

AVALIAÇÃO DAS IMAGENS SAR/SENTINEL-1 PARA IDENTIFICAÇÃO DE GARIMPOS DE OURO EMBARCADOS POR MEIO DE ALGORITMOS DE DETECÇÃO DE EMBARCAÇÕES

Diego Henrique Costa Pereira

Universidade de Brasília – UNB
Programa de Pós-Graduação em Geografia, Brasília, DF, Brasil
diegohcpereira1988@gmail.com

Roberto Arnaldo Trancoso Gomes

Universidade de Brasília – UNB
Programa de Pós-Graduação em Geografia, Brasília, DF, Brasil
robertogomes@unb.br

Osmar Abílio de Carvalho Júnior

Universidade de Brasília – UNB
Programa de Pós-Graduação em Geografia, Brasília, DF, Brasil
osmarjr@unb.br

Renato Fontes Guimarães

Universidade de Brasília – UNB
Programa de Pós-Graduação em Geografia, Brasília, DF, Brasil
renatofg@unb.br

RESUMO

A garimpagem de ouro no Brasil pode ser realizada em terra firme ou nos leitos dos rios. Nesse sentido, garimpos embarcados são embarcações que dragam sedimentos de fundo dos rios para produção do ouro mediante uso de maquinário pesado. O uso de imagens de *Synthetic Aperture Radar* (SAR) para detecção de embarcações vem ganhando destaque devido à disponibilização gratuita de imagens de melhor qualidade e com melhor resolução temporal e à menor influência de fatores atmosféricos nas imagens, o que permite seu uso em locais com densa cobertura de nuvens. Mediante inexistência de técnicas específicas para detecção de garimpos embarcados, métodos com imagens SAR apresentam-se com uma alternativa. Assim, este estudo objetivou identificar garimpos de ouro embarcados no Rio Madeira, em Porto Velho, em sete imagens Sentinel-1 entre 2018 e 2021, por meio do uso de algoritmos *Constant False Alarm Rate* (CFAR) e de avaliação geométrica. Foram gerados *score* F1 entre 0,76 e 0,86, com percentual médio de detecção de 89,7%, e de omissão de 10,3%. Ainda, foram identificados garimpos em áreas legais e em áreas potencialmente ilegais. Portanto, o método pode fornecer subsídios para os órgãos de controle otimizarem sua atuação frente à atividade.

Palavras-chave: Imagens SAR. Garimpos de ouro em rios. Algoritmo Constant False Alarm Rate.

EVALUATION OF SAR/SENTINEL-1 IMAGES FOR IDENTIFICATION OF GOLD MINING VESSELS BASED ON VESSEL DETECTION ALGORITHMS

ABSTRACT

Artisanal and Small-Scale Gold in Brazil can be conducted on dry land or riverbeds. In this context, Artisanal and Small-Scale Gold mining vessels dredge sediment from the riverbeds to extract gold using heavy machinery. Synthetic Aperture Radar (SAR) imagery for detecting these vessels has been gaining prominence due to the availability of higher quality images with better temporal resolution and less influence from atmospheric factors, allowing their use in areas with dense cloud cover. Given the absence of specific techniques for detecting gold mining vessels, SAR imagery methods present themselves as an alternative. Therefore, this study aimed to identify gold mining vessels on the Madeira River in Porto Velho using seven Sentinel-1 images from 2018 to 2021, employing Constant False Alarm Rate (CFAR) and geometric evaluation algorithms. The results generated F1 scores from 0.76 to 0.86, with an average detection rate of 89.7% and an omission rate of 10.3%. Gold mining vessels were

also identified in legal and potentially illegal areas. Thus, this study can provide valuable information for regulatory agencies to optimize their efforts in overseeing this activity.

Keywords: SAR images. Artisanal and small-scale gold mining in rivers. Constant False Alarm Rate algorithm.

INTRODUÇÃO

A garimpagem de ouro está presente no Brasil há muito tempo e, atualmente, produz em torno de 19 toneladas/ano, levando em consideração somente a produção formalmente declarada (BRASIL, 2021). A legislação brasileira estabelece que um garimpo de ouro deve possuir a Permissão de Lavra Garimpeira (PLG) para que possa operar de forma legal, juntamente com licença ambiental (BRASIL, 1989), podendo ocorrer em terra firme e em rios. Conforme exposto por Balzino et al. (2015), a garimpagem de ouro em rios ocorre por meio de embarcações que dragam sedimentos de fundo dos rios para produção do ouro mediante uso de maquinário pesado e que apresentam comportamento típico de se agrupar e ficarem fixos durante sua operação, formando aglomerados de embarcações (Figura 1).

Figura 1 - Garimpos Embarcados no Rio Madeira.



Fonte - IBAMA (2017); G1 (2022).

Existem diversos métodos baseados em sensoriamento remoto que objetivam identificar garimpos em áreas terrestres. Isidro et al. (2017) empregaram o classificador supervisionado em imagens dos satélites Spot. Simionato, Bertani e Osako (2021) implementaram técnicas de mineração de dados para definição de critérios de classificação de pixels e classificaram imagens Sentinel-2 com base em árvore de decisão. Asner et al. (2013) fizeram uso de imagens Landat-7 e de fotografias aéreas de alta resolução para realizar identificação visual dos garimpos. Contudo, inexistem métodos dedicados exclusivamente à identificação de garimpos embarcados devido a fatores desafiadores.

Lobo et al. (2018) e Trindade e Barbosa Filho (2002) destacam que o tamanho reduzido dos garimpos embarcados e sua alta capacidade de locomoção dificultam o emprego de sensoriamento remoto para identificação destes alvos. Complementarmente, Dechesne et al. (2019) ressalta a inexistência de sistemas de localização automática e em tempo real como um desafio adicional para identificação de pequenas embarcações, pois se torna mais difícil de localizar tais embarcações nas imagens. A questão levantada por Dechesne et al. (2019) pode ser contextualizada à realidade dos garimpos brasileiros por meio de elementos apresentados por Cetem (2018), que ao realizar profunda discussão sobre garimpos no Brasil, pontuou que grande parte das atividades ocorre na região Amazônica, de forma informal e em condições precárias e em embarcações de pequeno porte – o que pode justificar a inexistência de sistemas de localização para a realidade dos garimpos embarcados brasileiros. Além disso, a densa e recorrente cobertura de nuvens na Amazônia inviabiliza o uso de imagens de sensores passivos, como os sensores óticos, em grande parte do ano (MARTINS et al., 2018).

Nesse contexto, a adoção de imagens de Radar de Abertura Sintética, em inglês *Synthetic Aperture Radar* (SAR), ganhou impulso devido à melhoria da resolução espacial e temporal, à redução da interferência atmosférica que possibilita seu uso em áreas cobertas por nuvens e à redução/eliminação de custos (ESA, 2012). Merece destaque a missão Sentinel-1, coordenada pela Agência Espacial Europeia (ESA), composta por dois satélites que geram imagens SAR na banda C do micro-ondas

(5.405 GHz) com tempo de revisita de 5 a 12 dias, resolução espacial de 5 a 40 m e quatro polarizações distintas: VV, VH, HV e HH. Os produtos Sentinel-1 são disponibilizados gratuitamente e é disponibilizado *software* específico para realizar as etapas de pré-processamento e outras análises dos produtos, chamado SNAP (ESA, 2012).

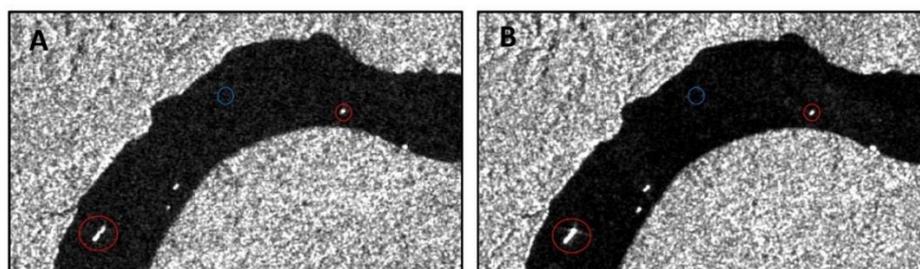
No escopo do processo de difusão do uso de imagens SAR também se intensificou o seu uso, especificamente, para detecção de embarcações. Ouchi (2016) atribui este fato à necessidade de otimizar o controle do tráfego de embarcações e de aprimorar as ações voltadas ao combate das atividades ilegais. Ainda, o autor faz uma revisão bibliográfica e conclui que tais estudos utilizam, majoritariamente, métodos baseados em algoritmos *Constant False Alarm Rate* (CFAR).

Algoritmos CFAR calculam estatísticas locais, como média e desvio padrão, a partir de uma janela de tamanho definido pelo usuário que percorre toda imagem a fim de estabelecer um limiar de separação entre água-embarcação (SPA, 2018), e se caracterizam por serem de rápida e fácil implementação (CRISP, 2004; PAES, 2009; OUCHI, 2016). Logo, são encontrados diversos estudos recentes que utilizam o algoritmo CFAR em imagens SAR, utilizando, principalmente, imagens dos satélites Sentinel-1. Dechesne et al. (2019) utilizaram o algoritmo CFAR para detecção de embarcações a partir de uma aplicação *multi-task deep learning* para categorizar diferentes tipos de embarcações com base nas suas dimensões, e obteve *F score* de 97,45, conseguindo detectar inclusive embarcações de menor porte, como, pesqueiras (26 m) e rebocadores (47 m). Contudo, os autores ressaltaram a necessidade de um número grande de amostras de treinamento da aplicação *deep learning*. Da mesma forma, Pelich et al. (2019) implementou o algoritmo CFAR na Inglaterra e México e obteve taxa de detecção de embarcação superior a 80% com baixa incidência de falsos alarmes para embarcações até 400 m. Ainda, Fitriani, Gaol e Kushardono (2020) foram exitosos em detectar embarcações no mar de Java com dimensão superior a 25 m, obtendo média de falsos alarmes de 34,5%. Portanto, os referidos estudos atestam a eficiência dos algoritmos CFAR na detecção de embarcações, inclusive demonstrando sua aplicação para embarcações de diferentes tamanhos e formas.

Vale destacar que os estudos citados utilizam uma prática comum em que são utilizadas informações pré-existentes de sistemas automatizados para treinamento, avaliação e validação dos resultados, como o *Automatic Identification System* (AIS) - sistema que disponibiliza a localização em tempo real, o tipo de embarcação, bem como suas dimensões (DECHESNE et al., 2019). Isso viabiliza quantificar e qualificar as embarcações detectadas a fim de melhor compreender as limitações e potencialidades dos métodos empregados (FITRIANI; GAOL; KUSHARDONO, 2020).

Ainda em relação aos algoritmos CFAR, Paes (2009) e An, Xie e Yaun (2014) destacam as seguintes características: apresentam melhor performance em áreas com águas homogêneas, com menor turbulência, pois permite o cômputo mais preciso das estatísticas; tendem a apresentar dificuldade próximo às margens ou de grandes estruturas, pois tais elementos influenciam no cálculo das estatísticas e criam limiares que não representam, necessariamente, o sinal das embarcações; e são influenciados por fatores ambientais, como, o movimento da água, chuvas e intensidade do vento, que conferem um aspecto rugoso à superfície da água, comportamento semelhante a alvos pequenos e de baixo sinal (Figura 2). Adicionalmente, deve-se atentar para o impacto do ruído *speckle* - ruído multiplicativo inerente às imagens SAR que é ocasionado pela interferência construtiva e destrutiva das ondas do radar que degrada a qualidade das imagens e dificulta sua interpretação (BIORESITA; PRIBADI; FIRDAUS, 2018).

Figura 2 - Imagem SAR Sentinel-1 de 16/06/2018 do Rio Madeira, em Rondônia. Embarcações (vermelho) e água (azul). A) Polarização VH. B) Polarização VV.

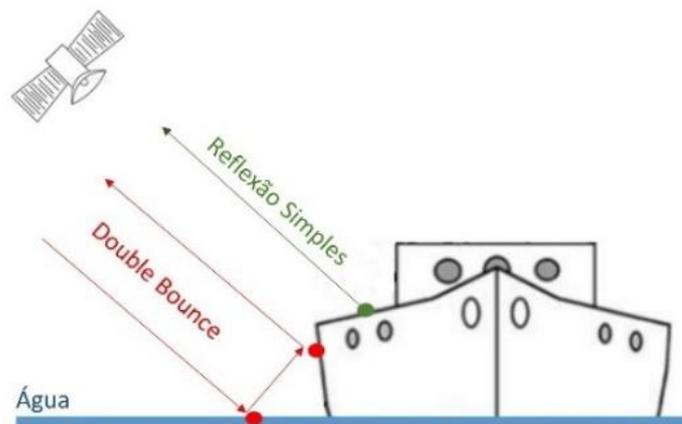


Fonte - os autores.

Conforme explicitado por Ouchi (2016), as características do radar, também influenciam diretamente na eficiência da detecção das embarcações por meio de algoritmos CFAR, com destaque para a polarização utilizada, uma vez que polarizações paralelas registram o sinal de forma mais intensa que as polarizações cruzadas. Ou seja, a eficiência do método é fortemente influenciada a depender da polarização utilizada (PELICH et al., 2019).

Da mesma forma, as características das embarcações (dimensão, orientação e forma), bem como o material que as constituem ou que as recobrem, também impactam na eficiência dos algoritmos CFAR. Nesse sentido, materiais de metal são registrados com sinal mais intenso em imagens SAR em comparação com madeira, palha ou similares o que incrementa o contraste entre a embarcação e água, facilitando sua detecção (AIELLO; VEZZOLI; GIANINETTO, 2019). Ainda, é comum a ocorrência de efeito *double bounce*, ou reflexão de canto, em grandes embarcações, conferindo um registro muito forte ao alvo (WANG et al., 2019) (Figura 3).

Figura 3 - Contexto de ocorrência de efeito *double bounce*.



Fonte - WANG et al., 2019. Adaptação: os autores.

Portanto, o desenvolvimento de estudos que empreguem o sensoriamento remoto para detecção de garimpos de ouro embarcados é oportuno, uma vez que tais estudos podem auxiliar na compreensão da ocorrência da atividade ao longo do tempo em determinada área. Este tipo de informação pode subsidiar os órgãos de controle no monitoramento e fiscalização da atividade legal e no planejamento e implementação de ações de combate à atividade ilegal.

Assim, mediante escassa literatura dedicada à detecção de garimpos de ouro embarcado e que existem técnicas consolidadas para detecção de embarcações que podem ser adaptadas à detecção da garimpagem embarcada, o presente artigo avaliou o uso de imagens SAR dos satélites Sentinel-1 para identificar garimpos de ouro embarcados por meio de algoritmos de detecção, baseado em algoritmo CFAR. Com isso, espera-se contribuir nas discussões referentes às potencialidades e limitações do emprego das imagens SAR para o controle da garimpagem de ouro.

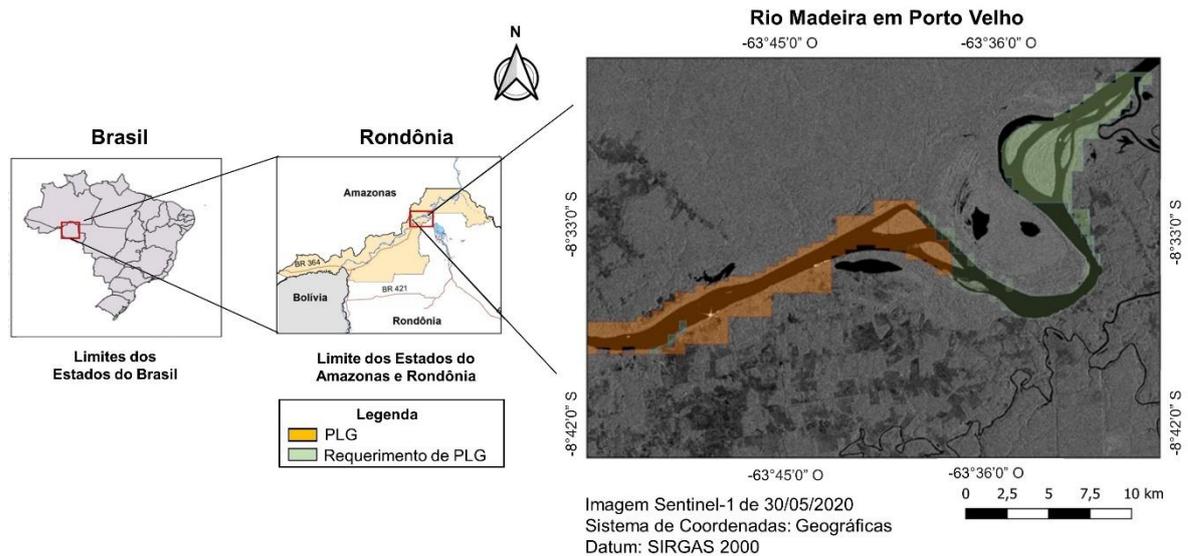
MATERIAIS E MÉTODOS

Área de estudo

A bacia hidrográfica do Rio Madeira concentra 55% do total de PLG e 20,61% dos Requerimentos de PLG localizados em rios no Brasil (SIGMINE, 2022), caracterizando-se por ser uma bacia onde garimpagem de ouro embarcado ocorre de forma recorrente. Assim, a área de estudo está localizada no Rio Madeira próximo a Porto Velho, capital do estado de Rondônia - coordenadas 63°24'25,25" O / 8°51'9,92" S e 65°1'34,89" O / 8°23'43,874" S (Figura 4). A área se estende por 82 km ao longo do Rio Madeira e possui 14.400 hectares de Requerimento de PLG e 9.400 hectares de PLG (SIGMINE, 2022). As águas do Rio Madeira são classificadas como águas brancas com elevada concentração de sólidos

em suspensão e de coloração marrom (ESPINOZA VILLAR et al., 2013). O clima na área de estudo é classificado como Aw, com regime pluviométrico entre 38,7 e 329 mm/mês, sendo os meses de junho/julho/agosto os de menores chuvas e novembro/dezembro/janeiro de maiores (BEZERRA; DANTAS; TRINDADE, 2010). A sazonalidade pluviométrica reflete diretamente no regime hidrológico do Rio Madeira, sendo que sua vazão varia de 5.000 m³/s nos meses de menores chuvas até 50.000 m³/s nos meses de maiores chuvas (ADAMY, 2016). Ainda, a cota pluviométrica no Rio Madeira varia de 8 a 20 m e sua largura de 700 a 2.000 m (RODRIGUEZ et al., 2017).

Figura 4 - Área de Estudo.



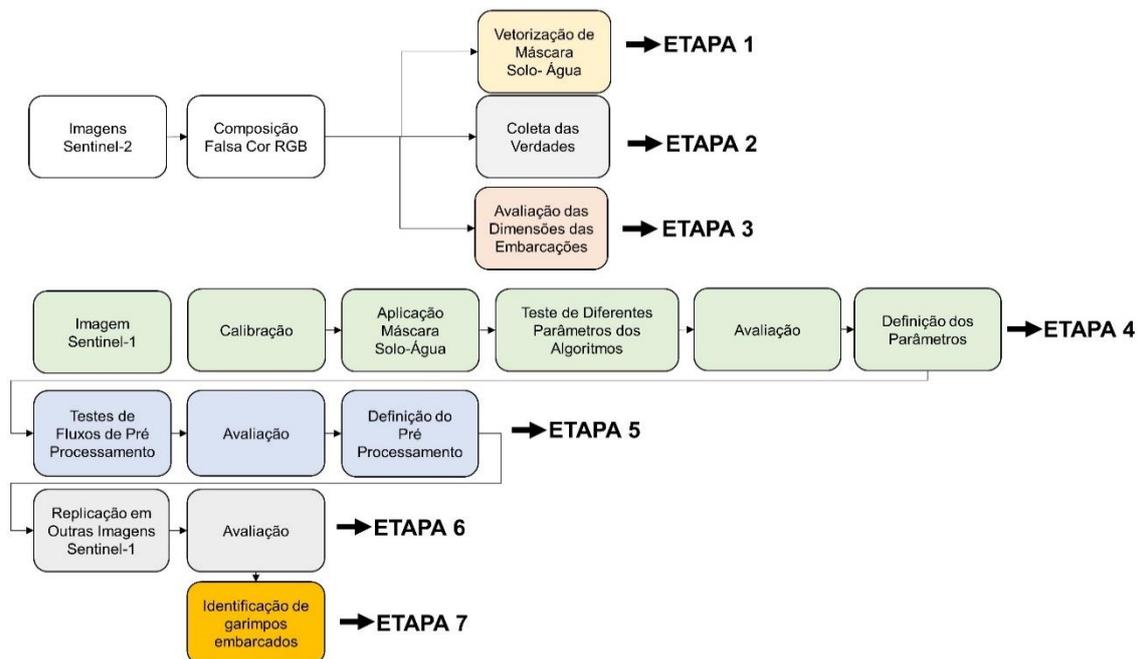
Fonte - os autores.

Metodologia

A metodologia foi organizada em sete etapas, conforme Figura 5. Em relação às polarizações das imagens Sentinel-1 utilizadas a ESA disponibiliza somente as polarizações VV e VH para a área de estudo as quais foram utilizadas no presente estudo.

Para escolher as datas das imagens Sentinel-1 a serem trabalhadas foram levadas em consideração os seguintes pontos: i) existência de imagens multiespectrais de outros satélites com resolução espacial igual ou maior que 10 m para realizar a validação dos resultados; ii) estas imagens devem ser gratuitas; iii) estas imagens devem ser de mesma data das imagens Sentinel-1; iv) a cobertura de nuvens nestas imagens não pode impedir a visualização do Rio Madeira. Isto culminou na escolha da utilização das imagens dos satélites Sentinel-2.

Figura 5 - Metodologia Empregada.



Fonte - os autores.

Os satélites Sentinel-2 geram imagens por meio de sensores passivos *Multi Spectral Instruments* com resolução espacial de 10 m nas bandas do vermelho, verde e azul, ou *Red, Green e Blue (RGB)*, e são disponibilizadas georreferenciadas (ESA, 2015). Assim, ao realizar a busca das imagens Sentinel-2 de mesma data que imagens Sentinel-1, foram identificadas 7 datas entre 2018 e 2021 – as quais foram utilizadas no presente estudo (Tabela 1).

Tabela 1 - Imagens Sentinel-1 Utilizadas.

Data	Imagem
11/05/2018	S1A_IW_GRDH_1SDV_20180511T094907_20180511T094932_021855_025BDC_CB00
10/07/2018	S1A_IW_GRDH_1SDV_20180710T094910_20180710T094935_022730_0276A0_2497
03/09/2019	S1A_IW_GRDH_1SDV_20190903T094920_20190903T094945_028855_034518_C4F4
30/05/2020*	S1B_IW_GRDH_1SDV_20200530T094814_20200530T094843_021809_02965F_D1C6
	S1B_IW_GRDH_1SDV_20200530T094843_20200530T094908_021809_02965F_FD0C
27/09/2020*	S1B_IW_GRDH_1SDV_20200927T094820_20200927T094849_023559_02CC3A_FBA9
	S1B_IW_GRDH_1SDV_20200927T094849_20200927T094914_023559_02CC3A_732E
24/06/2021	S1A_IW_GRDH_1SDV_20210624T094928_20210624T094953_038480_048A73_EB90
23/08/2021	S1A_IW_GRDH_1SDV_20210823T094931_20210823T094956_039355_04A5ED_299F

* Foi feito mosaico das imagens para abranger a área de estudo.

Fonte - os autores.

Etapa 1 - Vetorização da máscara solo-água

Foram utilizadas imagens Sentinel-2 da órbita T20LMR das mesmas datas das imagens Sentinel-1 para vetorizar de forma manual máscaras água-solo por meio de composição falsa cor RGB.

Etapa 2 - Coleta das verdades

Apesar de existirem dispositivos para localização automática e em tempo real de embarcações que geram dados que podem ser utilizados para treinamento e validação, como o AIS, esta situação não se aplica à realidade da região amazônica - onde o deslocamento de grande parte da população e de cargas é feito por embarcações de pequeno/médio porte, de pouca estrutura e em muitas vezes em estado precário de conservação (MOURA; FROTA, 2016). Assim, foram montadas composições falsa-cor utilizando as bandas do vermelho, verde e azul das sete imagens Sentinel-2. Uma vez que garimpos embarcados e embarcações são facilmente identificados nas imagens (Figura 6) foi simples de realizar a captura das coordenadas para servirem como amostra verdade para serem utilizadas na validação dos resultados. Vale ressaltar que a hora de registro das imagens Sentinel-1 e Sentinel-2 são diferentes, logo as embarcações podem se locomover entre a geração das imagens. Contudo, alvos fixos, característica dos garimpos embarcados, tendem a ser registrados em ambas as imagens. Dessa forma, somente as coordenadas das embarcações presentes nas imagens Sentinel-2 e Sentinel-1 foram consideradas como amostras verdade.

Etapa 3 - Avaliação das dimensões das embarcações

A imagem Sentinel-2 de 24/06/2021 foi utilizada para avaliar o comprimento e largura das embarcações por possuir a maior quantidade de embarcações entre todas as imagens, permitindo uma melhor compreensão das dimensões dos alvos. A mensuração foi feita de forma manual.

Figura 6 - Características das Embarcações: A) Garimpos Agrupados (em Preto); B) Garimpos Agrupados (em Preto) e Grande Embarcação (em Laranja).



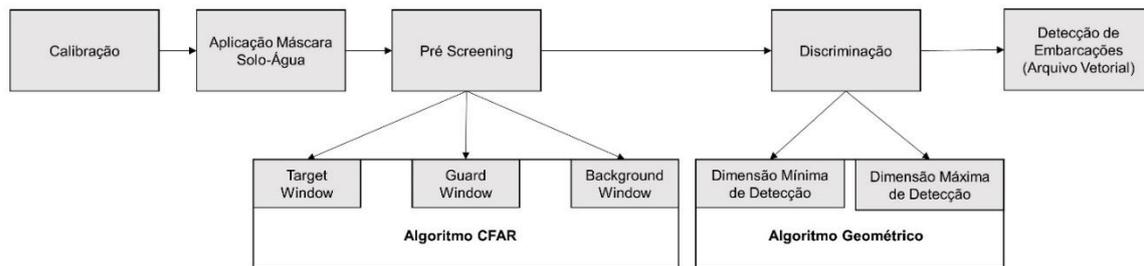
Fonte - os autores.

Etapa 4 - Definição dos parâmetros do algoritmo de detecção

A imagem Sentinel-1 de 24/06/2021 foi utilizada para definir os melhores parâmetros do algoritmo de detecção presente no *software* SNAP, desenvolvido pela Agência Espacial Europeia.

O *software* possui metodologia para detecção de embarcações baseada em um algoritmo CFAR e outro de avaliação geométrica, conforme explanado por Spa (2018). A Figura 7 mostra as etapas metodológicas do algoritmo.

Figura 7 – Metodologia do CFAR e Algoritmo Geométrico Implementados no SNAP para Detecção de Embarcações.



Fonte - os autores.

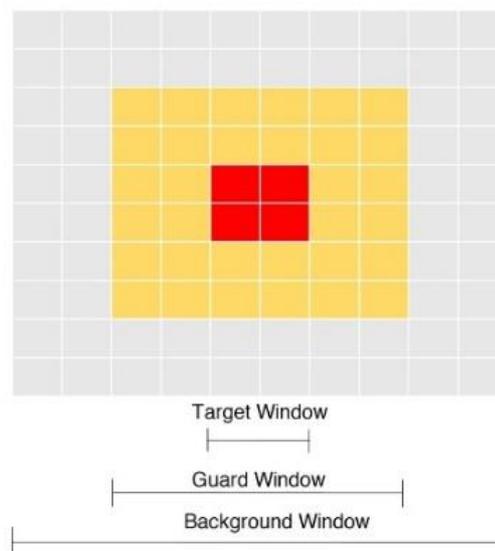
O algoritmo CFAR calcula estatísticas locais a partir de uma janela que percorre toda imagem (Figura 8) cujas dimensões são definidas em função do tamanho das embarcações a serem detectadas a partir de três parâmetros: *target window*, *guard window*, e *background window* (todos em metros). O *target window* deve ser igual à dimensão da menor embarcação a detectar. O *guard window* funciona como um muro para impedir que as estatísticas do *background window* sejam contaminadas pelas estatísticas do *target window*, e deve ser igual à dimensão da maior embarcação a detectar. Por último, o *background window* deve ser maior do que o tamanho da *guard window* – definido de forma empírica a depender de cada contexto (SPA, 2018).

Por fim, o algoritmo CFAR do SNAP utiliza dois parâmetros para diferenciar a água das embarcações – Equação 1 (BIORESITA; PRIBADI; FIRDAUS, 2018):

$$\mu_t > \mu_b + \sigma_b \sqrt{n} \rightarrow \text{Alvo} \quad (1)$$

Onde μ_t é a média dos valores da *target window*; μ_b é a média dos valores do *background window*; σ_b é o desvio padrão dos valores do *background window*; e t é o limiar que acima deste, considera-se a feição como embarcação.

Figura 8 - Estêncil do Algoritmo CFAR.



Fonte - os autores.

Na etapa de discriminação, o algoritmo agrupa pixels iguais e contíguos em um único *cluster* e extrai informações de largura/comprimento, comparando-as com as dimensões máximas e mínimas das

embarcações que são definidas pelo usuário (SPA, 2018).

Os resultados gerados pelos algoritmos foram validados por meio do *score F1* (CAO et al., 2020) a partir das amostras verdade coletadas na Etapa 2 (Equações 2, 3 e 4). O *score F1* é a média harmônica entre *precision* e *recall* e que podem ser interpretados como a capacidade de precisão na detecção de determinada feição e a capacidade de realizar a discriminação da feição. É importante buscar um equilíbrio entre o *precision* e o *recall*, uma vez que um alto *precision* e *recall* baixo representa um modelo em que uma quantidade baixa de alvos foram corretamente classificados, porém, estes se assemelham bastante com as amostras verdade, relacionando-se falsos negativos (omissões). Já um *precision* baixo e *recall* alto demonstra que os alvos foram amplamente classificados, no entanto, estes foram generalizados, ocorrendo em erros relacionados a falsos positivos (comissões). Dessa forma, quanto maior o *score F1*, mais equilibrados são os resultados.

$$\text{Score F1} = 2 * \frac{P * R}{P + R} \quad (2)$$

$$P = \frac{\Sigma VP}{\Sigma VP + \Sigma FP} \quad (3)$$

$$R = \frac{\Sigma VP}{\Sigma VP + \Sigma FN} \quad (4)$$

Onde: P = *precision*; R = *recall*; VP = verdadeiro positivo; FP = falso positivo; FN = falso negativo.

Etapa 5 - Definição do pré-processamento

A metodologia contida no *software* SNAP orienta apenas a calibração como etapa de pré-processamento para realizar a detecção das embarcações – procedimento que converte os valores registrados em níveis digitais para valores de retroespalhamento radiometricamente calibrados, convertendo os valores de intensidade para sigma zero (ESA, 2012). Porém, buscou-se avaliar a influência da inclusão de mais etapas de pré-processamento a fim de verificar possíveis melhorias na eficiência na detecção dos garimpos de ouro embarcados. Assim, os procedimentos apresentados na Figura 9 foram testados na imagem Sentinel-1 de 24/06/2021.

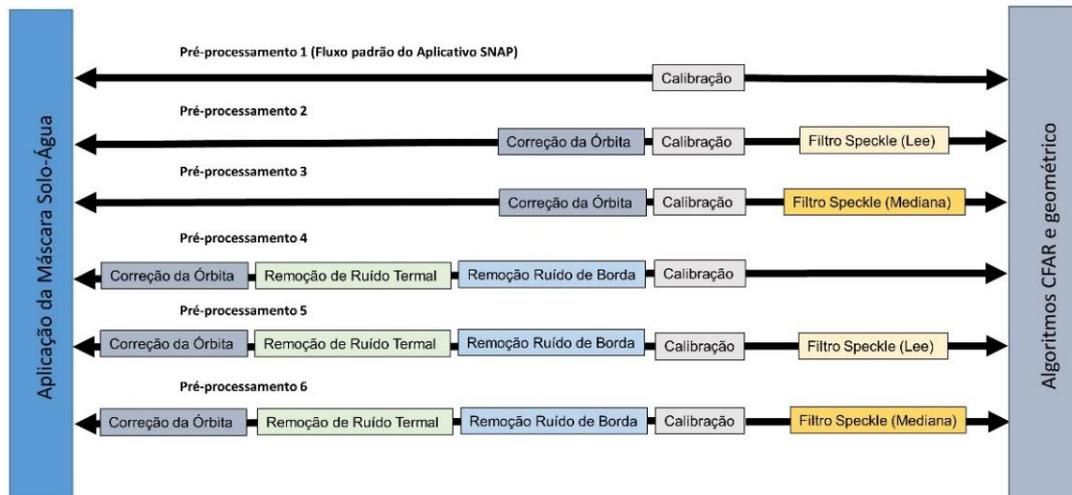
Os procedimentos foram escolhidos com base em documento produzido pela Agência Espacial Europeia a fim de orientar sobre melhores práticas de pré-processamento para imagens Sentinel1 (FILIPPONI, 2019). Assim, as etapas de pré-processamento são resumidas da seguinte forma i) a correção de órbita incrementa a confiabilidade das imagens a partir da atualização de informações sobre posição e velocidade dos satélites; ii) a remoção de ruído térmico atenua os efeitos do ruído térmico aditivo que altera a textura das imagens de intensidade, normalizando o sinal de intensidade da imagem; iii) a remoção de ruído de borda remove ruídos de baixa intensidade e dados inválidos criados nas bordas das imagens em decorrência da compensação geométrica da mudança da curvatura terrestre; iv) a remoção do *speckle*, que é um ruído multiplicativo ocasionado pela interferência construtiva e destrutiva das ondas, evita a degradação da qualidade da imagem e minimiza a confusão entre alvos, facilitando a interpretação da imagem.

Foram utilizados os filtros mediana e Lee, ambos de janela 3x3 para atenuação do ruído *speckle*. Rodrigues et al. (2019) e Castro Filho et al. (2020) pontuam que tais filtros são de rápida e fácil implementação e amplamente utilizados em estudos de sensoriamento remoto utilizando imagens SAR, e que, apesar de alterarem os valores originais de intensidade para atenuação do ruído, apresentam resultados satisfatórios para diferenciação de feições em imagens SAR.

Por fim, a avaliação dos resultados foi realizada por meio do *score F1*, de forma similar à Etapa 4, sendo que o fluxo de pré-processamento que obteve maior *score F1* foi escolhido como mais adequado.

Esta etapa metodológica do estudo foi importante para a definição da melhor metodologia para detecção de embarcações de forma precisa e rápida, já que a etapa de pré-processamento de imagens SAR apresenta custo de tempo operacional que pode variar de minutos a horas a depender do tamanho da área que será processada.

Figura 9 - Pré-Processamentos Avaliados.



Fonte - os autores.

Etapa 6 - Replicação em outras 6 imagens Sentinel-1

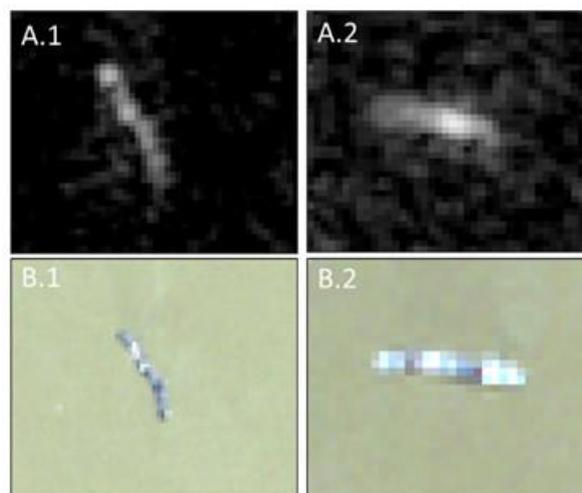
A metodologia de detecção foi replicada nas outras imagens Sentinel-1, utilizando a polarização mais adequada, os melhores parâmetros e o melhor fluxo de pré-processamento, conforme identificados nas Etapas 4 e 5. Os resultados foram avaliados em função do *score* F1, de forma similar às Etapas 4 e 5.

Etapa 7 - Identificação de garimpos de ouro embarcados

Os garimpos foram identificados mediante avaliação visual dos resultados, utilizando imagens Sentinel 1 e 2, conforme apresentado na Figura 10.

Vale ressaltar que a metodologia empregada no presente estudo apresenta a limitação de não dispor de uma base de dados históricos de localização de embarcações e de garimpos embarcados, e nem mesmo de acesso à localização em tempo real de tais alvos, quando existentes. Isso impactou diretamente na quantidade de imagens que puderam ser utilizadas, bem como na quantidade de amostras verdade utilizadas para realizar as validações.

Figura 10 - Identificação de Garimpos Embarcados: A) Embarcações Detectadas em Imagem Sentinel-1 com Padrão de Garimpos; B) Imagem Sentinel-2 usada para Identificação dos Garimpos.



Fonte - os autores.

RESULTADOS E DISCUSSÃO

As máscaras solo-água foram vetorizadas facilmente uma vez que as margens do rio e bancos de areia são prontamente identificáveis nas imagens óticas do sensor Sentinel-2, e o mesmo ocorre com as embarcações, o que permitiu coletar amostras verdade de forma satisfatória e contabilizar de 14 a 44 embarcações por imagem (Tabela 2). O Rio Madeira é uma via de transporte de cargas e de pessoas relevante sendo comum a circulação de grandes, médias e pequenas embarcações. Por isso, existe grande variação no tamanho, forma e tipo de embarcações presentes na área de estudo.

Tabela 2 - Quantidade de Embarcações por Imagem Sentinel-2.

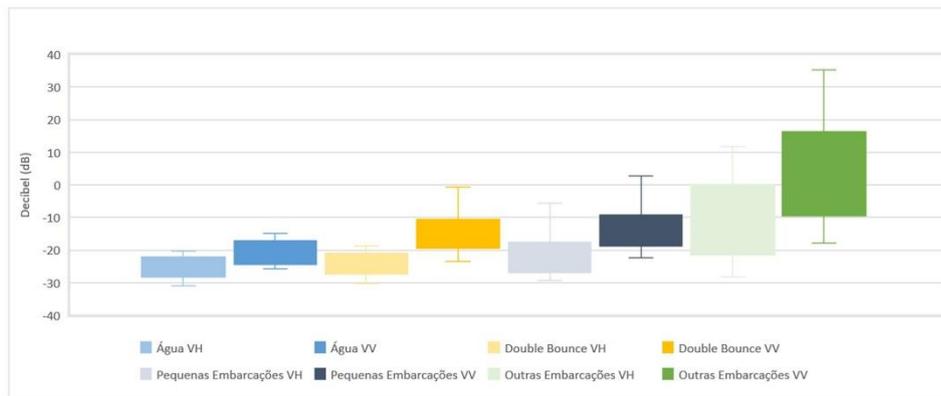
Data	Quantidade de Embarcações
11/05/2018	17
10/07/2018	40
03/09/2019	21
30/05/2020	14
7/09/2020	22
24/06/2021	44
23/08/2021	18

Fonte - os autores.

A variação das dimensões das embarcações presentes na imagem Sentinel-2 de 24/06/2021 foi de 20 a 280 m, existindo grandes embarcações, garimpos agrupados e embarcações isoladas de diferentes tamanhos. Algumas embarcações de grande porte que são recobertas de metal, material de grande capacidade reflexiva, sofreram efeito *double bounce* nas imagens Sentinel-1. Assim, em determinados casos o efeito foi tão forte que inviabilizou a visualização da área vizinha à embarcação, indo ao encontro do descrito por Paes (2009) que ressalta o efeito prejudicial do efeito *double bounce* na interpretação dos resultados na detecção de embarcações em imagens SAR.

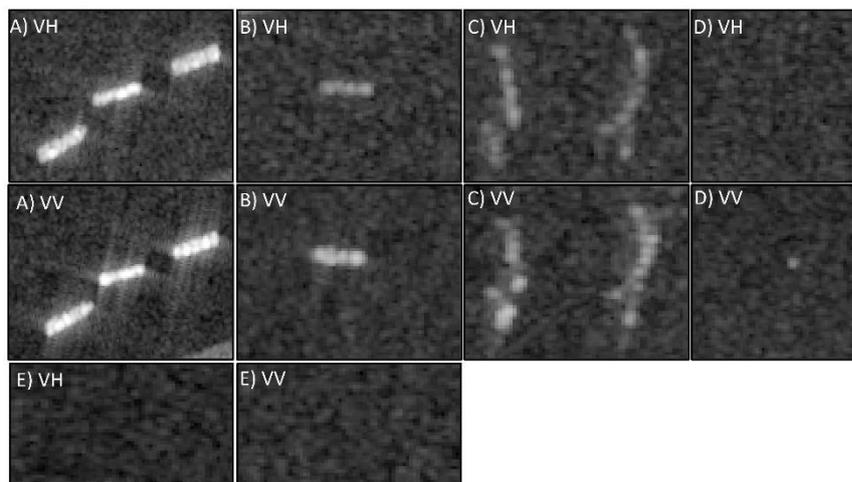
A literatura demonstra que a polarização VV registra sinais mais fortes que VH (OUCHI, 2016; PELICH et al., 2019), fazendo com que os alvos sejam registrados de formas diferentes a depender da polarização. Esse comportamento foi percebido no presente estudo, uma vez que a intensidade de todos os alvos foi maior em VV que em VH. A intensidade média das embarcações em VV foi de 3,74 dB ($\sigma = 16,92$) e -9,03 dB ($\sigma = 11,95$) em VH (Figuras 11 e 12). Vale ressaltar que todos os tipos de embarcações apresentaram maior intensidade em VV. Wang et al. (2019) destaque que grandes embarcações, definidas como "outras embarcações" na Figura 11, são comumente revestidas, cobertas, transportam cargas ou possuem estruturas de metal, fato que contribuiu diretamente para que estas registrassem as maiores intensidades. Já as embarcações menores registraram intensidade inferior o que é relacionado ao tamanho reduzido do alvo e ao material que constitui ou recobre embarcação, por exemplo, madeira, palha ou cerâmica registram menor intensidade em comparação ao metal (AIELLO; VEZZOLI; GIANINETTO, 2019).

Figura 11 - Intensidade em VV e VH das Embarcações Identificadas em todas as Imagens Sentinel-1.



Fonte - os autores.

Figura 12 - Aspectos dos Alvos em Imagem Sentinel-1: A) Grandes Embarcações; B) Outras Embarcações; C) Pequenas Embarcações Agrupadas; D) Pequena Embarcação Isolada; E) Água.

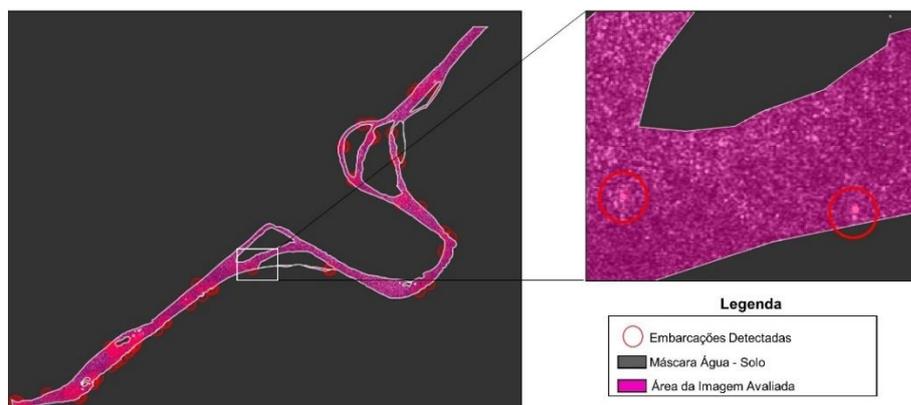


Fonte - os autores.

A intensidade da água também foi maior em VV, pois as polarizações cruzadas registram de forma mais amena o retroespalhamento deste alvo (OUCHI, 2016). Contudo, a diferença média não foi tão acentuada: -25,23 dB ($\sigma = 3,54$) em VH e -20,21 dB ($\sigma = 3,84$) em VV. Isso significa que a superfície da água apresenta certo grau de homogeneidade, condição adequada para implementação dos algoritmos CFAR, conforme pontuado por An, Xie e Yuan (2014).

A Figura 13 exemplifica como os resultados de detecção são apresentados pelo *software* SNAP, e a Tabela 3 apresenta os resultados dos seis conjuntos de parâmetros testados que variaram em função das dimensões das embarcações medidas (entre 20 e 280 m).

Figura 13 - Resultado Gerado pelo Software.



Fonte - os autores.

Tabela 3 - Resultados para os Diferentes Parâmetros dos Algoritmos de Detecção.

Janelas TGB* (metros)	VH						VV					
	Falsos Positivos	Acertos	Falsos Negativos	Precision	Recall	F1	Falsos Positivos	Acertos	Falsos Negativos	Precision	Recall	F1
10x30x90	9	19	25	0,68	0,43	0,53	16	28	16	0,64	0,64	0,64
10x50x150	8	24	20	0,75	0,55	0,63	13	33	11	0,72	0,75	0,73
10x70x210	8	29	15	0,78	0,66	0,72	12	34	10	0,74	0,77	0,76
10x280x310	7	30	14	0,81	0,68	0,74	19	33	11	0,63	0,75	0,69
20x40x120	8	26	18	0,76	0,59	0,67	13	25	19	0,66	0,57	0,61
20x60x180	9	27	17	0,75	0,61	0,68	13	28	16	0,68	0,64	0,66
20x80x240	8	32	12	0,8	0,73	0,76	16	36	8	0,69	0,82	0,75
20x280x310	9	34	10	0,79	0,77	0,78	14	41	3	0,75	0,93	0,83
30x70x110	8	22	22	0,73	0,5	0,59	13	31	13	0,7	0,7	0,7
30x90x180	7	25	19	0,78	0,57	0,66	12	28	16	0,7	0,64	0,67
30x110x220	7	26	18	0,79	0,59	0,68	11	28	16	0,72	0,64	0,67
30x280x310	5	31	13	0,86	0,7	0,78	11	35	9	0,76	0,8	0,78

* T = target window; G= guard window; B= Background window.

Fonte - os autores.

Em relação à validação dos resultados na imagem utilizada para definir os melhores parâmetros para os algoritmos, percebe-se que o score F1 variou de 0,53 e 0,83, sendo que os valores de VH foram inferiores aos de VV: F1_{VH} entre 0,53 e 0,78; e F1_{VV} entre 0,61 e 0,83. A polarização VV apresentou performance mais equilibrada que VH, sendo que na maioria dos parâmetros os scores F1 foram superiores. Isso ocorreu porque o número de falsos negativos foi menor em VV (Recall_{VH} de 0,43 a 0,77 e Recall_{VV} e 0,57 a 0,93). Estes achados são aderentes aos estudos conduzidos por Pelich et al. (2019), Wang et al. (2019) e Fitriani, Gaol e Kushardono (2020) onde foram obtidas menores quantidades de falsos negativos em VV. Como a polarização VV registra sinais de forma mais fortes que em VH, acaba por destacar alvos mais difíceis de serem visualizados em VH, aumentando o número de acertos. Contudo, isso faz com que seja uma polarização mais propensa à ocorrência de

falsos positivos, devendo ser utilizada a polarização que melhor se adapta ao contexto estudado (PELICH et al., 2019). Nesse sentido, os parâmetros 20 m x 280 m x 310 m em VV geraram o melhor score F1 (0,83).

Foi percebido que a quantidade de omissões aumentou conforme os valores de *target window* e *background window* se distanciavam das dimensões máximas e mínimas das embarcações, tanto que os piores scores F1 foram observados nos conjuntos de parâmetros mais distantes das dimensões mínima e máxima (10 m x 30 m x 90 m; 20 m x 40 m x 120 m; 30m x 70 m x 110 m), justificados pela maior ocorrência de falsos negativos (*recall*_{VH} de 0,53, 0,67 e 0,59 e *recall*_{VV} de 0,64, 0,61 e 0,70). Por outro lado, foi percebida uma relação inversamente proporcional entre a ocorrência de falsos positivos e a dimensão do *target window*, sendo que aumentaram conforme esta janela foi reduzida. Assim, quanto menor a dimensão da embarcação a ser detectada, maior a quantidade de falsos positivos. Não foram encontrados estudos testando diferentes valores daqueles orientados pela metodologia do software SNAP. Como os garimpos embarcados ocorrem em embarcações de menor dimensão, que por vezes se agrupam, se torna prejudicial aumentar a *target window* a fim de diminuir a ocorrência de falsos positivos em detrimento de aumentar as omissões destas embarcações, ainda mais que a ocorrência de omissões em VV é menor.

Ao adotar dimensões intermediárias como valores de *target window* e *guard window* são criadas linhas de corte que ora omitem embarcações de menor porte, ora de grande porte. Por isso, utilizar as dimensões máximas e mínimas das embarcações, no caso 20 m e 280 m conferiu melhor performance para a detecção das embarcações, similar ao descrito por Spa (2018).

Os falsos negativos ocorreram em embarcações pequenas e com sinal baixo que dificultou o contraste com a água, fato ocasionado pelo tamanho reduzido do alvo e ao material de cobertura da embarcação, conforme explanado por Aiello, Vezzoli e Gianinetta (2019). Já os falsos positivos ocorreram, principalmente, por influência do efeito *double bounce* (WANG et al., 2019) e pela rugosidade da água (AN; XIE; YUAN, 2014), representada por pontos isolados no leito ou às margens do rio e que apresentam sinal próximo de embarcações de menor porte e sinal mais fraco.

Como a metodologia disponível no SNAP não orienta quanto à definição do *background window*, foram testadas quatro diferentes opções na polarização VV (310, 330, 370 e 400 m), utilizando o melhor conjunto identificado de *target window* (20 m) e *guard window* (280 m). Foi constatado um leve aumento das omissões de embarcações conforme o aumento do tamanho do *background window*, principalmente das menores de 50 m, causando uma queda no *recall* de 0,93 para 0,89 (Tabela 4). Também foi percebida queda na quantidade de falsos positivos conforme o aumento do *background window*, aumentando o *precision* de 0,75 para 0,80. Um grande *background* leva em consideração muitos pixels de água, fazendo com que embarcações com menor intensidade sejam omitidas. Ressalta-se que também não foram achados estudos que avaliam diferentes tamanhos de *background windows*. Vale pontuar que não foram achados estudos que comparados o efeito de diferentes tamanhos de *background windows*.

Assim, os melhores valores para a imagem de 24/06/2021 foram 340 m e 370 m, com score F1 de 0,85. Contudo, conclui-se pela necessidade de testar diferentes *background windows* a fim de encontrar aquele que melhor se adapta à imagem utilizada.

Tabela 4 - Score F1 de 24/06/2021, testando Diferentes *Background Windows*.

Janelas TGB* (metros)	Falso Positivo	Acertos	Falsos Negativos	Precision	Recall	Score F1
20x280x310	14	41	3	0,75	0,93	0,83
20x280x340	12	41	3	0,77	0,93	0,85
20x280x370	12	41	3	0,77	0,93	0,85
20x280x400	10	39	5	0,8	0,89	0,84

* T = target window; G= guard window; B= Background window em metros

Fonte - os autores.

O teste de diferentes fluxos de pré-processamentos produziu *scores* F1 entre 0,57 e 0,83, sendo que o melhor *score* foi obtido quando foi utilizada apenas calibração (0,83) (Tabela 5). Ao implementar filtros, remover o ruído termal e o ruído de borda a quantidade de falsos positivos aumentou, com queda no *precision* de 0,75 a 0,43. Da mesma forma, aumentou-se também a quantidade de omissões, com queda no *recall* de 0,93 a 0,84. Os filtros modificam o valor original do pixel e tal alteração ocasionou aumento dos falsos positivos e de omissões. Este comportamento foi similar ao descrito por Marino et al. (2015) que destacou que o emprego de técnicas para remoção do *speckle* afeta a performance de algoritmos de detecção, devendo ser avaliado caso a caso sobre os benefícios de usá-las, uma vez que podem piorar ou melhorar os resultados, a depender do contexto (FITRIANI; GAOL; KUSHARDONO, 2020). Além disso, o fluxo de pré-processamento composto pela remoção de ruído de borda e termal, e a calibração apresentou o segundo melhor *score* F1, fato ocorrido porque houve apenas ajustes radiométricos nas imagens (FILIPPONI, 2019) que alteraram os valores dos pixels de forma mais suave que os filtros. Portanto, a adição de etapas que alteram os dados originais piorou a eficiência da detecção das embarcações, sendo que o uso somente da calibração apresentou os melhores resultados, como mencionado também em outros estudos (BIORESITA; PRIBADI; FIRDAUS, 2018; FITRIANI; GAOL; KUSHARDONO, 2020).

Tabela 5 - Score F1 para Diferentes Pré-Processamentos.

Performance	VV					
	1*	2*	3*	4*	5*	6*
Falsos Positivos	14	30	19	14	54	49
Acertos	41	37	35	38	39	37
Omissões	3	7	6	6	5	7
Avaliação						
Precision	0,75	0,55	0,65	0,73	0,42	0,43
Recall	0,93	0,84	0,85	0,86	0,89	0,84
F1	0,83	0,67	0,74	0,79	0,57	0,57

* 1 = Calibração; 2 = Calibração + Speackle Filter Lee; 3= Calibração + Speackle Filter Mediana; 4 = Calibração + Thermal Noise Removal + Remove Border Noise; 5 = Calibração +Thermal Noise Removal + Remove Border Noise + Calibração + Speackle Filter Lee; 6 = Calibração +Thermal Noise Removal + Remove Border Noise + Calibração + Speackle Mediana

Fonte - os autores.

A replicação dos algoritmos de detecção com os parâmetros e fluxo de pré-processamento mais adequados nas outras imagens Sentinel-1 apresentou *score* F1 entre de 0,76 a 0,86 (Tabela 6). O tamanho ótimo de *background window* não foi igual para todas as imagens, sendo que os melhores resultados foram obtidos com janelas de 340 m e 370 m, e em alguns casos não houve diferença de performance entre *background window* distintas.

Tabela 6 - Desempenho dos Algoritmos de Detecção de Embarcações em todas as Imagens Sentinel-1.

Imagem	Background Window (metros)	Precision	Recall	Score F1
11/05/2018	310	0,45	0,88	0,60
	340	0,78	0,88	0,83
	370	0,83	0,88	0,86
	400	0,82	0,82	0,82
10/07/2018	310	0,61	0,72	0,66
	340	0,82	0,70	0,76
	370	0,82	0,68	0,74

	400	0,82	0,68	0,74
03/09/2019	310	0,67	0,86	0,75
	340	0,75	0,86	0,80
	370	0,68	0,81	0,74
	400	0,68	0,81	0,74
30/05/2020	310	0,38	1,00	0,55
	340	0,74	1,00	0,85
	370	0,74	1,00	0,85
	400	0,76	0,93	0,84
27/09/2020	310	0,71	0,91	0,80
	340	0,77	0,91	0,83
	370	0,77	0,91	0,83
	400	0,76	0,86	0,81
24/06/2021	310	0,75	0,93	0,83
	340	0,77	0,93	0,85
	370	0,77	0,93	0,85
	400	0,80	0,89	0,84
23/08/2021	310	0,67	1,00	0,80
	340	0,69	1,00	0,82
	370	0,69	1,00	0,82
	400	0,68	0,94	0,79

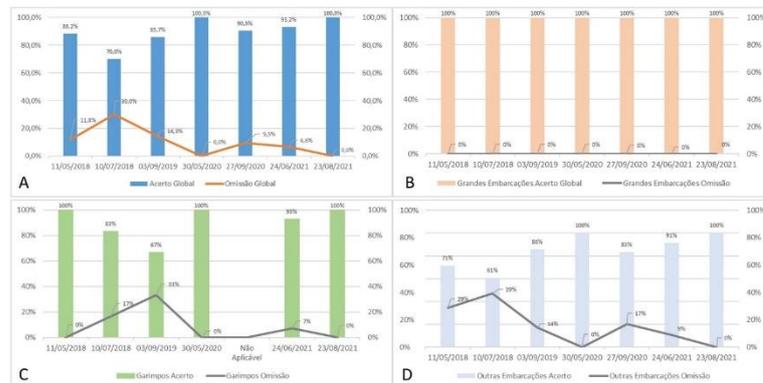
Fonte - os autores.

O percentual de detecção variou 70 a 100% e de omissão de 0 e 30%, com média de 89,7 e 10,3%, respectivamente (Figura 14A), valores convergentes com resultados encontrados na literatura cuja detecção varia de 66% até > 90% e omissão de 34,5% a 5% (MARINO et al., 2015; BIORRESITA; PRIBADI; FIRDAUS, 2018; PELICH et al., 2019; WANG et al., 2019; FITRIANI; GAOL; KUSHARDONO, 2020). Ao categorizar embarcações em grandes embarcações (maiores que 50 m, Figura 14B), garimpos (embarcações agrupadas menores que 50 m, Figura 14C) outras embarcações (menores que 50 m, Figura 14D) a compreensão das limitações e potencialidades do método se torna mais clara.

O percentual de detecção das grandes embarcações foi 100%, enquanto para garimpos foi de 67 a 100%, e outras embarcações de 61 a 100%. O método apresentou perda de eficiência quanto menor foi a intensidade do alvo e sua dimensão, tanto que o percentual de detecção diminuiu para embarcações menores, comportamento também percebido em outros estudos (PELICH et al., 2019; FITRIANI; GAOL; KUSHARDONO, 2020).

O percentual de detecção dos garimpos só foi maior que o de outras embarcações menores porque estes se agrupam e acabam formando *cluster* de embarcações que facilita sua visualização e aumenta o sinal registrado pelo sensor.

Figura 14 - Percentual de Detecção e Omissão de Embarcações de todas as Imagens Sentinel-1: A) Geral; B) Grandes Embarcações; C) Garimpos; D) Outras Embarcações.

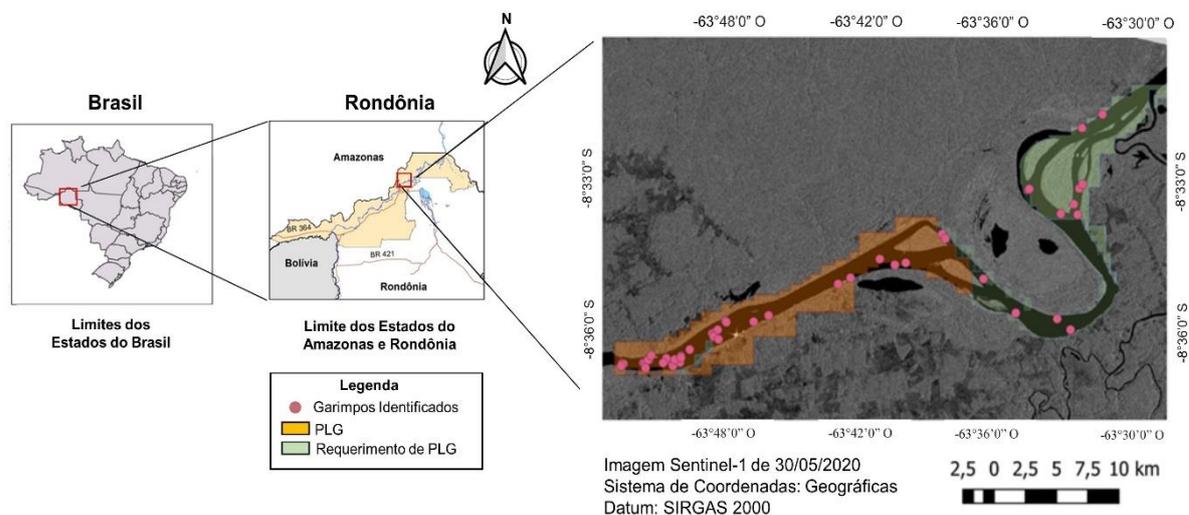


Fonte - os autores.

Por fim, em todas as imagens avaliadas foram identificados 28 garimpos, sendo que 14 ocorreram em área onde existe a PLG, em tese, de produção legalizada, 14 em área de Requerimento de PLG potencialmente ilegais (Figura 15). Porém, neste ponto vale destacar algumas limitações da abrangência dos resultados. A inexistência de uma base de dados com a localização de embarcações e de garimpos embarcados, bem como a inexistência e de informações da localização em tempo real dos garimpos embarcados, quando existente, impacta diretamente na quantidade de amostras verdade que podem ser utilizadas para realizar as validações. Isso ocorre porque, na ausência de tais informações, restou coletar tais amostras em imagens controle de sensores multiespectrais de igual, ou melhor resolução espacial, e de mesma data das imagens SAR utilizadas. Ainda, há de se considerar que a hora do registro das imagens controle e SAR são diferentes, tornando possível que embarcações em deslocamento possam não ser detectadas em ambas as imagens. Portanto, a quantidade de garimpos embarcados na realidade deve ser maior do que a identificada neste estudo

Mesmo diante de tais limitações, o método foi capaz de identificar garimpos embarcados em áreas legalizadas e potencialmente ilegais, apresentando-se como uma metodologia capaz de gerar subsídios para os órgãos de controle, podendo ser utilizada no monitoramento e fiscalização da atividade legal e no planejamento e execução de ações de combate à atividade ilegal. Da mesma forma, o método apresenta-se como uma aplicação inovadora dos algoritmos de detecção de embarcações, demonstrando sua utilidade em tema que extrapola a pesquisa acadêmica e que se mostra aplicável à realidade.

Figura 15 - Garimpos Embarcados Identificados.



Fonte - os autores.

CONCLUSÃO

O estudo utilizou algoritmos de detecção de embarcações e demonstrou que as imagens SAR Sentinel-1 podem ser utilizadas para identificação de garimpos de ouro embarcados, alcançando os seguintes resultados: score F1 entre 0,76 e 0,86; percentual detecção de embarcações de 70 a 100%; percentual de omissões de 0 e 30%. Estes resultados foram alcançados ao implementar apenas a calibração como etapa de pré-processamento, e utilizadas as dimensões mínimas (20 m) e máximas (280 m) das embarcações presentes nas imagens como *target* e *guard window*, devendo ser testado diferentes valores de *background window*, no caso do estudo foi entre 340 e 370 m.

A compreensão das dimensões das embarcações foi vital para otimizar a eficiência da sua detecção, auxiliando na definição dos parâmetros mais adequados para os algoritmos que variam a depender do contexto dos alvos. Da mesma forma, as etapas de pré-processamento utilizadas também influenciaram na detecção dos alvos, sendo que os melhores resultados foram obtidos quando os dados originais foram menos alterados. Por fim, foi possível identificar garimpos embarcados localizados em áreas legais e em áreas potencialmente ilegais o que pode ser utilizado como um subsídio para o controle da atividade por parte dos órgãos competentes.

Ao conseguir identificar 28 garimpos embarcados, sendo 14 em áreas legalizadas e 14 em áreas potencialmente ilegais, o método se mostrou capaz de ser utilizado como uma fonte de subsídios para os órgãos de controle otimizarem sua atuação frente à atividade.

REFERÊNCIAS

- ADAMY, A. Dinâmica fluvial do Rio Madeira. In: SILVA, R.G.C. (org.). **Porto Velho: Cultura, natureza e território**, p. 120–147, 2016.
- AIELLO, M.; VEZZOLI, R.; GIANINETTO, M. Object-based image analysis approach for vessel detection on optical and radar images. **Journal of Applied Remote Sensing**, v. 13, n. 01, p. 1, 2019. <https://doi.org/10.1117/1.JRS.13.014502>
- AN, W.; XIE, C.; YUAN, X. An improved iterative censoring scheme for CFAR ship detection with SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 8, p. 4585–4595, 2014. <https://doi.org/10.1109/TGRS.2013.2282820>
- ASNER, G. P.; LLACTAYO, W.; TUPAYACHI, R.; LUNA, E.R. Elevated rates of gold mining in the Amazon revealed through high-resolution monitoring. **Proceedings of the National Academy of Sciences**, v. 110, n. 46, p. 18454–18459, 29 out. 2013. <https://doi.org/10.1073/pnas.1318271110>
- BALZINO, M.; SECCATORE, J.; MARIN, T.; DE TOMI, G. Gold losses and mercury recovery in artisanal gold mining on the Madeira River, Brazil. **Journal of Cleaner Production**, v. 102, p. 370–377, 2015.
- BEZERRA, R. B.; DANTAS, T. R.; TRINDADE, A. G. Caracterização Temporal da Precipitação Pluvial no Município de Porto Velho/RO no Período de 1945 a 2003. **Sociedade & Natureza**, v. 22, n. 3, p. 609–623, 2010. <https://doi.org/10.1590/S1982-45132010000300015>
- BIORESITA, F.; PRIBADI, C. B.; FIRDAUS, H. S. Ship detection in Madura Strait and Lamong Gulf using Sentinel-1 SAR Data. **Digital Press Physical Sciences and Engineering**, v.1, p. 13-23, Out. 2018.
- BRASIL. **Lei nº 7.805, de 18 de julho de 1989**. Disponível em: <https://presrepublica.jusbrasil.com.br/legislacao/103411/lei-7805-89> Acesso em: 30 ago. 2022.
- BRASIL. **Anuário Mineral Brasileiro 2021**. Disponível em: <https://www.gov.br/anm/pt-br/centrais-de-conteudo/publicacoes/serie-estatisticas-e-economia-mineral/anuario-mineral/anuario-mineral-brasileiro/amb-2021-ano-base-2020.pdf> Acesso em: 04 de set. 2022.
- CAO, R.; TU, W.; YANG, C.; LI, Q.; LIU, J.; ZHU, J.; ZHANG, Q.; LI, Q.; QIU, G. Deep learning-based remote and social sensing data fusion for urban region function recognition. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 163, p. 82–97, 1 maio 2020. <https://doi.org/10.1016/j.isprsjprs.2020.02.014>
- CASTRO FILHO, H. C.; CARVALHO JÚNIOR, O. A.; CARVALHO, O.L.F.; DE BEM, P.P.; MOURA, R.S.; ALBIQUERQUE, A.O.; SILVA, C.R.; FERREIRA, P.H.G.; GUIMARÃES, R. F.; GOMES, R.A.T.

Rice crop detection using LSTM, Bi-LSTM, and machine learning models from Sentinel-1 time series. **Remote Sensing**, v. 12, n. 16, p. 1–25, 2020.

CETEM – Centro de Tecnologia Mineral. **Inventário Nacional de Emissões e Liberações de Mercúrio pelos Garimpos de Ouro**. 2018. Disponível em: <https://diretorioopre.mma.gov.br> Acesso em: 12 ago. 2022.

CRISP, D. J. **The state-of-the-art in ship detection in synthetic aperture radar imagery**. Defence Science and Technology Organisation Salisbury (Australia) Info Sciences Lab, 2004.

DECHESNE, C.; LEFÈVRE, S.; VADAIME, R.; HAJDUCH, G.; FABLET, R. Ship identification and characterization in Sentinel-1 SAR images with multi-task deep learning. **Remote Sensing**, v. 11, n. 24, p. 1–18, 2019. <https://doi.org/10.3390/rs11242997>

ESA – European Space Agency. **ESA's radar observatory mission for GMES operational services**. 2012. Disponível em: https://sentinel.esa.int/documents/247904/349449/s1_sp-1322_1.pdf Acesso em: 29 ago. 2022.

ESA - European Space Agency. **Sentinel-2 User Handbook**. 2015. Disponível em: https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook.pdf/8869acdf-d84-43ec-ae8c-3e80a436a16c?t=1438278087000 Acesso em: 01 set. 2022.

ESPIÑOZA VILLAR, R.; MARTINEZ, J.M.; TEXIER, M.; GUYOT, J.L.; FRAIZY, P.; MENESES, P.R.; OLIVEIRA, E. **Journal of South American Earth Sciences**, v. 44, p. 45–54, 2013.

FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, v. 18, n. 1, p. 11, 2019.

FITRIANI, S. P.; GAOL, J. L.; KUSHARDONO, D. Fishing-Vessel Detection Using Synthetic Aperture Radar (Sar) Sentinel-1 (Case Study: Java Sea). **International Journal of Remote Sensing and Earth Sciences (IJReSES)**, v. 16, n. 2, p. 131, 2020.

G1. **PF e fiscais do IBAMA destroem-dragas-de-garimpo-ilegal-no-rio-madeira-em-rondonia-veja-video**. 2022. Disponível em: <https://g1.globo.com/ro/rondonia/noticia/2022/10/13/pf-e-fiscais-do-ibama-destroem-dragas-de-garimpo-ilegal-no-rio-madeira-em-rondonia-veja-video.ghtml>. Acesso em: 28 fev. 2023.

IBAMA – Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais. **Ibama combate garimpo ilegal de ouro e apreende 19 dragas no rio Madeira (AM)**. 2017. Disponível em: <http://www.ibama.gov.br/noticias/422-2017/1024-ibama-combate-garimpo-ilegal-de-ouro-e-apreende-19-dragas-no-rio-madeira-am> Acesso em: 27 fev. 2023.

ISIDRO, C. M.; MCINTYRE, N.; LECHER, A.M.; CALLOW, I. Applicability of earth observation for identifying small-scale mining footprints in a wet tropical region. **Remote Sensing**, v.9, n.9, p. 945, 12 set. 2017. <https://doi.org/10.3390/rs9090945>

LOBO, F. de L.; SOUZA-FILHO, P.W.M.; NOVO, E.M.L.D.M.; CARLOS, F.M.; BARBOSA, C.C.F. Mapping Mining Areas in the Brazilian Amazon Using MSI/Sentinel-2 Imagery (2017). **Remote Sensing**, v. 10, n. 8, p. 1178, 25 jul. 2018. <https://doi.org/10.3390/rs10081178>

MARINO, A.; SANJUAN-FERRER, M.J.; HAJNSEK, I.; OUCHI, K. Ship detection with spectral analysis of synthetic aperture radar: A comparison of new and well-known algorithms. **Remote Sensing**, v.7, n.5, p. 5416–5439, 2015. <https://doi.org/10.3390/rs70505416>

MARTINS, V. S.; NOVO, E.M.L.D.M.; LYAPUSTIN, A.; ARAGÃO, L.E.O.C.; FREITAS, S.R.; BARBOSA, C.C.F. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): Insights for remote sensing and climate analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 309–327, 2018. <https://doi.org/10.1016/j.isprsjprs.2018.05.013>

MOURA, J. B.; FROTA, C. D. Transporte misto de cargas e passageiros através de barcos regionais (recreios) no estado do Amazonas: uma proposta para cálculo da modicidade da tarifa. **Revista Eletrônica Ciência e Desenvolvimento**, v. 2, n. 3, p. 23–41, 2016.

OUCHI, K. Current Status on Vessel Detection and Classification by Synthetic Aperture Radar for Maritime Security and Safety. SYMPOSIUM ON REMOTE SENSING FOR ENVIRONMENTAL SCIENCES, 38., 2016. **Proceedings...**, p. 5–12, set. 2016.

- PAES, R. L. **Detecção de Alvos na Superfície do Mar Utilizando Imagens SAR Orbitais**. 2009. 169f. Thesis (Master in Remote Sensing) – Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 2009.
- PELICH, R.; CHINI, M.; HOSTACHE, R.; MATGEN, P.; LOPEZ-MARTINEZ, C.; NUEVO, M.; RIES, P.; EIDEN, G. Large-scale automatic vessel monitoring based on dual-polarization Sentinel-1 and AIS data. **Remote Sensing**, v. 11, n. 9, p. 1–21, 2019.
- RODRIGUES, T.; SANO, E. E.; ALMEIDA, T.; CHAVES, J. M.; DOBLAS, J. Detecção de mudanças na cobertura vegetal natural do Cerrado por meio de dados de radar (Sentinel-1A). **Sociedade & Natureza**, v. 31, p. 1–22, 2019. <https://doi.org/10.14393/rbcv69n4-44337>
- RODRIGUEZ, D. A.; LOPES, L.G.; CARIELLO, F.; SIQUEIRA JÚNIOR, J. L.; PINTO, G. L.; TOMASELLA, J.; CHOU, S. C. Previsões de cheias extremas nos horizontes sazonais e de curto e médio prazos na bacia do rio Madeira: estudo de caso da enchente de 30 de março de 2014 em Porto Velho. **Revista Brasileira de Cartografia**, v. 69, n. 4, p. 827–836, 2017. <https://doi.org/10.14393/SN-v31-2019-46315>
- SIGMINE. **Sistema de Informações Geográficas da Mineração**. 2022. Disponível em: <<https://geo.anm.gov.br>> Acesso em: 10 out. 2022.
- SIMIONATO, J.; BERTANI, G.; OSAKO, L. S. Identification of artisanal mining sites in the Amazon Rainforest using Geographic Object-Based Image Analysis (GEOBIA) and Data Mining techniques. **Remote Sensing Applications: Society and Environment**, v. 24, p.100633. 1 nov. 2021. <https://doi.org/10.1016/j.rsase.2021.100633>
- SPA, S. I. **Ship Detection with Sentinel-1 Using Snap S-1 Toolbox-Gulf of Trieste, Italy Training Kit-Ocea01**. 2018. Disponível em: https://rus-copernicus.eu/portal/wp-content/uploads/library/education/training/OCEA01_ShipDetection_Trieste_Tutorial.pdf Acesso em: 02 set. 2022.
- TRINDADE, R. B. E.; BARBOSA FILHO, O. **Extração de ouro**: princípios, tecnologia e meio ambiente. CETEM/MCT & PUC-RJ, 2002.
- WANG, Y.; WANG, C.; ZHANG, H.; DONG, Y.; WEI, S. A SAR dataset of ship detection for deep learning under complex backgrounds. **Remote Sensing**, v. 11, n. 7, p. 765–778, 2019. <https://doi.org/10.3390/rs11070765>

Recebido em: 30/05/2023

Aceito para publicação em: 17/10/2023