

Aprendizado de Máquina Aplicado a Detecção de Navios e ao Derramamento de Óleo ao Mar Via Satélites Ópticos e de Radar de Abertura Sintética: Uma perspectiva para a vigilância automatizada das águas jurisdicionais brasileiras

Resumo – Este estudo propõe uma abordagem inovadora para a vigilância das Águas Jurisdicionais Brasileiras, visando a detecção de navios e vazamentos de óleo através da integração de técnicas de aprendizado de máquina com imagens de satélite SAR e óptico. A metodologia empregada envolveu a coleta e processamento de dados de imagens de satélite, o desenvolvimento de algoritmos especializados e a avaliação do desempenho dos modelos propostos. Os resultados obtidos demonstram uma alta precisão na detecção de navios e derramamentos de óleo, destacando a eficácia da abordagem proposta. Esses resultados sugerem que a integração de aprendizado de máquina com imagens de satélite pode fornecer uma ferramenta poderosa para a vigilância marítima automatizada, com potenciais implicações para a segurança nacional e a proteção ambiental. No entanto, é necessário considerar melhorias futuras, especialmente na qualidade das imagens de satélite SAR, em ordem de aprimorar a eficiência e confiabilidade dos sistemas de vigilância marítima.

Palavras-Chave – Aprendizado de Máquina, Detecção de Navios, Derramamento de Óleo, Sistemas Satelitais.

I. INTRODUÇÃO

As Águas Jurisdicionais Brasileiras desempenham um papel de suma importância no contexto nacional, representando não apenas, ampla extensão territorial, mas também um recurso estratégico vital para o Brasil. Conhecidas como Amazônia Azul, essas águas abrigam uma riqueza incomparável de recursos naturais, incluindo petróleo, gás natural e uma biodiversidade marinha exuberante, fundamentais para a segurança energética, econômica e ambiental do país [1]. Diante dessa perspectiva, é imprescindível compreender e proteger adequadamente esse patrimônio marítimo, o que demanda não apenas políticas e regulamentações eficazes, mas também sistemas de vigilância robustos e tecnologicamente avançados [2].

A Referência [3] sobre o impacto devastador de vazamentos de óleo no Porto de Nova York ressalta os consideráveis danos ambientais que podem afetar ecossistemas sensíveis, destacando a urgência de medidas eficazes de vigilância e resposta para mitigar tais incidentes e proteger o ambiente marinho.

A Referência [4] também enfatiza a importância crítica da vigilância marítima na salvaguarda da segurança nacional, ao abordar as preocupações sobre a proteção da infraestrutura marítima vital para o comércio global. Assim, é ressaltada a

necessidade premente de aprimorar os sistemas de inteligência, monitoramento e resposta para assegurar a segurança das águas jurisdicionais.

Nesse contexto, diante da crescente complexidade dos desafios enfrentados na vigilância das águas jurisdicionais brasileiras, impulsionados pela expansão das atividades marítimas e pela necessidade de proteger o meio ambiente marinho, surge a demanda por soluções inovadoras e eficazes. O governo brasileiro demonstra interesse no desenvolvimento de pesquisas na área, como evidenciado pelo Plano de Ações para a Neoliberalização, com o objetivo de fomentar a criação de tecnologias de interesse para a soberania e a defesa nacionais [5].

Ao integrar algoritmos de inteligência artificial, como aprendizado de máquina, aos métodos tradicionais de vigilância, busca-se aprimorar a capacidade de detecção, permitindo uma resposta mais rápida e precisa a atividades suspeitas [6]. No entanto, é importante ressaltar que as imagens convencionais de satélite apresentam limitações quanto a penetração em nuvens e imageamento em baixas condições de luminosidade, ao passo que o Radar de Abertura Sintética (SAR) oferece vantagens significativas nesse aspecto [7]. Portanto, a combinação de satélites ópticos e que empregam SAR, aliada ao aprendizado de máquina, emerge como uma abordagem promissora para a vigilância automatizada das águas jurisdicionais brasileiras, permitindo não apenas uma detecção mais eficiente, mas também a capacidade de identificar padrões e ameaças de forma automatizada, contribuindo para uma resposta ágil e precisa.

Esta pesquisa tem como objetivo principal analisar e fornecer soluções práticas para os desafios enfrentados na vigilância das águas jurisdicionais brasileiras. Busca-se, em particular, abordar a detecção de navios e derramamentos de óleo ao mar, com potencial para impactar positivamente a segurança nacional, a proteção ambiental e a gestão sustentável dos recursos marinhos, haja vista a necessidade de soluções eficientes que possam agilizar o reconhecimento de embarcações suspeitas e a detecção de incidentes de poluição marinha.

II. OBJETIVOS

Desenvolver um modelo abrangente de vigilância marítima utilizando técnicas de aprendizado de máquina e imagens de satélite SAR e óptico para o reconhecimento de navios e detecção de vazamentos de óleo, visando contribuir

significativamente para a segurança nacional e a proteção do meio ambiente marinho.

Objetivos específicos:

- Coletar e processar dados de imagens de satélite SAR e óptico, garantindo uma base de dados abrangente para análise.
- Desenvolver algoritmos de processamento de imagem especializados para identificação e classificação precisa de navios.
- Implementar e aprimorar técnicas avançadas de aprendizado de máquina para o reconhecimento automático de padrões associados a vazamentos de óleo.
- Avaliar a eficácia e a precisão do modelo desenvolvido por meio de testes e validações utilizando conjuntos de dados reais, contemplando tanto imagens de satélite SAR quanto óptico.
- Propor melhorias e recomendações específicas para o aprimoramento contínuo do modelo de vigilância marítima, visando sua implementação e utilização em larga escala nas Águas Jurisdicionais Brasileiras.

III. METODOLOGIA

Este estudo emprega uma abordagem quantitativa para avaliar a precisão do aprendizado de máquina na identificação de navios e derramamentos de óleo em imagens de satélite ópticas e de radar de abertura sintética (SAR). As informações foram obtidas por meio de imagens captadas pela constelações de satélites *Dove* e *SkySat*, disponibilizadas pela plataforma Planet [8], assim como a Referência [9], que aborda o mapeamento de derramamentos de óleo usando imagens de SAR, e a Referência [10], do qual trata do processamento de imagens SAR para melhor resolução. Ferramentas de programação em *Python* para o aprendizado de máquina, como U-Net, YOLO (You Only Look Once) e CNN (Convolutional Neural Network), foram empregadas para desenvolver e implementar os algoritmos de aprendizado de máquina. A análise dos resultados foi conduzida utilizando a biblioteca *Matplotlib*. Este trabalho é caracterizado como um estudo de caso, onde os dados coletados são provenientes de pesquisas de campo. A aplicação de técnicas avançadas de aprendizado de máquina em imagens de satélite oferece a oportunidade de desenvolver modelos eficazes, os quais fazem o reconhecimento de forma rápida e eficiente.

IV. DESENVOLVIMENTO

A. Satélites e Captura de Imagens

Os satélites desempenham uma função crucial na obtenção de imagens da Terra através de sistemas de imagem avançados e telescópios especialmente projetados [11]. Esses sistemas incluem câmeras de varredura linear em sua órbita específica e telescópios que capturam luz refletida pela Terra em diversas bandas espectrais, como visível, infravermelho e térmico.




Fig. 1. Satélites Constelação Dove [12]

Estes satélites possuem câmeras usadas para capturar imagens, rodas de reação (*reaction wheels*) para controle de orientação, circuitos (*circuitry*) para coordenar operações, painéis solares (*solar pannels*) para energia e baterias (*batteries*) para períodos sem luz solar e antenas de rádio (*radio antenna*) permitem comunicação com a Terra, que com capacidades direcionais, podem varrer diferentes áreas.




Fig. 2. Baía de São Francisco Capturada pela Constelação Dove [8]

As imagens captadas pelos satélites são então processadas por sistemas especializados em solo, desempenhando um papel vital no monitoramento climático, previsão de eventos meteorológicos e estudo de mudanças ambientais globais.

B. Radar de Abertura Sintética (SAR)

Radar de Abertura Sintética (SAR) é uma tecnologia de sensoriamento remoto que emprega ondas de rádio para gerar imagens detalhadas da superfície terrestre. Diferentemente do sensoriamento óptico, o SAR é independente da luz solar direta e capaz de penetrar nuvens e outras obstruções atmosféricas.




Fig. 3. Radar de Abertura Sintética em Satélites [13]

O funcionamento de um satélite equipado com SAR envolve a emissão de pulsos de radar (*incident radar pulse*) em direção à superfície terrestre (*ground targets*) a partir de uma antena montada no mesmo (*SAR antenna*). Estes pulsos

de radar são refletidos por objetos e terrenos na superfície (*backscattered radar pulse*), retornando à antena do satélite. Ao mensurar o tempo de ida e volta dos pulsos, juntamente com a posição do satélite, é possível determinar a distância e a localização dos objetos na superfície.




Fig. 4. Imagem Capturada Através de Radar de Abertura Sintética [10]

A alta resolução das imagens SAR é alcançada através da técnica de abertura sintética. Ao contrário das antenas de radar convencionais limitadas pelo tamanho, o SAR simula uma antena maior movendo-se em uma trajetória conhecida, criando uma abertura sintética equivalente a uma antena maior, resultando em maior resolução na imagem final.

C. Aprendizado de Máquina e Aplicação em Satélites

Aprendizado de Máquina é uma área da inteligência artificial que visa ensinar computadores a aprender com dados, reconhecendo padrões para fazer previsões ou tomar decisões, ao contrário da programação tradicional, onde seguem instruções específicas [14]. Já sendo amplamente aplicado na análise de imagens de satélites, segundo a Referência [15], essa abordagem é eficaz para processar e extrair informações úteis dessas imagens.

Algoritmos de aprendizado de máquina automaticamente aprendem características importantes em imagens de satélite, como formas, texturas e padrões. Sua automação permite o monitoramento em larga escala de mudanças na cobertura terrestre, detecção de mudanças ambientais e previsão de eventos naturais [16].

D. Parâmetros de Programação

Ao desenvolver os códigos para detecção de navios em imagens de satélite, seja utilizando tecnologia SAR (Synthetic Aperture Radar) ou óptica, bem como para identificação de derramamentos de óleo ao mar com satélites SAR, adotou-se uma abordagem sistemática para atingir os objetivos específicos do trabalho. Os três códigos analisados aqui abordam diferentes problemas de detecção e segmentação em imagens marítimas utilizando técnicas avançadas de visão computacional e aprendizado profundo.

Cada código é especializado em um tipo de imagem e tarefa específica: detecção de navios em imagens de radar de abertura sintética (SAR) usando o modelo YOLO, detecção de derramamento de óleo em imagens usando uma rede

U-Net, e detecção de navios em imagens de satélite usando uma rede neural convolucional (CNN).

Inicialmente, foram importadas as bibliotecas necessárias para processamento de dados e implementação dos modelos de detecção de objetos. Para a detecção de navios, foram utilizadas as bibliotecas PyLabel e Ultralytics para lidar com anotações de imagem e implementar o modelo YOLO (You Only Look Once), conhecido por sua eficácia em tempo real [17]. Para a detecção de derramamentos de óleo, a arquitetura U-Net foi adotada devido à sua eficácia comprovada em problemas de segmentação semântica [18]. Para a detecção de navios em imagens de satélite usando uma CNN, foram importadas bibliotecas adicionais como TensorFlow e Keras para construção e treinamento da rede.

O primeiro código utiliza o modelo YOLO (You Only Look Once), especificamente a versão YOLOv8n, para detectar navios em imagens SAR. O modelo YOLO é amplamente conhecido por sua eficiência em tempo real na detecção de objetos e é adequado para aplicações em que a velocidade de inferência é crucial. Este código começa instalando as bibliotecas necessárias, como PyLabel e Ultralytics, que são essenciais para o processamento de anotações e a implementação do YOLO, respectivamente. Em seguida, são definidas funções para manipulação de dados, como a extração de imagens de diretórios e a conversão de anotações do formato COCO para o formato YOLO, utilizando a biblioteca PyLabel. Com os dados prontos, o código cria um arquivo de configuração YAML que especifica os caminhos dos dados, o número de classes e o tamanho do lote. O modelo YOLO é então inicializado com esta configuração e treinado por 10 épocas utilizando imagens de 640x640 pixels. Este pipeline é eficaz para detecção de objetos em imagens SAR, aproveitando a velocidade e precisão do YOLO.

O segundo código implementa uma rede U-Net para segmentação de imagens com o objetivo de detectar derramamentos de óleo. A U-Net é uma arquitetura utilizada em segmentação semântica, ideal em tarefas de mapeamento de pixel-para-pixel, como a identificação de derramamentos de óleo em imagens. O código começa importando bibliotecas para manipulação de dados (numpy, pandas), visualização (matplotlib, seaborn), processamento de imagens (cv2, PIL, skimage) e aprendizado de máquina (TensorFlow, Keras). Em seguida, as imagens e máscaras são carregadas de diretórios específicos, redimensionadas e normalizadas. As máscaras são processadas para converter cores RGB em índices de classe usando um mapa de cores definido. Após a exploração inicial dos dados de treinamento, a U-Net é configurada com camadas de convolução, pooling e upsampling para segmentação. O modelo é treinado por 100 épocas com um tamanho de lote de 16, utilizando a função de perda `categorical_crossentropy` e o otimizador Adam. Durante o treinamento, o código monitora a perda e precisão tanto nos conjuntos de treinamento quanto de validação, e exibe as predições em imagens de teste para avaliação.

O terceiro código utiliza uma rede neural convolucional (CNN) para a detecção de navios em imagens de satélite. A CNN é uma escolha popular para tarefas de classificação de imagens devido à sua capacidade de aprender características

complexas a partir de imagens de entrada. O código começa importando uma série de bibliotecas, incluindo pandas, numpy, skimage, matplotlib, seaborn, sklearn e TensorFlow. Ele carrega os dados de um arquivo JSON e os converte para um formato adequado para uma CNN, transformando as imagens de um formato plano para um array de 3 dimensões (RGB). As imagens são normalizadas e divididas em conjuntos de treinamento e teste. A arquitetura da CNN é então definida, consistindo em camadas de convolução 2D, pooling e camadas densas, com a última camada sendo uma softmax para classificação multi-classe. O modelo é treinado por 10 épocas utilizando o otimizador Adam e a função de perda `sparse_categorical_crossentropy`.

A visualização e pré-processamento dos dados, incluindo extração de imagens, conversão de anotações e organização dos conjuntos de treinamento e teste foram cruciais para preparar os dados para treinamento dos modelos, como se pode notar na Figura 5.




Fig. 5. Dados Processados [19]

Em seguida, foram definidas as arquiteturas dos modelos: YOLO para detecção de navios em SAR, CNN (Convolutional Neural Network) para detecção de navios em tecnologia de satélites ópticos, e U-Net para detecção de derramamentos de óleo. Toda arquitetura foi definida com base na natureza dos dados que a mesma iria processar. Assim, foram configurados otimizadores, funções de perda e métricas de avaliação relevantes para suas respectivas tarefas, conforme ilustrado na Figura 6.

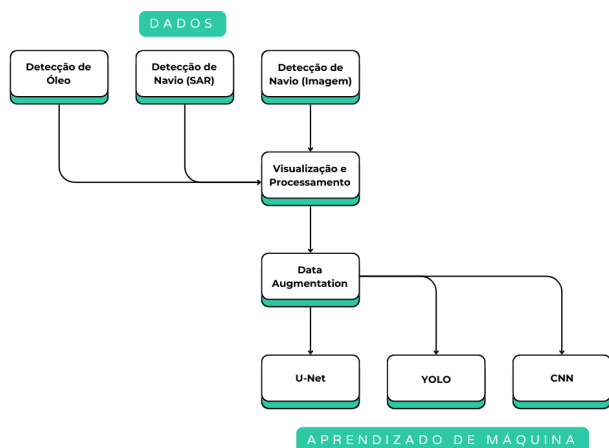


Fig. 6. Fluxograma do Processo de Desenvolvimento da Programação [19]

Para evitar o overfitting e ampliar a diversidade dos dados, foram aplicadas transformações aleatórias às imagens de entrada, como rotação, espelhamento, translação, mudanças na escala, entre outras. Ao incorporar essas

variações nos dados de treinamento, o modelo é exposto a diferentes perspectivas das mesmas informações, o que ajuda a melhorar sua capacidade de generalização e a reduzir o risco de overfitting. Esta técnica é conhecida como data augmentation. Após o treinamento, os modelos foram avaliados utilizando conjuntos de teste, e métricas de desempenho como precisão, recall e F1-score foram calculadas para avaliar sua eficácia na detecção de navios ou derramamentos de óleo.

Como se pode notar na Figura 7, o processo de desenvolvimento do sistema programado segue uma sequência lógica de etapas que incluem a coleta e pré-processamento de dados, o treinamento de modelos de aprendizado de máquina, a validação dos resultados, a integração do sistema e os aprimoramentos contínuos. Este fluxo de trabalho estruturado garante que os modelos sejam desenvolvidos de maneira eficiente e adaptativa, permitindo melhorias contínuas baseadas na validação e análise dos resultados.



Fig. 7. Esquematização do Sistema Programado [19]

Por fim, foram geradas visualizações dos resultados para permitir uma avaliação detalhada do desempenho dos modelos. Acompanhando tais métricas, torna-se possível, determinar a qualidade do aprendizado. Esses resultados são fundamentais para identificar áreas de melhoria e ajustes necessários visando aprimorar a precisão e o desempenho dos modelos em futuras iterações.

V. RESULTADOS

Para avaliar o desempenho dos modelos, as métricas desempenham um papel fundamental na análise da eficácia e precisão das soluções propostas. Precisão, *recall* e *F1 Score* fornecem uma medida abrangente do desempenho dos modelos, considerando tanto a capacidade de identificar corretamente os incidentes quanto a capacidade de minimizar falsos positivos e negativos.

TABELA I. DESEMPENHO DOS MODELOS

	<i>Precisão</i>	<i>Recall</i>	<i>F1 Score</i>
Detecção de Óleo	94,84%	95,33%	95%

	<i>Precisão</i>	<i>Recall</i>	<i>F1 Score</i>
Deteção de Navio (Imagem)	97%	93%	95%
Deteção de Navio (SAR)	88,24%	76,83%	82,16%

Para a deteção de derramamentos de óleo ao mar, o modelo alcançou uma precisão de 94.84%, *recall* de 95.33% e um *F1 Score* de 95%. Esses resultados destacam a eficácia do modelo na identificação precisa de incidentes de poluição marinha, fornecendo uma base sólida para uma resposta rápida e eficiente a tais eventos, minimizando assim os impactos ambientais.

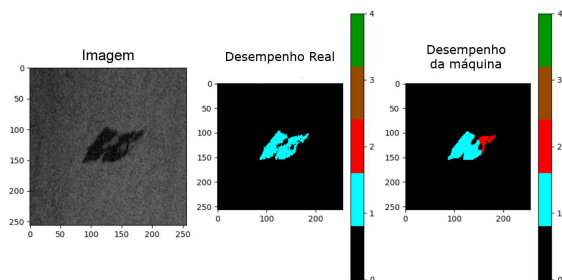


Fig. 8. Predição do modelo para deteção de óleo [19]

No que diz respeito à deteção de navios por meio de imagens de satélite óptico, o modelo apresentou uma precisão de 97%, *recall* de 93%, e um *F1 Score* de 95%. Esses resultados demonstram a capacidade do modelo em identificar embarcações com alta precisão, contribuindo para o monitoramento e controle do tráfego marítimo nas águas jurisdicionais brasileiras.



Fig. 9. Predição do modelo para deteção de navio por imagens [19]

Por fim, para a deteção de navios utilizando tecnologia SAR, o modelo atingiu uma precisão de 88.24% e *recall* de 76.83%. Embora os resultados mostrem uma menor taxa de *recall* em comparação com o modelo de deteção de navios por satélite óptico, ainda assim fornecem uma contribuição valiosa para a vigilância marítima, especialmente em condições adversas de visibilidade, onde o SAR oferece vantagens significativas.




Fig. 10. Predição do modelo para deteção de navio por SAR [19]

Os resultados validam a eficácia da abordagem proposta, que combina o uso de algoritmos de aprendizado de máquina com imagens de satélite SAR e óptico para a vigilância automatizada das águas jurisdicionais brasileiras. A precisão alcançada pelos modelos demonstra sua utilidade potencial na identificação precoce de atividades suspeitas, como vazamentos de óleo e navegação não autorizada, permitindo uma resposta rápida e eficaz para garantir a segurança e proteção do meio ambiente marinho.

VI. OBSERVAÇÕES FINAIS

A coleta e o processamento de dados de imagens de satélite SAR e óptico foram realizados com sucesso, garantindo uma base de dados abrangente para análise. Isso permitiu a implementação e o treinamento de algoritmos de processamento de imagem especializados para a identificação e classificação precisa de navios. Da mesma forma, a implementação e o aprimoramento de técnicas avançadas de aprendizado de máquina para o reconhecimento automático de padrões associados a vazamentos de óleo foram bem-sucedidos, como evidenciado pelos resultados alcançados.

A avaliação da eficácia e precisão do modelo desenvolvido, contemplando conjuntos de dados reais de imagens de satélite SAR e óptico, revelou resultados promissores, destacando a utilidade potencial do modelo na deteção de navios e derramamentos de óleo. Assim, foi demonstrada a viabilidade e a eficácia da integração de técnicas de aprendizado de máquina com imagens de satélite para a vigilância marítima. Isso pode ter implicações importantes para a segurança nacional, a proteção ambiental e a gestão sustentável dos recursos marinhos não apenas no Brasil, mas também em outras regiões costeiras do mundo.

Os menores índices de precisão, *recall* e *F1 Score* do modelo em SAR, em comparação com os modelos ópticos, destacam a necessidade de evolução do SAR para melhorar o reconhecimento de navios e derramamentos de óleo. Futuras melhorias devem incluir avanços na qualidade da resolução das imagens de satélite SAR e óptico, contribuindo para aprimorar os modelos de deteção. Com a melhoria da

qualidade das imagens, o aprendizado de máquina será mais capaz de realizar reconhecimentos precisos, aumentando a eficiência dos sistemas de vigilância marítima automatizada.

REFERÊNCIAS

- [1] MEDEIROS, Jorge Luiz Mesquita. A Amazônia Azul e a geopolítica brasileira: a Marinha do Brasil na defesa da Amazônia Azul. 2008. Monografia (Curso de Estado-Maior para Oficiais Superiores) - Escola de Guerra Naval.
- [2] INÁCIO, Laerte. A Importância da Atuação da Marinha do Brasil na Vigilância e na Defesa dos Recursos Naturais Existentes na Amazônia Azul. 2009. Monografia (Curso de Estado-Maior para Oficiais Superiores) - Escola de Guerra Naval.
- [3] BURGER, Joanna. Before and After an Oil Spill: The Arthur Kill. Nova Jersey: Rutgers University Press, 1994.
- [4] LUCAS, Edward. Maritime security : counter-terrorism lessons from maritime piracy and narcotics interdiction. Amsterdã: IOS Press, 2020.
- [5] MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA, COMÉRCIO E SERVIÇOS. Nova Indústria Brasil é marco para a retomada do setor. Disponível em: <https://www.gov.br/mdic/pt-br/assuntos/noticias/2024/janeiro/nova-industria-brasil-e-marco-para-a-retomada-do-setor>. Acesso em: 01/02/2024.
- [6] VIKRAM, Bali. Industry 4.0, AI, and Data Science: Research Trends and Challenges. Flórida: CRC Press, 2021.
- [7] MAÎTRE, Henri. Processing of synthetic aperture radar (SAR) images. Nova Jersey: John Wiley & Sons, 2008.
- [8] PLANET. Daily Satellite Imagery and Insights. Disponível em: <https://www.planet.com>. Acesso em: 05/02/2024.
- [9] KRESTENITIS, Marios et al. Oil spill identification from satellite images using deep neural networks. Remote Sensing, v. 11, n. 15, p. 1762, 2019.
- [10] WEI, Shunjun et al. HRSID: A high-resolution SAR images dataset for ship detection and instance segmentation. IEEE Access, v. 8, p. 120234-120254, 2020.
- [11] LILLESAND, Thomas; KIEFER, Ralph W.CHIPMAN, Jonathan. Remote sensing and image interpretation. Nova Iorque: John Wiley & Sons, 2015.
- [12] KINGSBURY, Ryan W. et al. Dove GPS: An Unconventional Approach to CubeSat Orbit Determination. Proceedings of the 32nd International Technical Meeting of the Satellite Division of The Institute of Navigation, p. 1157-1163, 2019.
- [13] CENTER FOR REMOTE IMAGING, SENSING AND PROCESSING. Principles of Remote Sensing. Disponível em: <https://crisp.nus.edu.sg/~research/tutorial/mw.htm>. Acesso em: 18/02/2024.
- [14] ZHOU, Zhi-Hua. Machine learning. Berlim: Springer nature, 2021.
- [15] HEMANTH, D. Jude. Artificial intelligence techniques for satellite image analysis. Berlim: Springer, 2020.
- [16] OUCHRA, Hafsa; BELANGOUR, Abdessamad; ERRAISSI, Allae. Machine learning for satellite image classification: A comprehensive review. 2022 International Conference on Data Analytics for Business and Industry (ICDABI). IEEE, p. 1-5. 2020
- [17] JIANG, Peiyuan et al. A Review of Yolo algorithm developments. Procedia computer science, v. 199, p. 1066-1073, 2022.
- [18] GUO, Changlu et al. Sa-unet: Spatial attention u-net for retinal vessel segmentation. 25th international conference on pattern recognition (ICPR). IEEE, p. 1236-1242. 2021.
- [19] O Autor.