a ampliação da MDA, podem elencar diversas outras direções para a realização de trabalhos futuros relacionados com esta pesquisa. Abaixo, destaca-se alguns pontos de sugestões destes trabalhos:

- Explorar abordagens multimodais na integração e fusão de dados em outras fontes como informações de radar e sensores, para melhorar a veracidade e completeza das informações dos registros de embarcação.

- Aumentar na diversidade da coleção de dados por meio da coleta de mais imagens de diferentes regiões e condições marítimas nas águas interiores do Brasil. Isso ajudará a melhorar a representação da heterogeneidade e robustez da coleção de imagens em diversos cenários.

- Refinar a anotação dos dados de maneira mais contextual com as informações de descrição das embarcações como tamanho, forma, características distintivas, entre outros. Isso pode permitir uma detecção mais precisa e uma análise mais rica e detalhada das características das embarcações.

- Realizar o treinamento de modelos para melhor avaliar a capacidade das coleções de imagens na detecção e identificação de embarcações, avaliando os diversos fatores de parametrização de modelos de aprendizado de máquina para obter modelos inteligência artificial adequados a realidade marítima brasileira.

Essas são apenas algumas sugestões de trabalhos futuros, não limitando a realização de outros trabalhos. O campo de detecção de ampliação da MDA está em constante evolução, com várias técnicas e abordagens emergentes. É importante acompanhar as últimas pesquisas e avanços tecnológicos para identificar novas oportunidades de pesquisa e desenvolvimento face aos avanços das soluções.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABIELMONA, R. Tackling big data in maritime domain awareness. **Vanguard Magazine**, 17 set. 2013.
- AGARWAL, A.; JAWAHAR, C. V.; NARAYANAN, P. J. A Survey of Planar Homography Estimation Techniques. dez. 2005.
- AHMED, I. et al. Top view multiple people tracking by detection using deep SORT and YOLOv3 with transfer learning: within 5G infrastructure. **International Journal of Machine Learning and Cybernetics**, v. 12, n. 11, p. 3053–3067, 1 nov. 2021.
- BANNISTER, N. P.; NEYLAND, D. L. Maritime domain awareness with commercially accessible electro-optical sensors in space. **International Journal of Remote Sensing**, v. 36, n. 1, p. 211–243, 2 jan. 2015.
- BATTISTELLO, G. et al. **Multi-sensor maritime monitoring for the Canadian Arctic: Case studies**. 2016 19th International Conference on Information Fusion (FUSION). **Anais...** Em: 2016 19TH INTERNATIONAL CONFERENCE ON INFORMATION FUSION (FUSION). jul. 2016.
- BLOISI, D. D. et al. **ARGOS-Venice Boat Classification**. 2015 12th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS). **Anais...** Em: 2015 12TH IEEE INTERNATIONAL CONFERENCE ON ADVANCED VIDEO AND SIGNAL BASED SURVEILLANCE (AVSS). Karlsruhe, Germany: IEEE, ago. 2015. Disponível em: <<https://ieeexplore.ieee.org/document/7301727>>. Acesso em: 1 abr. 2023
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. Yolov4: Optimal speed and accuracy of object detection. **arXiv preprint arXiv:2004.10934**, 2020.
- BORAZ, S. C. **Maritime Domain Awareness: Myths and Realities**. [s.l.] NAVAL WAR COLL NEWPORT RI, jan. 2009. Disponível em: <<http://www.dtic.mil/docs/citations/ADA519318>>. Acesso em: 18 out. 2018.
- BREITINGER, A.; CLUA, E.; FERNANDES, L. An Augmented Reality Periscope for Submarines with Extended Visual Classification. **Sensors**, v. 21, p. 7624, 17 nov. 2021.
- CLARAMUNT, C. et al. Maritime data integration and analysis: recent progress and research challenges. **Advances in Database Technology-EDBT**, v. 2017, p. 192–197, 2017.
- DE PAOR, D.; WHITMEYER, S.; BENTLEY, C. **CESIUM—A VIRTUAL GLOBE WITH STRONG POTENTIAL APPLICATIONS IN GEOSCIENCE EDUCATION**. [s.l.: s.n.].
- DE SOUZA, E. N. et al. Improving fishing pattern detection from satellite AIS using data mining and machine learning. **PloS one**, v. 11, n. 7, p. e0158248, 2016.
- DENG, J. et al. **Scalable multi-label annotation**. Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. **Anais...** Em: CHI '14: CHI CONFERENCE ON

HUMAN FACTORS IN COMPUTING SYSTEMS. Toronto Ontario Canada: ACM, 26 abr. 2014. Disponível em: <<https://dl.acm.org/doi/10.1145/2556288.2557011>>. Acesso em: 21 mar. 2023

DWYER, B.; NELSON, J.; SOLAWETZ, J. **Roboflow (version 1.0)[software]**.

ESTEVA, A. et al. Deep learning-enabled medical computer vision. **npj Digital Medicine**, v. 4, n. 1, p. 1–9, 8 jan. 2021.

FIORINI, M.; CAPATA, A.; BLOISI, D. D. AIS data visualization for Maritime Spatial Planning (MSP). **International Journal of e-Navigation and Maritime Economy**, v. 5, p. 45–60, 2016.

FONTOURA, P. R. C. T. **O Brasil e as operações de manutenção da paz das Nações Unidas**. [s.l.] Instituto Rio Branco, 1999. v. 37

GIANNAKOPOULOS, T. et al. **AMINESS: A Platform for Environmentally Safe Shipping**. Proceedings of the 7th International Conference on Pervasive Technologies Related to Assistive Environments. **Anais...: PETRA '14**. New York, NY, USA: ACM, 2014. Disponível em: <<http://doi.acm.org/10.1145/2674396.2674464>>. Acesso em: 24 maio. 2018

GIRSHICK, R. **Fast R-CNN**. . Em: PROCEEDINGS OF THE IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION. 2015. Disponível em: <https://openaccess.thecvf.com/content_iccv_2015/html/Girshick_Fast_R-CNN_ICCV_2015_paper.html>. Acesso em: 16 abr. 2022

GUNDOGDU, E. et al. **MARVEL: A Large-Scale Image Dataset for Maritime Vessels**. (S.-H. Lai et al., Eds.) Computer Vision – ACCV 2016. **Anais...: Lecture Notes in Computer Science**. Cham: Springer International Publishing, 2017.

GUO, N. et al. A Geographic Meshing and Coding Method Based on Adaptive Hilbert-Geohash. **IEEE Access**, v. 7, p. 11, 28 mar. 2019.

HADZAGIC, M.; SHAHBAZIAN, E. **Towards an Optimal Design of a Data Fusion System for Maritime Domain Awareness (Poster)**. 2018 IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA). **Anais...IEEE**, 2018.

HAMMEDI, W. et al. **Deep Learning-Based Real-Time Object Detection in Inland Navigation**. 2019 IEEE Global Communications Conference (GLOBECOM). **Anais... Em: 2019 IEEE GLOBAL COMMUNICATIONS CONFERENCE (GLOBECOM)**. dez. 2019.

JIANG, H.; LEARNED-MILLER, E. **Face Detection with the Faster R-CNN**. 2017 12th IEEE International Conference on Automatic Face Gesture Recognition (FG 2017). **Anais... Em: 2017 12TH IEEE INTERNATIONAL CONFERENCE ON AUTOMATIC FACE GESTURE RECOGNITION (FG 2017)**. maio 2017.

KAUR, P. et al. **Sea Situational Awareness (SeaSAW) Dataset**. . Em: PROCEEDINGS OF THE IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. 2022. Disponível em:

<https://openaccess.thecvf.com/content/CVPR2022W/Precognition/html/Kaur_Sea_Situation_al_Awareness_SeaSAW_Dataset_CVPRW_2022_paper.html>. Acesso em: 31 mar. 2023

KIEFER, B. et al. **Workshop on Maritime Computer Vision (MaCVi) 2023: Challenge Results**. 2023 IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW). **Anais...** Em: 2023 IEEE/CVF WINTER CONFERENCE ON APPLICATIONS OF COMPUTER VISION WORKSHOPS (WACVW). Waikoloa, HI, USA: IEEE, jan. 2023. Disponível em: <<https://ieeexplore.ieee.org/document/10031200/>>. Acesso em: 20 mar. 2023

KIM, J.-H. et al. Object Detection and Classification Based on YOLO-V5 with Improved Maritime Dataset. **Journal of Marine Science and Engineering**, v. 10, n. 3, p. 377, mar. 2022.

KIM, K.-I.; LEE, K. M. Deep Learning-Based Caution Area Traffic Prediction with Automatic Identification System Sensor Data. **Sensors**, v. 18, n. 9, p. 3172, set. 2018.

KUMAR, A. S.; SHERLY, E. **A convolutional neural network for visual object recognition in marine sector**. 2017 2nd International Conference for Convergence in Technology (I2CT). **Anais...** Em: 2017 2ND INTERNATIONAL CONFERENCE FOR CONVERGENCE IN TECHNOLOGY (I2CT). abr. 2017.

LASO, P. M. et al. **ISOLA: An Innovative Approach to Cyber Threat Detection in Cruise Shipping**. (Á. Rocha, C. H. Fajardo-Toro, J. M. R. Rodríguez, Eds.) Developments and Advances in Defense and Security. **Anais...**: Smart Innovation, Systems and Technologies. Singapore: Springer, 2022.

LEE, A.; JANG, I. **Mouse Picking with Ray Casting for 3D Spatial Information Open-platform**. 2018 International Conference on Information and Communication Technology Convergence (ICTC). **Anais...** Em: 2018 INTERNATIONAL CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGY CONVERGENCE (ICTC). out. 2018.

LEELA, S. J.; ROH, M.-I.; OHB, M. J. Image-based ship detection using deep learning. **Ocean Systems Engineering**, v. 10, 2020.

LI, Y. et al. **SAR Ship Detection Based on Resnet and Transfer Learning**. IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium. **Anais...** Em: IGARSS 2019 - 2019 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. jul. 2019.

LIU, W. et al. **SSD: Single Shot MultiBox Detector**. (B. Leibe et al., Eds.) Computer Vision – ECCV 2016. **Anais...**: Lecture Notes in Computer Science. Cham: Springer International Publishing, 2016.

MAGALHÃES, M. E. DE et al. Improving Maritime Domain Awareness in Brazil through Computer Vision Technology. **Journal of Marine Science and Engineering**, v. 11, n. 7, p. 1272, jul. 2023.

MARCH, S. T.; SMITH, G. F. Design and natural science research on information technology. **Decision support systems**, v. 15, n. 4, p. 251–266, 1995.

MARTELLI, M. et al. An Outlook on the Future Marine Traffic Management System for Autonomous Ships. **IEEE Access**, v. 9, p. 157316–157328, 2021.

MURRAY, F. et al. Data challenges and opportunities for environmental management of North Sea oil and gas decommissioning in an era of blue growth. **Marine Policy**, 2018.

NATIONAL COMMISSION ON TERRORIST ATTACKS. **The 9/11 Commission Report: Final Report of the National Commission on Terrorist Attacks Upon the United States (Authorized Audio Edition, Abridged)**. [s.l.] W. W. Norton, 2011.

NIEMEYER, G. **Geohash**. Disponível em:
<<https://web.archive.org/web/20120112004608/http://www.bigfastblog.com/geohash-intro>>. Acesso em: 2 jan. 2020.

PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on knowledge and data engineering**, v. 22, n. 10, p. 1345–1359, 2010.

PEFFERS, K.; ROTHENBERGER, M.; KUECHLER, B. **Design Science Research in Information Systems. Advances in Theory and Practice: 7th International Conference, DESRIST 2012, Las Vegas, NV, USA, May 14-15, 2012. Proceedings**. [s.l.: s.n.]. v. 7286

PLACHKOV, A. et al. **Automatic Course of Action Generation Using Soft Data for Maritime Domain Awareness**. Proceedings of the 2016 on Genetic and Evolutionary Computation Conference Companion. **Anais...: GECCO '16 Companion**. New York, NY, USA: ACM, 2016. Disponível em: <<http://doi.acm.org/10.1145/2908961.2931678>>. Acesso em: 12 nov. 2018

PRASAD, D. K. et al. Video Processing From Electro-Optical Sensors for Object Detection and Tracking in a Maritime Environment: A Survey. **IEEE Transactions on Intelligent Transportation Systems**, v. 18, n. 8, p. 1993–2016, ago. 2017.

REDMON, J. et al. **You only look once: Unified, real-time object detection**. Proceedings of the IEEE conference on computer vision and pattern recognition. **Anais...2016**.

REDMON, J.; FARHADI, A. Yolov3: An incremental improvement. **arXiv preprint arXiv:1804.02767**, 2018.

RICOLFE-VIALA, C.; SÁNCHEZ-SALMERÓN, A.-J. Using the camera pin-hole model restrictions to calibrate the lens distortion model. **Optics & Laser Technology**, v. 43, n. 6, p. 996–1005, 1 set. 2011.

RUSSELL, B. C. et al. LabelMe: A Database and Web-Based Tool for Image Annotation. **International Journal of Computer Vision**, v. 77, n. 1, p. 157–173, 1 maio 2008.

SANTIPANTAKIS, G. M. et al. A Stream Reasoning System for Maritime Monitoring. **Submitted for publication**, 2018.

SEKACHEV, B. et al. **Computer Vision Annotation Tool (CVAT)**. Zenodo, , 31 ago. 2020. Disponível em: <<https://zenodo.org/record/4009388>>. Acesso em: 7 jul. 2023

SHAO, Z. et al. SeaShips: A Large-Scale Precisely Annotated Dataset for Ship Detection. **IEEE Transactions on Multimedia**, v. 20, n. 10, p. 2593–2604, out. 2018.

SHELMERDINE, R. L. Teasing out the detail: How our understanding of marine AIS data can better inform industries, developments, and planning. **Marine Policy**, v. 54, p. 17–25, 2015.

SIMONSEN, C. et al. **Detecting and Locating Boats using a PTZ Camera with Both Optical and Thermal Sensors**. 1 jan. 2020.

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

SNIDARO, L.; VISENTINI, I.; BRYAN, K. Fusing uncertain knowledge and evidence for maritime situational awareness via Markov Logic Networks. **Information Fusion**, v. 21, p. 159–172, 2015.

SOARES, A. et al. CRISIS: Integrating AIS and Ocean Data Streams Using Semantic Web Standards for Event Detection. maio 2019.

SURASAK, T. et al. **Histogram of oriented gradients for human detection in video**. 2018 5th International Conference on Business and Industrial Research (ICBIR). **Anais...** Em: 2018 5TH INTERNATIONAL CONFERENCE ON BUSINESS AND INDUSTRIAL RESEARCH (ICBIR). maio 2018.

TORI, R.; KIRNER, C.; SISCOOTTO, R. A. **Fundamentos e tecnologia de realidade virtual e aumentada**. [s.l.] Editora SBC Porto Alegre, 2006.

UNITED STATES DEPARTMENT OF STATE. **U.S. Relations With Brazil**. Disponível em: <<https://www.state.gov/u-s-relations-with-brazil/>>. Acesso em: 5 ago. 2023.

VETTOR, R.; SOARES, C. G. Detection and analysis of the main routes of voluntary observing ships in the North Atlantic. **The Journal of Navigation**, v. 68, n. 2, p. 397–410, 2015.

VICENTE, R. et al. Earth Observations for Goal 14: Improving Maritime Domain Awareness Using Synthetic Aperture Radar Imaging with Automatic Identification System in the Philippines. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLIII-B3-2020, p. 215–219, 21 ago. 2020.

VONDRICK, C.; PATTERSON, D.; RAMANAN, D. Efficiently Scaling up Crowdsourced Video Annotation. **International Journal of Computer Vision**, v. 101, n. 1, p. 184–204, 1 jan. 2013.

WANG, Y. et al. Automatic Ship Detection Based on RetinaNet Using Multi-Resolution Gaofen-3 Imagery. **Remote Sensing**, v. 11, n. 5, p. 531, jan. 2019.

YANG, Y.; YAN, R.; WANG, S. Integrating Shipping Domain Knowledge into Computer Vision Models for Maritime Transportation. **Journal of Marine Science and Engineering**, v. 10, n. 12, p. 1885, dez. 2022.

ZHAO, L.; SHI, G.; YANG, J. Ship trajectories pre-processing based on AIS data. **The Journal of Navigation**, v. 71, n. 5, p. 1210–1230, 2018.

ZHENG, Y.; ZHANG, S. **Mcships: A Large-Scale Ship Dataset For Detection And Fine-Grained Categorization In The Wild**. 2020 IEEE International Conference on Multimedia and Expo (ICME). **Anais...** Em: 2020 IEEE INTERNATIONAL CONFERENCE ON MULTIMEDIA AND EXPO (ICME). jul. 2020.

ZHOU, Y. et al. Spatial Indexing for Data Searching in Mobile Sensing Environments. **Sensors**, v. 17, p. 1427, 18 jun. 2017.