

Identificação de Garimpos de Ouro Embarcados por meio de Algoritmos de Classificação em Imagens Sentinel-2

Identification of Gold Mining Vessels based on Classification Algorithms using Sentinel-2 Images.

Diego Henrique Costa Pereira¹ 

Roberto Arnaldo Trancoso Gomes² 

Osmar Abílio de Carvalho Júnior³ 

Renato Fontes Guimarães⁴ 

Palavras-chave:

Garimpos de ouro embarcados
Classificadores
Machine learning

Resumo

Garimpos de ouro podem ocorrer em terra firme ou em leitos de rios na forma de embarcações. Porém, a atividade precisa estar amparada com uma Permissão de Lavra Garimpeira (PLG), expedida pela Agência Nacional de Mineração, e com a devida licença ambiental do órgão ambiental competente. Nesse sentido, o uso de imagens dos satélites Sentinel-2 se apresenta como ferramenta potencial para identificação de garimpos de ouro embarcados devido à resolução temporal, gratuidade de imagens, cobertura global e resolução espacial mais refinada. Este estudo objetivou identificar garimpos de ouro embarcados no Rio Madeira, próximo à cidade Porto Velho, estado de Rondônia, em 13 imagens Sentinel-2 de 2018 a 2021, a partir dos seguintes classificadores: Support Vector Machine (SVM); K-Nearest Neighbor (KNN); Random Forest (RF); e Spectral Angle Mapper (SAM). Os resultados demonstraram que os classificadores do tipo machine learning obtiveram melhor performance, com destaque para o classificador SVM orientado a objeto que apresentou melhor score F1 médio (0,91). Além disso, o percentual de detecção obtido foi satisfatório com omissão variando de 0 a 4 garimpos ativos por imagem. Assim, a partir dos resultados obtidos, conclui-se que o uso de classificadores machine learning se mostrou eficaz para identificar garimpos de ouro embarcados.

Keywords

Gold mining vessels
Classifiers
Machine learning

Abstract

Artisanal and small-scale gold mining can occur on land or in riverbeds. However, the activity needs to be supported by a Mining Permit, issued by the Agência Nacional de Mineração, and the appropriate environmental license from the competent environmental agency. The use of images from Sentinel-2 satellites presents itself as a potential tool for identifying gold mining vessels due to the temporal resolution, free imagery, global coverage, and more refined spatial resolution. So, this study aimed to identify gold mining vessels on the Madeira River near Porto Velho city, Rondônia state, located at Brazilian Amazon, in 13 Sentinel-2 images from 2018 to 2021 using the classifiers: Support Vector Machine (SVM), K-Nearest Neighbors (KNN) Random Forest (RF) and Spectral Angle Mapper (SAM). The results showed that machine learning classifiers obtained the best performance, especially the object-oriented SVM classifier, which had the best average F1 score (0.91). In addition, the detection percentage of gold mining vessels originated by this classifier was satisfactory, with only 0 to 4 active gold mining vessels with sediment plumes being omitted per image. Therefore, based on the results obtained, it was concluded that the use of machine learning classifiers proved to be effective in identifying gold mining vessels.

¹ Universidade de Brasília - UnB, Brasília, DF, Brasil. diegohcpereira1988@gmail.com

² Universidade de Brasília - UnB, Brasília, DF, Brasil. robertogomes@unb.br

³ Universidade de Brasília - UnB, Brasília, DF, Brasil. osmarjr@unb.br

⁴ Universidade de Brasília - UnB, Brasília, DF, Brasil. renatofg@unb.br

INTRODUÇÃO

Garimpos de ouro ocorrem em terra firme ou em leitos de rios e podem operar caso possuam Permissão de Lavra Garimpeira (PLG) expedida pela Agência Nacional de Mineração (Brasil, 1989). Os garimpos em rios são embarcações que dragam sedimentos de fundo que podem conter de 3 a 30 g/m³ de ouro (Balzino *et al.*, 2015). Estas embarcações possuem o maquinário necessário para produção do ouro e caracterizam-se por lançar o rejeito do processo produtivo diretamente no rio e se agrupar durante a operação (Figura 1). O rejeito lançado possui concentração de sedimentos maior que a concentração natural das águas e pode levar a formação de plumas de sedimentos (Fernandes

et al., 2014), porém isto depende da capacidade de dragagem, tipo de sedimento, coloração da água, entre outros (Cetem, 2018; Barbosa *et al.*, 2019).

A resposta espectral da água registrada por sensores óticos é resultado da interação da radiação eletromagnética com a coluna d'água e com Compostos Opticamente Ativos (COA) - partículas inorgânicas, matéria orgânica e pigmentos de fitoplânctons (Lobo *et al.*, 2012). Barbosa *et al.* (2019) realizaram compilação de vários estudos que usam sensoriamento remoto aplicado aos recursos hídricos, demonstrando a capacidade para diferenciar coloração de água, estimar COA e avaliar a reflectância de cada tipo de COA ao longo do espectro eletromagnético.

Figura 1 - Exemplo de embarcação de garimpo de ouro.



Fonte: Balzino *et al.* (2015).

Variadas técnicas de sensoriamento remoto são empregadas para detecção de garimpos localizados em terra firme (Asner *et al.*, 2013; Isidro *et al.*, 2017; Simionato *et al.*, 2021).

Contudo, métodos dedicados exclusivamente à identificação de garimpos embarcados são escassos devido: ao tamanho reduzido dos alvos e sua alta capacidade de locomoção (Lobo *et al.*, 2018; Trindade; Barbosa Filho, 2002); à inexistência de sistemas de localização automática e tempo real (Dechesne *et al.*, 2019), seja pelo relevante grau de informalidade da atividade, precariedade e porte das embarcações (Cetem, 2018).

Por outro lado, existem inúmeras abordagens que utilizam imagens de satélite para detecção de embarcações. Por exemplo, Ciocarlan e Stoian (2021), utilizaram a arquitetura de deep learning U-Net, alcançando score F1 médio de 53,1, e concluíram que tais métodos apresentam resultados promissores, obtendo menor incidência de falsos negativos, tanto para

grandes (> 2.500 m²) quanto para pequenas (<2.500 m²) embarcações. Porém, ressaltaram que são métodos sensíveis à quantidade e qualidade das amostras. Heiselberg (2016) propôs algoritmo de avaliação geométrica e de resposta espectral das embarcações e obteve sucesso na detecção, identificação da orientação de navegação e mensuração da largura e comprimento dos alvos acima de 30 m. Embarcações menores que 30 m foram apenas detectadas, sem estimativa dos outros parâmetros.

Em outro estudo, Heiselberg e Heiselberg (2017), desenvolveram classificador supervisionado orientado a objeto para detecção de embarcações e diferenciação de outros alvos (gelo, pequenas ilhas e nuvens), destacando a perda de eficiência conforme a dimensão da embarcação diminui, pois 32% das embarcações menores que 10 m foram confundidas com nuvens e outros pequenos objetos.

Kanjir (2019) alcançou resultados satisfatórios na detecção de embarcações, inclusive daquelas com dimensão inferior a 20 m, alcançando taxa de detecção de até 0,96. Para tal, recorreu a árvore de decisão após realizar uma pré-deteção baseada em subtração de bandas. Porém, destacou que a baixa presença/inexistência de embarcações por imagem e a pequena dimensão podem ocasionar piora na eficiência do método.

Um dos grandes desafios para estes estudos é obter quantidade suficiente de amostras de treinamento de qualidade, por poder haver poucas embarcações nas imagens selecionadas (Ciocarlan; Stoian, 2021).

Portanto, o presente estudo objetiva avaliar o uso de imagens Sentinel-2 para identificação de garimpos de ouro embarcados a partir dos classificadores machine learning Support Vector Machine (SVM) (Vapnik, 1995), K-Nearest Neighbor (KNN) (Fix; Hodges, 1951), Random Forest (RF) (Breiman, 2001), e do classificador espectral Spectral Angle Mapper (SAM) (Kruse *et al.*, 1993).

MATERIAIS E MÉTODOS

Área de Estudo

A área de estudo compreende o Rio Madeira, na região de Porto Velho, Rondônia (Figura 2). A região abrange 80 km do rio, sendo uma das

principais áreas de garimpagem de ouro embarcado no Brasil, totalizando 9.400 hectares de Permissão de Lavra Garimpeira (PLG) e 14.400 hectares de Requerimento de PLG (Sigmine, 2022).

O Rio Madeira é um rio de águas brancas com elevada concentração de sólidos em suspensão (Espinoza Villar *et al.*, 2013). O clima da região é classificado como Awi e seu regime pluviométrico varia 38,7 a 329 mm/mês (Bezerra *et al.*, 2010). Seu comportamento hidrológico é tipicamente sazonal, com vazão partindo de 5.000 m³/s no período seco a 50.000 m³/s no período chuvoso (Adamy, 2016).

Além disso, apresenta boas condições de navegabilidade com largura de 700 a 2.000 m e cota fluviométrica de 8 a 20 m (Rodríguez *et al.*, 2017).

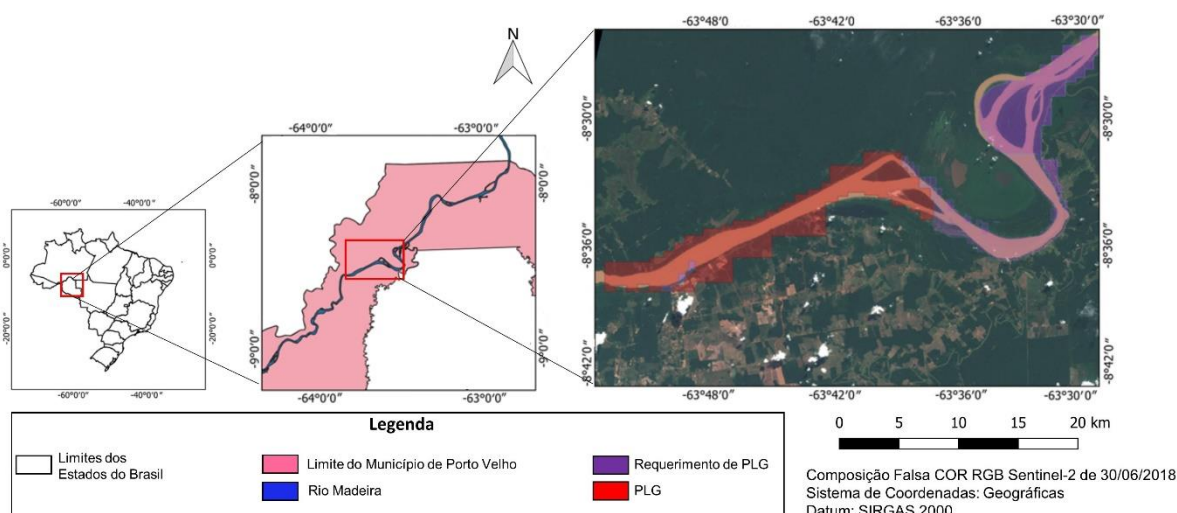
Metodologia

A metodologia do trabalho foi dividida em cinco etapas, conforme Figura 3.

Etapa 1 - Seleção das Imagens


A missão Sentinel-2 é composta pelos satélites 2A e 2B que possuem sensores Multiespectral Instruments (MSI), registrando informações em 13 bandas espectrais do azul ao infravermelho de ondas curtas com tempo de revisita de 5 dias, quando considerados os dois satélites, e resolução radiométrica de 12 bits.

Figura 2 - Área de Estudo.



Fonte: Os autores (2023).

Figura 3 - Metodologia Utilizada.




Fonte: Os autores (2023).

As imagens são gratuitas e disponibilizadas georreferenciadas com as seguintes resoluções espaciais: i) 10 m para azul, verde, vermelho e infravermelho próximo (IVP); ii) 20 m para limite do vermelho (LM) 1 a 4 e infravermelho de ondas curtas 1 e 2 (IVOC); iii) 60 m para aerossol, vapor d'água e cirrus (ESA, 2015). Foram avaliadas imagens da órbita 20LMR

entre os anos de 2018 e 2021 para selecionar aquelas com presença de garimpos embarcados que coincidisse com as datas das imagens que foram utilizadas para validação das classificações. A avaliação foi feita visualmente aplicando realce histogrâmico em composições falsa cor vermelho, verde e azul (Figura 4).

Figura 4 - Plumagens de Sedimentos de Garimpos Embarcados em Imagem Sentinel-2 de 14/06/2021 em Composição Falsa Cor Azul, Verde e Vermelho: a) Sem realce; b) Com realce na banda do Vermelho.

Em verde a pluma.



Fonte: Os autores (2023).

Treze imagens, entre junho e setembro de 2018 a 2021, foram selecionadas (Tabela 1). Este é o período de menores chuvas e com cobertura

de nuvens de 0 a 40% na região (Martins *et al.*, 2018).

Tabela 1 – Data das Imagens Sentinel-2 Utilizadas.

Data	Garimpo sem Pluma	Garimpo com Pluma
30/06/2018	Sim	Sim
25/07/2018	Sim	Sim
19/08/2018	Sim	Não
20/06/2019	Sim	Não
09/07/2020	Sim	Sim
22/09/2020	Sim	Não
14/06/2021	Sim	Sim
14/07/2021	Sim	Sim
24/07/2021	Sim	Sim
29/07/2021	Sim	Sim
08/08/2021	Sim	Não
13/08/2021	Sim	Sim
18/08/2021	Sim	Sim

Fonte: Os autores (2023).

Etapa 2 - Pré-Processamento

As imagens foram adquiridas no nível de processamento L1C sem correção atmosférica sendo convertidas para o nível L2A para descontar os efeitos atmosféricos usando o plugin Sen2Cor, desenvolvido para imagens Sentinel-2 (ESA, 2015; Louis *et al.*, 2016). Posteriormente, as bandas do infravermelho foram reamostradas para 10 m, com exceção do infravermelho próximo que já possui esta resolução.

Etapa 3 - Recorte e Aplicação de Máscara

As imagens foram recortadas nos limites da área de estudo e uma máscara foi aplicada na porção continental. As máscaras foram geradas a partir da edição manual do arquivo vetorial de massas d'água do Brasil, disponibilizado em escala 1:100.000 pela Agência Nacional de Águas e Saneamento Básico (Brasil, 2022), sobre as imagens Sentinel-2 utilizadas no estudo.

Etapa 4 - Treinamento e Classificação

As amostras de treinamento foram coletadas nas imagens Sentinel-2, sendo que a quantidade não foi igual em cada imagem, pois o número de embarcações, garimpos embarcados e plumas de sedimentos varia entre datas distintas, existindo por vezes poucos alvos na imagem.

Foram coletados 3000 pixels para água (na inexistência de pluma), vegetação e solo, os dois últimos presentes nas ilhas e nos bancos de areia existentes ao longo do rio. Quando existia pluma, a quantidade coletada de pixels atingiu o máximo possível e, nesses casos, a quantidade de pixels de água foi a mesma.

Foram coletados o máximo possível de pixels por imagem para garimpos embarcados (Tabela 2 e Figuras 5).


Para a classificação considerou-se os seguintes classificadores: RF; KNN; SVM; e SAM. O RF gera árvores de decisão de forma aleatória com base em um subconjunto de dados e procura o melhor resultado a partir de um processo de votação (Breiman, 2001). O KNN avalia a distância da amostra em relação aos seus "k" vizinhos mais próximos e a classifica conforme a maioria dos vizinhos (Fix; Hodges, 1951).

Tabela 2 - Quantidade de Pixels de Treinamento por Imagens.

Data	Classes					
	Vegetação	Solo	Água	Pluma	Embarcações	Garimpos
30/06/2018	3000	3000	1000	1000	250	95
25/07/2018	3000	3000	1200	1200	330	145
19/08/2018	3000	3000	3000	Inexiste	230	100
20/06/2019	3000	3000	3000	Inexiste	380	80
09/07/2020	3000	3000	1500	1500	390	100
22/09/2020	3000	3000	3000	Inexiste	160	45
14/06/2021	3000	3000	1000	1000	130	100
14/07/2021	3000	3000	2000	2000	300	200
24/07/2021	3000	3000	1000	1000	270	225
29/07/2021	3000	3000	1500	1500	450	160
08/08/2021	3000	3000	3000	Inexiste	285	120
13/08/2021	3000	3000	1000	1000	420	100
18/08/2021	3000	3000	1000	1000	255	135

Fonte: Os autores (2023).

Figura 5 - Exemplos de Amostras: a) água e embarcações; b) garimpos embarcados; c) plumas de sedimentos vistas com realce; d) embarcações e água; e); vegetação, águas e plumas de sedimentos vistas sem realce.



Fonte: Os autores (2023).

O SVM plota amostras como pontos no espaço n-dimensional e busca a melhor forma de separar as classes a partir da construção de um hiperplano que age como fronteira entre as classes (Vapnik, 1995). O SAM se baseia na similaridade das respostas espectrais e calcula ângulos entre as amostras a serem classificadas e as de referência (Kruse *et al.*, 1993). RF, KNN e SVM são classificadores machine learning, podendo ter uma abordagem de classificação pixel a pixel ou de classificação orientado a objeto. O método pixel a pixel utiliza a informação espectral dos pixels enquanto método orientado a objeto realiza o agrupamento dos pixels a fim de criar objetos que possuem determinada similaridade, sendo uma etapa vital a segmentação da imagem (Simionato *et al.*, 2021). As segmentações foram realizadas no software ArcGIS Pro a partir do algoritmo Mean Shift Segmentation (Comaniciu; Meer, 2002) que dispersa os pixels em um espaço n-dimensional e constrói uma área de interesse, calcula o centroide e a direção para qual a área de interesse deve se mover. Após, altera o centroide e repete o processo até que seja atingida a convergência, ou seja, que todos os pixels sejam agrupados em segmentos. O software ArcGIS Pro requer três parâmetros para realizar a segmentação: detalhes espectrais e espaciais (variam de 1 a 20); tamanho mínimo do segmento (ArcGIS PRO, 2023). O primeiro refere-se ao nível de importância dado às diferenças espectrais entre os pixels. O segundo controla o nível de

relevância dado à proximidade entre os pixels. O último é o tamanho mínimo do segmento a ser construído (Lodi *et al.*, 2019). No caso do detalhe espectral, valores maiores são apropriados para separar objetos que possuem características espectrais semelhantes, enquanto valores menores são apropriados para generalização de objetos. No caso do detalhe espacial, os valores maiores são apropriados quando os objetos são pequenos e formam clusters, e o oposto se aplica para objetos maiores (ArcGIS PRO, 2023).

Foram testadas diferentes combinações e após avaliação visual das segmentações, observando se os segmentos gerados foram condizentes em criar clusters do tamanho das embarcações, bem como separar águas de plumas de sedimentos, optou-se por utilizar 20 para detalhe espectral e 18 para detalhe espacial. Essa combinação gerou segmentação composta por vários pequenos segmentos que, após avaliação visual, mostrou-se adequada para delimitar embarcações e plumas de sedimentos, ressaltando, também, a diferença espectral entre os segmentos. Foi utilizado 1 pixel (10 m) como tamanho do segmento, menor dimensão de um garimpo embarcado conforme a resolução das bandas de 10 m das imagens Sentinel-2. Por fim, os pixels de treinamento dos classificadores pixel a pixel foram plotados na imagem segmentada para coleta dos segmentos de treinamentos, e não houve limitação de amostras por classe.

Etapa 5 – Validação das Classificações

Foram utilizados 300, 150 ou 100 pixels para validação das classificações. A quantidade variou em função do número e tamanho de embarcações, garimpos embarcados e plumas de sedimentos presentes nas imagens. Os pixels foram coletados mediante à visualização das imagens Planet de 3 m de resolução espacial que foram disponibilizadas pelo Programa Brasil M.A.I.S (Redemais/Mjisp © 2020 Planet, 2022).

Foram calculados o Índice *Kappa* e *score* F1 (Cao *et al.*, 2020; Salgado *et al.*, 2019). O *score* F1 (Equação 1) é calculado com base no *precision* (Equação 2) e no *recall* (Equação 3) que indicam a precisão da detecção do alvo e capacidade de discriminação:

$$\text{Score F1} = 2 * \frac{P * R}{P + R} \quad (1)$$

$$P = \frac{\Sigma VP}{\Sigma VP + \Sigma FP} \quad (2)$$

$$R = \frac{\Sigma VP}{\Sigma VP + \Sigma FN} \quad (3)$$

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

Ao analisar os resultados do F1 deve ser buscado um equilíbrio entre o *precision* e *recall*, pois um resultado alto de *precision* e baixo de *recall* significa que poucos alvos foram devidamente classificados, contudo estes poucos alvos se assemelham bastante com os dados de controle (relação com falsos negativos). Por outro lado, *precision* baixo e alto *recall* indicam que os alvos foram amplamente classificados, porém, generalizados, possuindo relação com falsos positivos (Cao *et al.*, 2020; Barbosa *et al.*, 2021).

Por fim, verificou-se também o percentual de detecção e omissão dos garimpos em operação, ou seja, embarcações que possuem pluma de sedimentos com origem em algum ponto neste alvo (Figura 4), calculados conforme Equações 4 e 5.

$$\% \text{ Detecção} = \left(\frac{Gd * 100}{Gt} \right) \quad (4)$$

$$\% \text{ Omissão} = \left(\frac{Go * 100}{Gt} \right) \quad (5)$$

Onde: Gd = garimpos detectados; Gt = garimpos totais; Go = garimpos omitidos.

RESULTADOS E DISCUSSÃO

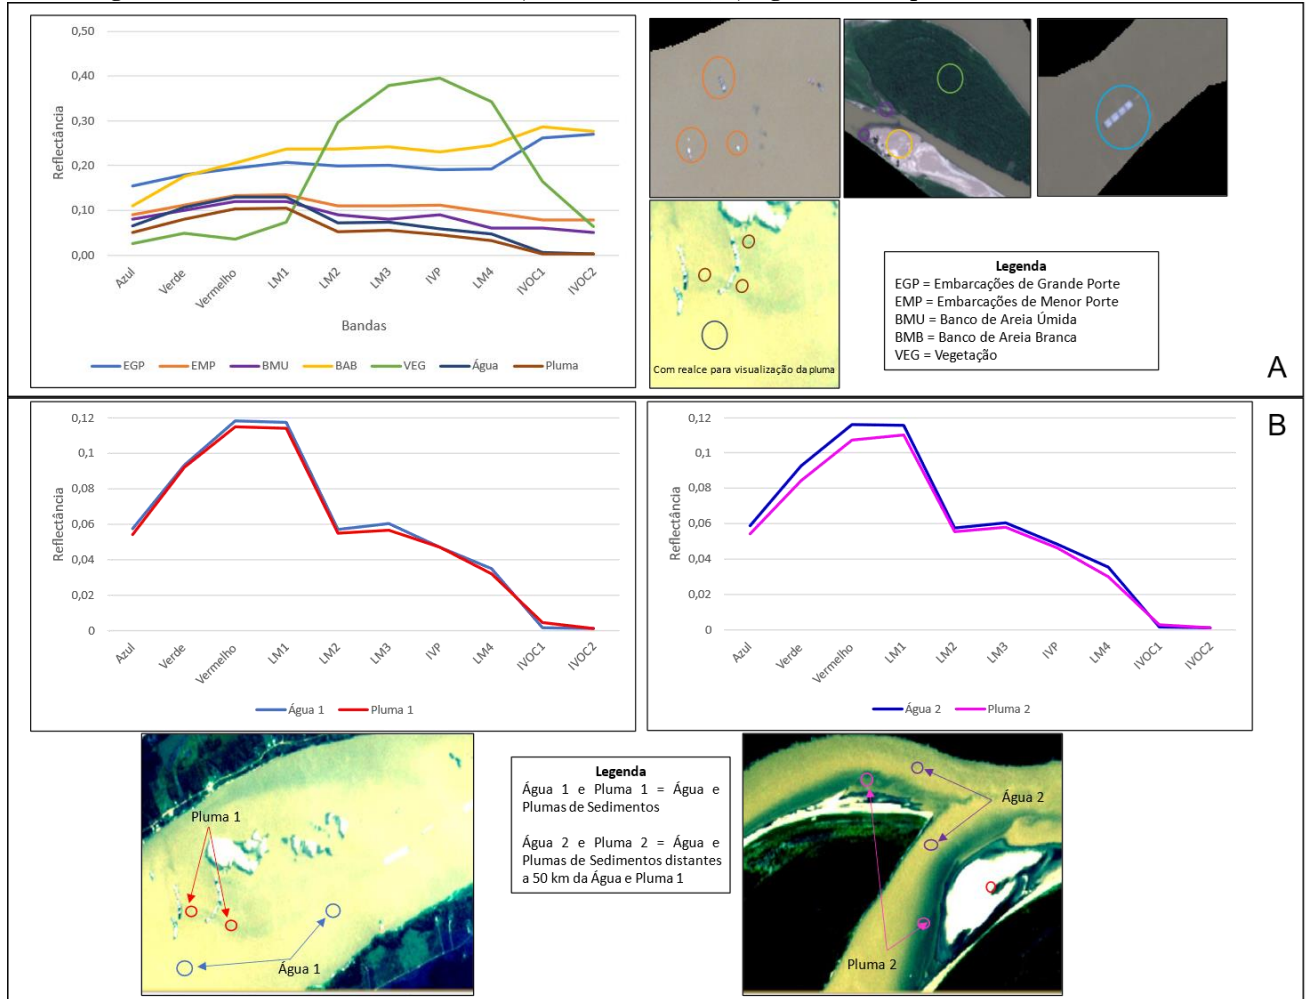
Os alvos presentes nas imagens foram: água; pluma de sedimentos; garimpos embarcados; embarcações (variados portes); solo; bancos de areia; e vegetação (Figura 6a). As águas do Rio Madeira são turvas e possuem elevada concentração de sedimentos em suspensão com reflectância naturalmente maior que a água com baixa concentração de sedimentos (Espinoza Villar *et al.*, 2013).

Águas e plumas de sedimentos apresentaram respostas muito próximas, contudo a reflectância das plumas de sedimentos é um pouco menor do que a reflectância das águas entorno dos garimpos embarcados. O pico de reflectância, bem como maior diferença entre estes alvos (0,03), ocorreu nas bandas verde, vermelho e LM1, sendo maior no vermelho, contudo ainda muito baixo. A maior reflectância no verde e vermelho ocorre devido ao maior espalhamento da radiação eletromagnética pela presença de material particulado e menor absorção da água nesta faixa (Barbosa *et al.*, 2019; Goodin *et al.*, 1993).

A diferença entre os alvos, bem como a reflectância, diminui a partir de LM1, tendendo a zero na região do IVOC.

Além da resposta próxima de água e pluma de sedimentos, ressalta-se que a concentração natural dos COA nos rios amazônicos varia a depender do período hidrológico - vazante, baixa, cheia ou enchente (Barbosa, 2005). Além disso, as plumas de sedimentos (Figura 6b) podem apresentar mesmo comportamento espectral da água em outras partes do rio quando a concentração sedimentos em suspensão forem semelhantes. Isso foi percebido em áreas próximas a bancos de areias.

Figura 6 – Reflectância dos Alvos: a) todos os alvos; b) água versus pluma de sedimentos.



Fonte: Os autores (2023).

Heiselberg (2016) identificou que as embarcações de grande porte (>100 m) possuem reflectância mais elevada, alcançando maiores valores a partir do IVOC, comportamento parecido com os bancos de areia branca presentes na área de estudo. Estes alvos possuem resposta espectral parecida entre si, sendo a maior diferença a partir da banda LM1. Embarcações menores, incluindo garimpos embarcados, e bancos de areia com a presença de água, de aspecto lamacento, apresentam resposta inferior e próximas em todas as bandas.

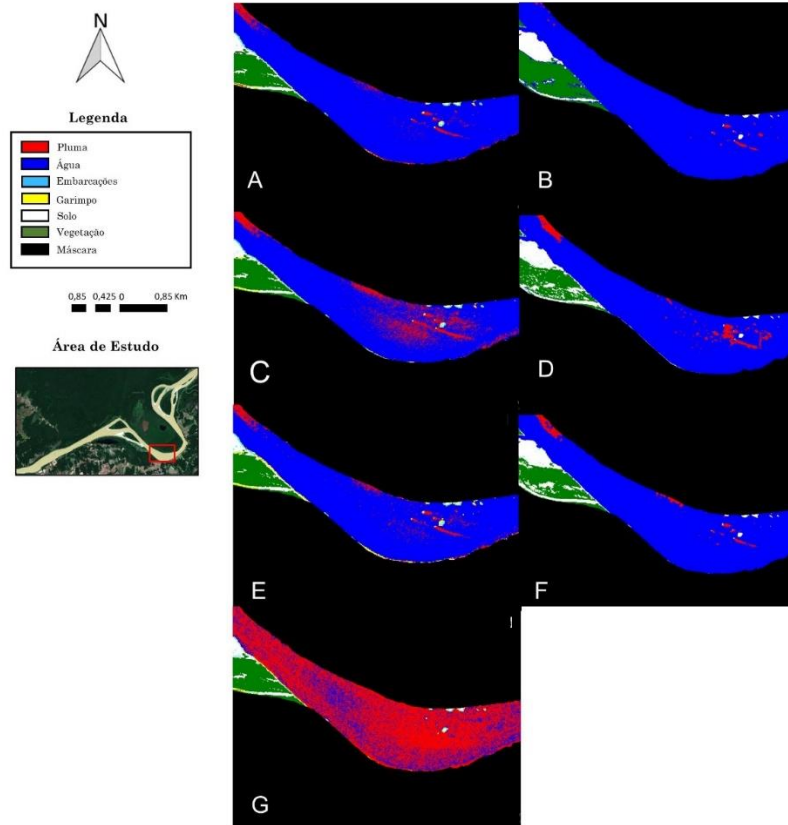
As menores dimensões das embarcações dificultam o registro das imagens devido à limitação da resolução espacial e ao tipo de material da embarcação que pode ser de palha, madeira ou outros materiais de baixa reflectância (Kanjir, 2019). Por fim, as classes utilizadas no estudo foram: água; pluma de sedimentos (quando existente); embarcações (grande, médio e pequeno porte); garimpos (embarcações de médio e pequeno porte com comportamento típico de se agrupar); solo; e vegetação.

A Figura 7 exemplifica as classificações da imagem de 14/07/2021, destacando as diferenças na detecção das plumas de sedimentos dos garimpos embarcados entre os classificadores. A Tabela 3 demonstra que o Índice Kappa variou de 0,70 a 0,95, resultados considerados “muito bom” ($0,6 < k < 0,8$) ou “excelente” ($0,8 < k < 1$) (Salgado *et al.*, 2019). Ainda, o score F1 variou de 0,74 a 0,96, resultados bastante satisfatórios (Barbosa *et al.*, 2021; Cao *et al.*, 2020).

Os valores médios de Kappa variaram de 0,76 a 0,89 e de F1 de 0,80 a 0,91, com desvio padrão de 0,06 a 0,02, no qual o SVM OBIA apresentou melhor desempenho, seguido por SVM Pixel, KNN OBIA, KNN Pixel, RF OBIA, RF Pixel e SAM (Tabela 4).

Os valores obtidos demonstram estar parecidos com literatura de referência no qual o fator de performance variou de até 0,68 a 1 (Heiselberg; Heiselberg, 2017). Vale ressaltar que as métricas do presente estudo não foram tão diferentes entre os classificadores SVM, KNN e RF com valores médios de Kappa de 0,81 a 0,89 e F1 de 0,84 a 0,91.

Figura 7- Classificações da Imagem de 14/07/2021: a) SVM Pixel; b) SVM OBIA; c) KNN; Pixel; d) KNN OBIA; e) RF Pixel; f) RF OBIA; g) SAM.



Fonte: Os autores (2023).

Tabela 3 - Resultados do Índice Kappa e Score F1.

Classificador	Métrica	Data												
		30/06/18	25/07/18	19/08/19	20/06/19	09/07/20	22/09/20	14/06/21	14/07/21	24/07/21	29/07/21	08/08/21	13/08/21	18/08/21
SVM Pixel	Kappa	0,86	0,83	0,84	0,88	0,80	0,84	0,87	0,89	0,87	0,90	0,86	0,85	0,85
	F1	0,88	0,86	0,87	0,91	0,83	0,87	0,89	0,91	0,89	0,92	0,88	0,88	0,87
SVM OBIA	Kappa	0,88	0,84	0,93	0,93	0,87	0,87	0,95	0,89	0,91	0,91	0,87	0,89	0,89
	F1	0,89	0,86	0,94	0,94	0,88	0,89	0,96	0,91	0,92	0,92	0,89	0,90	0,91
KNN Pixel	Kappa	0,81	0,80	0,83	0,86	0,81	0,80	0,86	0,88	0,86	0,89	0,86	0,85	0,85
	F1	0,84	0,84	0,86	0,89	0,83	0,84	0,88	0,90	0,88	0,91	0,88	0,87	0,88
KNN OBIA	Kappa	0,81	0,80	0,87	0,88	0,81	0,82	0,84	0,86	0,87	0,88	0,86	0,86	0,85
	F1	0,84	0,83	0,89	0,90	0,83	0,85	0,86	0,89	0,89	0,90	0,88	0,88	0,87
SAM	Kappa	0,70	0,73	0,80	0,85	0,72	0,79	0,82	0,72	0,73	0,71	0,82	0,83	0,73
	F1	0,74	0,76	0,84	0,87	0,76	0,82	0,85	0,77	0,77	0,75	0,85	0,85	0,78
RF Pixel	Kappa	0,73	0,79	0,83	0,74	0,71	0,74	0,81	0,86	0,87	0,89	0,83	0,83	0,92
	F1	0,77	0,82	0,85	0,76	0,74	0,79	0,84	0,87	0,90	0,91	0,86	0,82	0,93
RF OBIA	Kappa	0,74	0,85	0,85	0,84	0,84	0,79	0,84	0,83	0,84	0,82	0,85	0,85	0,82
	F1	0,77	0,87	0,86	0,86	0,86	0,80	0,86	0,84	0,85	0,84	0,87	0,85	0,84

Nota: pixel = método pixel a pixel; OBIA = método orientado a objeto

Fonte: Os autores (2023).

Tabela 4 - Kappa e F1 Médio e Desvio Padrão das Classificações.

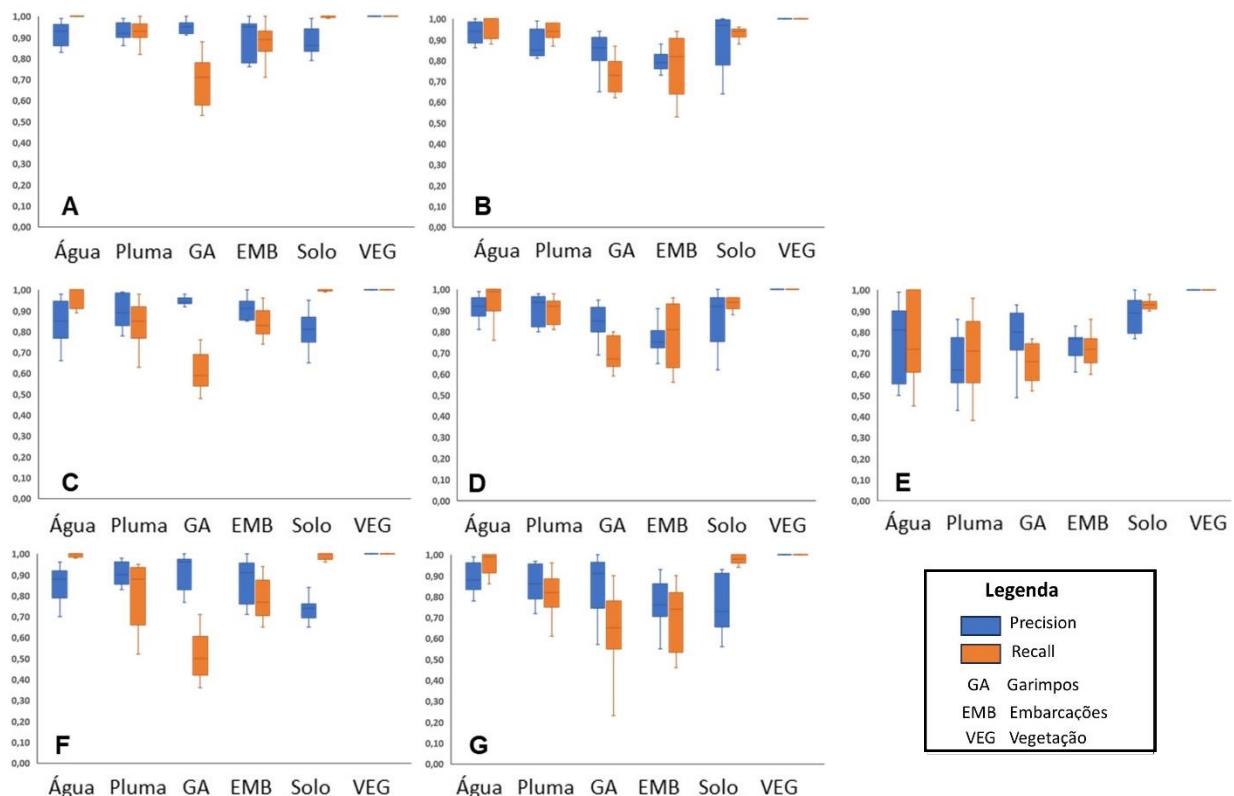
Classificador	Kappa Médio	Desvio Padrão	F1 Médio	Desvio Padrão
SVM OBIA	0,89	0,03	0,91	0,03
SVM Pixel	0,86	0,03	0,88	0,02
KNN OBIA	0,85	0,03	0,87	0,02
KNN Pixel	0,84	0,03	0,87	0,02
RF OBIA	0,83	0,03	0,84	0,03
RF Pixel	0,81	0,06	0,84	0,06
SAM	0,76	0,05	0,80	0,04

Fonte: Os autores (2023).

Os valores de *precision* e *recall* foram mais variados, com *precision* entre 0,43 e 1 e o *recall* entre 0,2 e 1 (Figura 8). Algumas classes estudadas foram facilmente classificadas, vegetação e água, quando inexistiam plumas de sedimentos. Nesses casos, *precision* e *recall* foram iguais a 1. Porém, os classificadores tiveram maior dificuldade para separar alvos com resposta espectral próxima, como, garimpos e embarcações – que apesar de apresentarem *precision* entre 0,77 e 0,88 (garimpos) e 0,78 e 0,89 (embarcações) obtiveram maior quantidade de falsos negativos, com *recall* de 0,58 a 0,71 (garimpos) e 0,69 a 0,87 (embarcações).

Este comportamento é comum na classificação de diferentes tipos de embarcações porque a resposta espectral das embarcações não apresenta padrão claro, por vezes são parecidas ou muito diferentes, afetando a performance de classificadores (Heiselberg, 2016). Além disso, o tamanho reduzido das embarcações afeta os métodos, fazendo o fator de performance decair de 0,93 para 0,68 para embarcações menores por causa de omissões e confusões com outros pequenos alvos (Heiselberg; Heiselberg, 2017).

Figura 8 - Precision e Recall para as Classificações: a) SVM OBIA; b) SVM Pixel; c) KNN OBIA; d) KNN Pixel; e) SAM; f) RF OBIA; g) RF Pixel.



Fonte: Os autores (2023).

Comportamento similar foi percebido para garimpos e bancos de areia úmida (solo), justificada pela baixa e próxima resposta espectral destes alvos e pelo tamanho reduzido de alguns bancos de areia que apresentam resposta semelhante a pequenos alvos não água (Kikaki *et al.*, 2022).

O detalhamento dos *scores* F1 médios reforça o melhor comportamento do SVM OBIA que além de alcançar melhor *score* apresentou maior constância, com menores quantidades de falsos negativos e falsos positivos, seguido pelo SVM Pixel (Tabela 5). KNN e RF apresentaram resultados inferiores, sendo que o RF apresentou maior inconstância, principalmente

quanto à ocorrência de falsos negativos. O SAM obteve os piores resultados, com maior grau de confusão principalmente entre garimpos e embarcações, alvos com resposta espectral semelhante (Figura 9).

Ainda, o SAM apresentou dificuldade em classificar água e pluma de sedimentos, havendo confusão e até mesmo ausência na delimitação das plumas. Isso ocorreu devido à baixa variação da concentração de COA, uma vez que diferentes tipos de águas são mais bem classificados quando existe maior diferença na concentração de COA (Barbosa, 2005; Vantrepotte *et al.*, 2012).

Tabela 5 - Precision, Recall e Score F1 das Classificações.

Classes	SVM Pixel		SVM OBIA		KNN Pixel		KNN OBIA		RF Pixel		RF OBIA		SAM	
	Precision Médio	Recall Médio	Precision Médio	Recall Médio	Precision Médio	Recall Médio	Precision Médio	Recall Médio	Precision Médio	Recall Médio	Precision Médio	Recall Médio	Precision Médio	Recall Médio
Água	0,88	0,96	0,90	0,99	0,92	0,95	0,85	0,96	0,89	0,95	0,88	0,91	0,75	0,78
Pluma	0,88	0,94	0,91	0,94	0,90	0,87	0,90	0,88	0,82	0,81	0,82	0,82	0,65	0,70
Garimpo	0,84	0,72	0,88	0,72	0,84	0,69	0,86	0,59	0,77	0,63	0,78	0,64	0,78	0,65
Embarcação	0,80	0,78	0,89	0,88	0,76	0,79	0,77	0,83	0,78	0,69	0,81	0,72	0,73	0,72
Solo	0,89	0,93	0,87	0,99	0,87	0,93	0,84	1,00	0,86	0,96	0,85	0,93	0,88	0,93
Vegetação	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
F1 Água	0,92		0,94		0,93		0,90		0,92		0,89		0,77	
F1 Pluma	0,91		0,92		0,88		0,89		0,82		0,82		0,68	
F1 Garimpo	0,78		0,79		0,76		0,70		0,69		0,70		0,71	
F1 Embarcação	0,79		0,89		0,77		0,80		0,73		0,76		0,72	
F1 Solo	0,91		0,93		0,90		0,91		0,91		0,89		0,90	
F1 Vegetação	1,00		1,00		1,00		1,00		1,00		1,00		1,00	
Score F1 Médio	0,88		0,91		0,87		0,87		0,84		0,84		0,80	

Fonte: Os autores (2023).

Figura 9 - Confusão entre Pequenas Embarcações e Garimpos com Outros Alvos. Em Vermelho Pequenos Bancos de Areia Escura. Em Branco Pequenas Embarcações e Garimpos: a) Imagem de 24/07/2021. b) 18/08/2021.



Fonte: Os autores (2023).

Ao comparar a abordagem pixel a pixel versus orientada a objeto, é perceptível a diferença nos resultados para o SVM (Tabela 5) quando aprimorou todas as métricas de avaliação. Keshtkar *et al.* (2017) e Noi e Kappas (2017) obtiveram resultados semelhantes em que o classificador SVM apresentou as melhores métricas para identificação de diferentes tipos

de águas, melhorando a performance, inclusive, quando utilizado método orientado a objeto (Hartoni *et al.*, 2022). Os resultados para KNN e RF foram variados, pois apesar de terem sido mantidos os *scores* F1 médios, verificou-se que o *precision* e *recall* foram mais aleatórios, melhorando para alguns alvos e piorando para

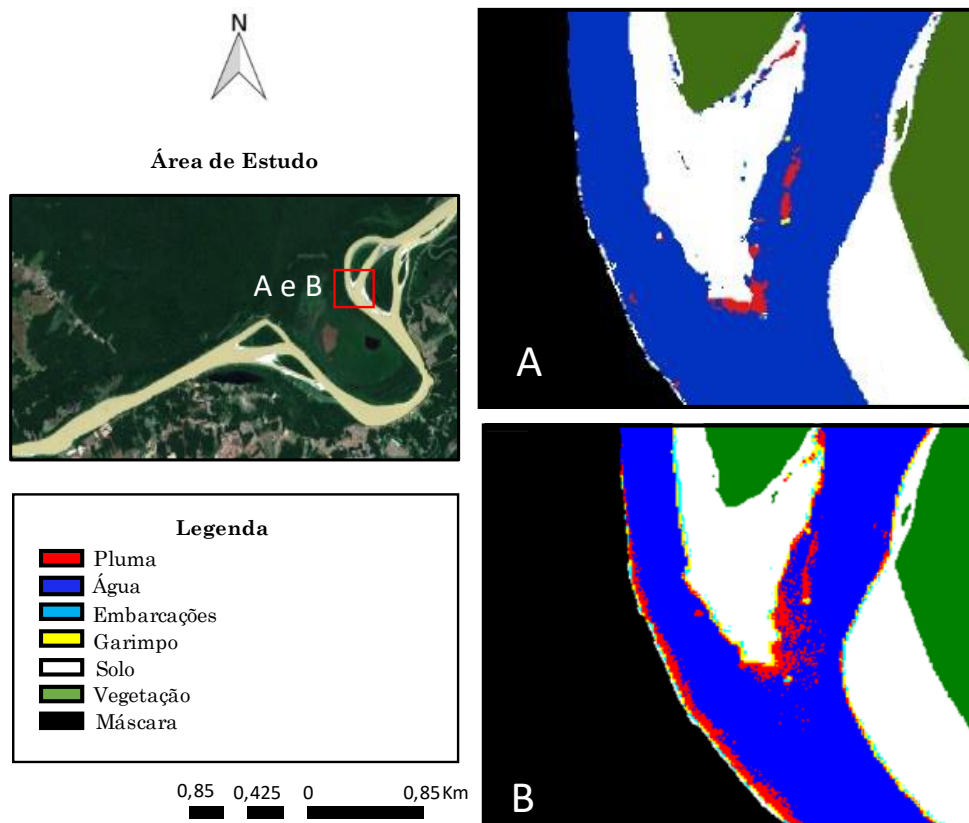
outro, porém ainda se mostraram mais efetivos que SAM.

Os classificadores pixel a pixel cometeram muitos erros de comissão entre garimpos embarcados e solo, gerando classificações com erros sistêmicos (Figuras 10). Neste ponto residiu a principal vantagem em utilizar o método orientado a objeto. Todos os classificadores OBIA atenuaram de forma acentuada este tipo de erro e deixaram as classificações mais limpas porque ao avaliar segmentos com determinada similaridade

espectral e espacial e não somente pixels, ampliou-se a capacidade de distinção entre as classes (Simionato *et al.*, 2021).

Por fim, verificou-se que a detecção dos garimpos sem plumas nas classificações SVM OBIA foi de 100%. Em relação aos garimpos em operação, ou seja, aqueles que originam plumas de sedimentos, a detecção variou de 73 a 100%, e omissão de 0 a 26,6%, deixando de detectar de 0 a 4 garimpos com plumas de sedimentos por imagem (Tabela 6).

Figura 10 - Melhoras nas Classificações OBIA X Pixel em Imagem de 13/08/2021: a) SVM OBIA; b) SVM Pixel.



Fonte: Os autores (2023).

Tabela 6 - Identificação de Garimpos em Operação no Classificador SVM OBIA.

Data	Garimpos em Operação Verdades	Garimpos em Operação Detectados	% de Detecção	Não Detectadas	% de Omissão
30/06/18	18	17	94,44	1	5,56%
25/07/18	6	6	100	0	0,00%
09/07/20	9	8	88,89	1	11,11%
14/06/21	15	11	73,33	4	26,67%
14/07/21	21	17	80,95	4	19,05%
24/07/21	8	6	75	2	25,00%
29/07/21	5	4	80	1	20,00%
13/08/21	3	3	100	0	0,00%
18/08/21	9	8	88,89	1	11,11%
Média	--	--	86,83	2	13,17

Fonte: Os autores (2023).

Estes resultados são similares aos percebidos por Kanjir (2019), que obteve detecção de 63 a 96% e omissão entre 4 e 34%, e por Heiselberg e Heiselberg (2017) que obteve detecção de 67 a 100% e omissão de 0 a 33%. Em todos os casos as piores performances foram percebidas por omissões de pequenas embarcações. No presente estudo, as omissões não ocorreram pela não detecção do garimpo em operação em si, mas

porque não foi possível identificar a pluma de sedimentos com origem na embarcação.

Nos casos dos garimpos sem pluma a avaliação visual se faz extremamente necessária para atestar que os alvos são garimpos de fato, uma vez que somente por meio visual é possível identificar o comportamento típico de tais garimpos (agrupamentos de embarcações) (Figura 11).

Figura 11 - Garimpos Sem Pluma Agrupados em Imagem de 29/07/2021.



Fonte: Os autores (2023).

CONCLUSÃO

Os resultados demonstraram que o classificador SVM apresentou as melhores métricas de avaliação. Ao comparar a abordagem pixel a pixel *versus* orientada a objeto, os resultados do SVM foram perceptivelmente melhores, alcançando o maior *score* F1 do estudo (0,91). Nesse contexto, 100% dos garimpos sem plumas de sedimentos foram detectados, bem como grande parte dos garimpos em operação. As omissões ocorreram porque não foi possível identificar o ponto de origem da pluma na embarcação. Portanto, a metodologia se mostrou eficaz para identificar garimpos de ouro embarcados a partir de classificadores do tipo *machine learning* utilizando imagens Sentinel-2.

A performance dos classificadores é influenciada por diversos fatores, como, as características dos alvos e quantidade e qualidade das amostras de treinamento. Logo, a escolha do classificador depende dos objetivos buscados uma vez que um método que obteve desempenho satisfatório pode ter resultados alterados sensivelmente quando aplicado a outro contexto. A limitada quantidade de pixels de treinamentos para as classes embarcações e garimpos e a similaridade espectral de determinados alvos é um ponto sensível à metodologia empregada.

REFERÊNCIAS

- ADAMY, A. Dinâmica fluvial do Rio Madeira. In: **SILVA, R.G.C. (org.). Porto Velho: cultura, natureza e território.** p. 120–147, 2016.
- 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>
- ARCGIS PRO. Segmentation. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/segmentation.htm>. Acesso em: 15 abr. 2023.
- 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. <https://doi.org/10.1016/j.jclepro.2015.05.012>
- BARBOSA, C. C. F. **Sensoriamento Remoto da Dinâmica da Circulação da Água do Sistema Planície de Curuai/Rio Amazonas.** 2005. São José dos Campos (SP). 281 p. (Tese de Doutorado, Instituto Nacional de Pesquisas Espaciais).
- BARBOSA, C. C. F.; NOVO, E. M. L. M.; MARTINS, V. S. **Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: Princípios e Aplicações.** São José dos Campos. Instituto Nacional de Pesquisas

- Espaciais. 2019.
- BARBOSA, F. L. R.; GUIMARÃES, R.F.; CARVALO JÚNIOR, O.A.; GOMES, R.A.T. Classificação do uso e cobertura da terra utilizando imagens SAR/Sentinel 1 no Distrito Federal. **Sociedade & Natureza**, v. 32, p. e55954, 2 fev. 2021. <https://doi.org/10.14393/SN-v33-2021-55954>
- 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>
- 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: 02 ago. 2022.
- BRASIL. Catálogo de Metadados. 2022. Disponível em: <https://metadados.snirh.gov.br/geonetwork/srv/p/or/catalog/search#/metadata/7d054e5a-8cc9-403c-9f1a-085fd933610c>. Acesso em: 04 set. 2022.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. <https://doi.org/10.1023/A:1010933404324>
- 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, n. February, p. 82–97, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.02.014>
- CETEM. **Inventário Nacional de Emissões e Liberações de Mercúrio pelos Garimpos de Ouro**. 2018. Disponível em: <https://diretoriopre.mma.gov.br>. Acesso em: 29 jul. 2022.
- CIOCARAN, A.; STOIAN, A. Ship detection in sentinel 2 multi-spectral images with self-supervised learning. **Remote Sensing**, v. 13, n. 21, 1 nov. 2021. <https://doi.org/10.3390/rs13214255>
- COMANICIU, D.; MEER, P. Mean shift: A robust approach toward feature space analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 5, p. 603–619, 2002. <https://doi.org/10.1109/34.1000236>
- 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. **Sentinel-2 User Handbook**. 2015. Disponível em: https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook.pdf/8869acdf-fd84-43ec-ae8c-3e80a436a16c?t=1438278087000. Accessed on: 03 ago. 2022.
- ESPINOZA VILLAR, R.; MARTINEZ, J.M.; TEXIER, M.; GUYOT, J.L.; FRAIZY, P.; MENESES, P.R.; OLIVEIRA, E. A study of sediment transport in the Madeira River, Brazil, using MODIS remote-sensing images. **Journal of South American Earth Sciences**, v. 44, p. 45–54, 2013. <https://doi.org/10.1016/j.jsames.2012.11.006>
- FERNANDES, F. R. C.; ALAMINO, R. C. J.; ARAUJO, E. Recursos minerais e comunidade: impactos humanos, socioambientais e econômicos. Rio de Janeiro. CETEM. 2014.
- FIX, E; HODGES; J. L. JR. Discriminatory analysis, nonparametric discrimination. **USAF School of Aviation Medicine**, Randolph Field, Tex., Project 21-49-004, Rept. 4, AF41(128)-31, February 1951.
- GOODIN, D. G.; HAN, L.; FRASER, R.N.; RUNDQUIST, D.C.; STEBBINS, W.A.; SCHALLES, J.F. Analysis of suspended solids in water using remotely sensed high resolution derivative spectra. **Photogrammetric Engineering & Remote Sensing**, v. 54, n. 4, p. 505–510, 1993.
- HARTONI, H.; SIREGAR, V.P.; WOUTHUYZEN, S.; AGUS, S.B. Object based classification of benthic habitat using Sentinel 2 imagery by applying with support vector machine and random forest algorithms in shallow waters of Kepulauan Seribu, Indonesia. **Biodiversitas**, v. 23, n. 1, p. 514–520, 1 jan. 2022. <https://doi.org/10.13057/biodiv/d230155>
- HEISELBERG, H. A direct and fast methodology for ship recognition in sentinel-2 multispectral imagery. **Remote Sensing**, v. 8, n. 12, 1 dez. 2016. <https://doi.org/10.3390/rs8121033>
- HEISELBERG, P.; HEISELBERG, H. Ship-iceberg discrimination in Sentinel-2 multispectral imagery by supervised classification. **Remote Sensing**, v. 9, n. 11, 1 nov. 2017. <https://doi.org/10.3390/rs9111156>
- 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 sep. 2017. <https://doi.org/10.3390/rs9090945>
- KANJIR, U. Detecting migrant vessels in the Mediterranean Sea: Using Sentinel-2 images to aid humanitarian actions. **Acta Astronautica**, v. 155, p. 45–50, 1 fev. 2019. <https://doi.org/10.1016/j.actaastro.2018.11.012>
- KESHTKAR, H.; VOIGT, W.; ALIZADEH, E. Land-cover classification and analysis of change using machine-learning classifiers and multi-temporal remote sensing imagery. **Arabian Journal of Geosciences**, v. 10, n. 6, 1 mar. 2017. <https://doi.org/10.1007/s12517-017-2899-y>
- KIKAKI, K.; KAKOGEORGIOU, I.; MIKELI, P.; RAITOS, D.; KARANTZALOS, K. MARIDA: A benchmark for Marine Debris detection from Sentinel-2 remote sensing data. **PLoS ONE**, v.

- 17, n. 1 January, 1 jan. 2022. <https://doi.org/10.1371/journal.pone.0262247>
- KRUSE, F. A.; LEFKOFF, A.B.; BOARDMAN, J.B.; HEIDEBRECHT, K.B.; SHAPIRO, A.T.; BARLOON, P.J.; GOETZ, A.F.H. The Spectral Image Processing System (SIPS) - Interactive Visualization and Analysis of Imaging spectrometer Data. **Remote Sensing of Environment**, v. 44, p. 145–163, 1993. [https://doi.org/10.1016/0034-4257\(93\)90013-N](https://doi.org/10.1016/0034-4257(93)90013-N)
- LODI, L. A.; FRANZINI, M.; CASELLA, V. Mapping Land Cover Types using Sentinel-2 Imagery: A Case Study. In: **GISTAM**. 2019. p. 242-249.
- LOBO, F. de L.; NOVO, E.M.L.M.; BARBOSA, C.C.F.; GALVÃO, L.S. Reference spectra to classify Amazon water types. **International Journal of Remote Sensing**, v. 33, n. 11, p. 3422–3442, 2012. <https://doi.org/10.1080/01431161.2011.627391>
- 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>
- LOUIS, J.; DEBAECKER, V.; PLUG, B.; MAINKORN, M.; BIENIARZ, J.; MUELLER-WILM, U. CADAU, E.; GASCON, F. SENTINEL-2 SEN2COR: L2A PROCESSOR FOR USERS. **Proceeding living planet symposium**, p. 1–8, 2016.
- 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, 1 nov. 2018. <https://doi.org/10.1016/j.isprsjprs.2018.05.013>
- NOI, P. T.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors (Basel, Switzerland)**, v. 18, n. 1, 22 dez. 2017. <https://doi.org/10.3390/s18010018>
- REDEMAIS/MJSP; © 2020 PLANET. PROGAMA BRASIL MAIS, 2020. Disponível em: <https://plataforma-pf.scon.com.br>. Acesso em: 22 jun. 2022.
- RODRIGUEZ, D. A.; LOPES, L.G.; CARIELLO, F.; LÁZARO, J. JÚNIOR, S.; PINTO, G.L. 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/rbcv69n4-44337>
- SALGADO, C. B.; CARVALHO JÚNIOR, O.A.; GOMES, R.A.T.; GUIMARÃES, R.F. Análise da interferência de nuvens na classificação de séries temporais MODIS-NDVI na região da Amazônia, município de Capixaba, Acre. **Sociedade & Natureza**, v. 31, p. 1–20, 2019. <https://doi.org/10.14393/SN-v31-2019-47062>
- SIGMINE. **Sistema de Informações Geográficas da Mineração**. 2022. Disponível em: <https://geo.anm.gov.br>. Acesso em: 17 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, 2021. <https://doi.org/10.1016/j.rsase.2021.100633>
- TRINDADE, R. B. E.; BARBOSA FILHO, O. **Extração de ouro - princípios, tecnologia e meio ambiente**. CETEM/MCT & PUC-RJ, 2002.
- VANTREPOTTE, V.; LOISEL, H.; DESSAILLY, H.; MÉRIAUX, X. Optical classification of contrasted coastal waters. **Remote Sensing of Environment**, v. 123, p. 306–323, ago. 2012. <https://doi.org/10.1016/j.rse.2012.03.004>
- VAPNIK, V. N. **The nature of Statistical learning theory**. New York. Springer-Verlag. 1995. <https://doi.org/10.1007/978-1-4757-2440-0>

CONTRIBUIÇÃO DOS AUTORES

Diego Henrique Costa Pereira concebeu o estudo, coletou, processou e analisou as informações e redigiu o texto. Roberto Arnaldo Trancoso Gomes auxiliou na concepção do estudo, orientou o trabalho desde as etapas iniciais, bem como auxiliou na análise das informações e redação do texto. Osmar Abílio de Carvalho Júnior auxiliou na análise das informações e na redação do texto. Renato Fontes Guimarães auxiliou na análise das informações e na redação do texto.

