

## TÉCNICAS DE CLASSIFICAÇÃO DE SEDIMENTOS DO FUNDO MARINHO POR IMAGENS DE SATÉLITE: UMA REVISÃO SISTEMÁTICA DE LITERATURA

## TECHNIQUES FOR CLASSIFYING SEABED SEDIMENTS USING SATELLITE IMAGES: A SYSTEMATIC REVIEW OF THE LITERATURE

## TÉCNICAS PARA CLASIFICAR SEDIMENTOS DEL FONDO MARINO UTILIZANDO IMÁGENES SATELITALES: UNA REVISIÓN SISTEMÁTICA DE LA LITERATURA

**Diego de Oliveira Dantas**

Doutorando, Universidade Federal do Maranhão, Brasil

E-mail: [diego.dantas@discente.ufma.br](mailto:diego.dantas@discente.ufma.br)

**Jailly Aparecida do Rosario Silva**

Graduanda, Universidade do Estado do Pará, Brasil

E-mail: [jailly.adr.silva@aluno.uepa.br](mailto:jailly.adr.silva@aluno.uepa.br)

**Marta de Oliveira Barreiros**

Doutora, Universidade do Estado do Pará, Brasil

E-mail: [marta.do.barreiros@uepa.br](mailto:marta.do.barreiros@uepa.br)

**Jonathan Araujo Queiroz**

Doutor, Universidade Federal do Maranhão, Brasil

E-mail: [queirozjth@gmail.com](mailto:queirozjth@gmail.com)

**Allan Kardec Duailibe Barros Filho**

Doutor, Universidade Federal do Maranhão, Brasil

E-mail: [allan.kardec@ufma.br](mailto:allan.kardec@ufma.br)

### Resumo

Esta revisão sistemática de literatura tem como objetivo analisar as principais técnicas de classificação de sedimentos do fundo marinho a partir de imagens de satélite. A pesquisa foi conduzida nas bases IEEE Xplore, Scielo, PubMed e Google Acadêmico, abrangendo publicações entre 2015 e 2025. Os resultados evidenciam avanços significativos nas metodologias de sensoriamento remoto marinho, com destaque para a integração de sensores ópticos e altimétricos (Sentinel-2, Landsat 8 e ICESat-2) e para o uso combinado de modelos empíricos, regressões

espectrais e algoritmos supervisionados como Random Forest, SVM e redes neurais convolucionais (CNNs). Embora predominem estudos voltados à batimetria, observou-se um crescimento gradual nas pesquisas dedicadas à classificação sedimentar óptica. As abordagens baseadas em aprendizado profundo mostraram-se promissoras, embora seu desempenho ainda seja limitado pela turbidez da água e pela escassez de dados rotulados. Conclui-se que a fusão multissensorial, associada à integração entre modelos empíricos e técnicas de aprendizado profundo, representa a principal tendência futura para aprimorar a acurácia, reduzir a dependência de levantamentos in situ e expandir o uso do sensoriamento remoto no monitoramento e gestão ambiental das zonas costeiras.

**Palavras-chave:** sensoriamento remoto; sedimentos marinhos; aprendizado de máquina; imagens de satélite.

## Abstract

This systematic literature review aims to analyze the main techniques for classifying seabed sediments from satellite imagery. The research was conducted in the IEEE Xplore, SciELO, PubMed, and Google Scholar databases, encompassing publications between 2015 and 2025. The results highlight significant advances in marine remote sensing methodologies, particularly the integration of optical and altimetric sensors (Sentinel-2, Landsat 8, and ICESat-2) and the combined use of empirical models, spectral regressions, and supervised algorithms such as Random Forest, SVM, and convolutional neural networks (CNNs). Although studies focused on bathymetry predominate, a gradual increase in research dedicated to optical sediment classification was observed. Deep learning-based approaches showed promise, although their performance is still limited by water turbidity and the scarcity of labeled data. It is concluded that multisensory fusion, associated with the integration between empirical models and deep learning techniques, represents the main future trend for improving accuracy, reducing dependence on in situ surveys, and expanding the use of remote sensing in the environmental monitoring and management of coastal zones.

**Keywords:** remote sensing; marine sediments; machine learning; satellite imagery.

## Resumen

Esta revisión sistemática de la literatura tiene como objetivo analizar las principales técnicas para clasificar sedimentos del fondo marino a partir de imágenes satelitales. La investigación se realizó en las bases de datos IEEE Xplore, SciELO, PubMed y Google Scholar, abarcando publicaciones entre

2015 y 2025. Los resultados destacan avances significativos en metodologías de teledetección marina, particularmente la integración de sensores ópticos y altimétricos (Sentinel-2, Landsat 8 e ICESat-2) y el uso combinado de modelos empíricos, regresiones espectrales y algoritmos supervisados como Random Forest, SVM y redes neuronales convolucionales (CNN). Si bien predominan los estudios centrados en batimetría, se observó un aumento gradual en la investigación dedicada a la clasificación óptica de sedimentos. Los enfoques basados en aprendizaje profundo mostraron ser prometedores, aunque su rendimiento aún está limitado por la turbidez del agua y la escasez de datos etiquetados. Se concluye que la fusión multisensorial, asociada a la integración entre modelos empíricos y técnicas de aprendizaje profundo, representa la principal tendencia futura para mejorar la precisión, reducir la dependencia de los estudios in situ y expandir el uso de la teledetección en el monitoreo y gestión ambiental de las zonas costeras.

**Palabras clave:** teledetección; sedimentos marinos; aprendizaje automático; imágenes satelitales.

## 1. Introdução

O estudo e o mapeamento dos sedimentos do fundo marinho são fundamentais para compreender a dinâmica dos ecossistemas costeiros, a morfologia submarina e os processos sedimentares que influenciam diretamente a estabilidade ambiental e econômica das regiões costeiras (Inácio et al. 2024). A caracterização dos sedimentos permite identificar áreas sujeitas à erosão, deposição e contaminação, contribuindo para a gestão ambiental, o planejamento costeiro e a conservação da biodiversidade bentônica (Oliveira, 2017). Além disso, a distribuição sedimentar influencia a composição de comunidades biológicas epibentônicas, que dependem do tipo de substrato para sua fixação e desenvolvimento, tornando-se um importante indicador da qualidade ambiental da região (Carrerette et al., 2022).

Tradicionalmente, o mapeamento dos sedimentos marinhos tem sido realizado por métodos diretos, como dragagens, amostragens por mergulho e análises laboratoriais granulométricas (Hilgert et al, 2024). Embora precisas, essas abordagens apresentam elevado custo, baixa cobertura espacial e alta demanda de

tempo, sendo inviáveis para grandes extensões de área (Oliveira, 2017; Lopes, 2024). Essas limitações impulsionaram pesquisadores a buscarem por técnicas indiretas e automatizadas, capazes de gerar informações espaciais contínuas com menor esforço de campo e maior eficiência operacional (Innangi, et al. 2022).

Nesse contexto, o sensoriamento remoto surgiu como uma alternativa promissora para a caracterização do fundo marinho. Sensores multiespectrais e hiperespectrais embarcados em satélites como Landsat, Sentinel-2 e WorldView têm sido amplamente utilizados para inferir propriedades do fundo a partir da assinatura espectral modulada pela água (Viña-Borja et al., 2023). A reflectância registrada permite estimar diferenças relacionadas à granulometria, composição e cobertura bentônica. Contudo, fatores como profundidade, turbidez, absorção da água e variabilidade angular da luz solar tornam o processo de classificação espectral complexo e sujeito a incertezas (Wei et al., 2024). Essas limitações demandaram o desenvolvimento de métodos mais robustos, capazes de lidar com ruídos e relações não lineares nos dados espectrais.

Antes da popularização das técnicas de aprendizado de máquina, a classificação de sedimentos do fundo marinho era amplamente baseada em modelos empíricos e estatísticos, que exploravam as relações espectrais entre a refletância das bandas ópticas e parâmetros físicos do ambiente (Li et al., 2023; Chen et al., 2023). Entre os métodos mais utilizados destacam-se os modelos de regressão linear, o método de razão de bandas (band ratio) e as análises multivariadas aplicadas à reflectância derivada de satélites como Landsat e Sentinel-2 (Neto, 2017). Essas abordagens, embora simples e de fácil implementação, apresentavam limitações em ambientes de alta turbidez e profundidade variável, devido à natureza linear das suas equações e à dificuldade de representar a complexa interação entre luz, coluna d'água e substrato (Kutser et al., 2020; Wei et al., 2024). Ainda assim,

tais modelos foram fundamentais para consolidar as bases conceituais da batimetria óptica e da classificação espectral de sedimentos, servindo como ponto de partida para o desenvolvimento das técnicas supervisionadas e dos algoritmos de aprendizado mais recentes.

O avanço das técnicas de aprendizado de máquina (Machine Learning) e do aprendizado profundo (Deep Learning) revolucionou as análises de dados ambientais. Algoritmos como Random Forest (RF), Support Vector Machine (SVM), Extreme Gradient Boosting (XGBoost) e Redes Neurais Convolucionais (CNNs) têm sido amplamente empregados na classificação automática de sedimentos, utilizando imagens de satélite multiespectrais e batimétricas como principal fonte de dados, apresentando resultados superiores aos métodos estatísticos convencionais (Zhang et al., 2023; Kim et al., 2024). Essas técnicas aprendem padrões complexos e não lineares entre as variáveis espectrais, o que melhora significativamente a acurácia das classificações e reduz o impacto de interferências ópticas.

Paralelamente, dados acústicos — especialmente provenientes de sonares multifeixe e backscatter — ganharam destaque como fonte complementar para a caracterização sedimentar. Menandro et al. (2023), por exemplo, aplicou classificadores SVM a dados de retroespalhamento acústico multifeixe para discriminar rodolitos e sedimentos mistos com alta acurácia, evidenciando o potencial da integração entre dados acústicos, ópticos e altimétricos. Além disso, a incorporação da batimetria óptica tem ampliado a capacidade de classificação, ao fornecer informações sobre profundidade e relevo que auxiliam na identificação de padrões espaciais e subsidiam modelos supervisionados mais precisos.

As metodologias contemporâneas tendem a combinar múltiplas fontes de dados, ópticas, batimétricas e acústicas, associadas a modelos supervisionados e arquiteturas profundas, como U-Net e DenseNet, com foco na detecção espacial de

padrões (Zhao, 2023). Ainda assim, permanecem lacunas importantes quanto ao desempenho relativo dessas técnicas em diferentes condições ambientais, especialmente em regiões tropicais e costeiras com maior heterogeneidade óptica e influência antrópica, como o litoral brasileiro (Zhang et al., 2023; Kim et al., 2024; Lopes, 2024).

Diante do exposto, este artigo tem como objetivo revisar e discutir as principais técnicas aplicadas à classificação de sedimentos do fundo marinho a partir de imagens de satélite, destacando a evolução das metodologias, as limitações dos modelos tradicionais e as contribuições das técnicas computacionais, incluindo métodos empíricos, estatísticos e de aprendizado de máquina, para o aprimoramento do sensoriamento remoto marinho. Ao reunir estudos recentes e comparar seus resultados, busca-se identificar tendências, desafios e perspectivas futuras para o mapeamento automatizado do fundo oceânico.

## 2. Metodologia

Esta seção descreve os procedimentos metodológicos adotados para a condução da revisão sistemática de literatura e a seleção dos estudos analisados. O objetivo é garantir uma análise criteriosa e atualizada das técnicas de classificação de sedimentos do fundo marinho por meio de imagens de satélite.

### 2.1 Tipo de Estudo

O presente trabalho caracteriza-se como uma revisão sistemática de literatura de natureza descritiva e exploratória, voltada para identificar, analisar e discutir as principais técnicas aplicadas à classificação espectral de sedimentos marinhos por meio de imagens de satélite. A pesquisa abrange estudos empíricos e teóricos publicados em periódicos científicos e conferências internacionais das áreas de Sensoriamento Remoto, Oceanografia e Ciência da Computação.

## 2.2 Estratégia de Busca

A busca bibliográfica foi conduzida nas principais bases de dados científicas, IEEE Xplore, PubMed, Scielo e Google Acadêmico. Foram utilizados descritores em português e inglês para ampliar o escopo da pesquisa, incluindo termos como “classificação” “máquinas de aprendizado” “técnicas de sedimento” “fundo marinho” “imagens de satélite” e seus correspondentes em inglês “classification” “learning machines” “sediment techniques” “seafloor” “satellite imagery”. As combinações de palavras-chave foram estruturadas por meio do operador booleano “AND” (E) para maximizar a relevância e a precisão dos resultados, desenvolvendo strings principais e variações complementares.

String principal em português: ("classificação de sedimentos" OR "sedimentos marinhos" OR "substrato marinho" OR "fundo marinho") AND ("imagens de satélite" OR "imagens multiespectrais" OR "sensoriamento remoto óptico" OR "Sentinel-2" OR "Landsat") AND ("aprendizado de máquina" OR "classificação supervisionada" OR "Random Forest" OR "SVM" OR "rede neural convolucional" OR "aprendizado profundo")

String principal em inglês: ("sediment classification" OR "seafloor sediment" OR "marine sediment") AND ("satellite imagery" OR "multispectral images" OR "Sentinel-2" OR "Landsat") AND ("machine learning" OR "supervised classification" OR "random forest" OR "SVM" OR "convolutional neural network" OR "deep learning")

Foram realizadas variações estruturais dessas combinações, incluindo versões mais amplas (com termos genéricos como "sediment") e versões mais específicas (focadas em algoritmos ou sensores específicos), a fim de evitar perdas de estudos relevantes.

## 2.3 Critérios de Inclusão e Exclusão

Foram incluídos na revisão artigos científicos, capítulos de livros, revisões sistemáticas e revisões narrativas que abordassem a classificação de sedimentos utilizando imagens de satélite e técnicas computacionais de modelagem, incluindo métodos empíricos, estatísticos e de aprendizado de máquina, publicados entre 2015 e 2025, em língua inglesa ou portuguesa, e disponíveis em texto completo.

Excluíram-se trabalhos duplicados, revisões narrativas sem metodologia explícita, estudos sem relação direta com classificação de substratos marinhos e publicações que não apresentavam aplicação de métodos computacionais de classificação.

## 2.4 Análise dos Artigos

O processo de seleção envolveu três etapas: (1) leitura dos títulos e resumos para triagem inicial; (2) leitura integral dos estudos pré-selecionados; e (3) verificação final da adequação aos critérios definidos.

Os artigos incluídos foram organizados e analisados comparativamente, considerando aspectos como:

- O tipo de dado utilizado (imagens ópticas, multiespectrais ou hiperespectrais);
- O satélite ou sensor empregado (ex.: Sentinel-2, Landsat-8/9, WorldView, PlanetScope);
- A técnica de classificação aplicada, incluindo métodos empíricos, estatísticos e de aprendizado de máquina (por exemplo, regressão linear, band ratio, Random Forest, SVM, CNN, U-Net, entre outros);
- As métricas de desempenho (acurácia, índice Kappa, F1-score);
- E as principais limitações e contribuições relatadas.

A partir dessa análise comparativa, buscou-se identificar tendências metodológicas, lacunas de pesquisa e avanços tecnológicos nas diferentes

abordagens de classificação sedimentar por imagens de satélite, consolidando uma visão crítica e atual sobre o tema.

## 2.5 Avaliação Qualitativa de Risco de Viés

A avaliação qualitativa de risco de viés foi conduzida considerando quatro dimensões metodológicas: (i) robustez da validação estatística, (ii) dependência de amostras de campo limitadas, (iii) generalização espacial dos modelos e (iv) controle de variáveis ambientais, como profundidade e turbidez da coluna d'água.

Observou-se que estudos baseados exclusivamente em áreas específicas podem apresentar risco moderado de viés espacial, enquanto abordagens multissensoriais tendem a reduzir limitações associadas à variabilidade ambiental.

**Quadro 1.** Quadro da Avaliação Qualitativa dos Riscos de Viés dos estudos selecionados

Estudo	Validação	Generalização	Risco de Viés
<b>Hedley et al. (2018)</b>	Dados in situ	Média	Baixo
<b>Poursanidis et al. (2019)</b>	campo + batimetria	Média	Moderado
<b>Li et al. (2023)</b>	ICESat-2 robusto	Alta	Baixo
<b>Neto (2017)</b>	Campo local	Baixa	Moderado
<b>Van An et al., (2023)</b>	Campo + ML	Média	Baixo

Fonte: Autoria Própria, 2026

## 2.6 Processo de Seleção (PRISMA)

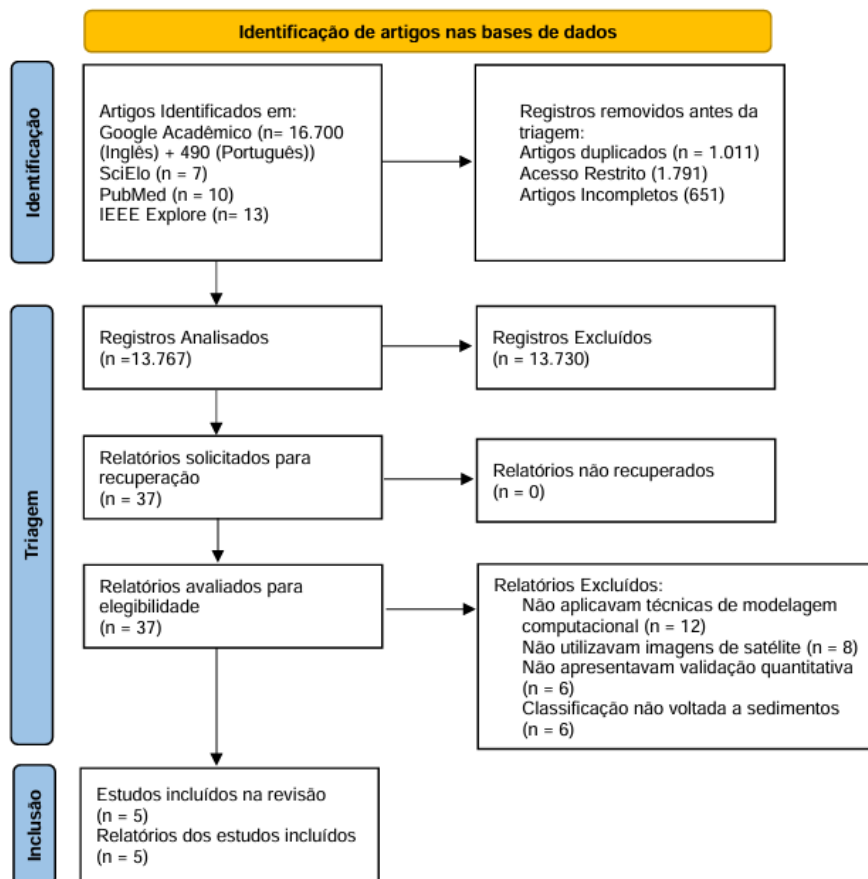
O processo de identificação, triagem e seleção dos artigos foi conduzido conforme o protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses).

A busca inicial resultou em 17.220 estudos identificados nas bases IEEE Xplore, Scielo, PubMed e Google Acadêmico. Após a remoção de duplicatas e exclusão automática de registros claramente irrelevantes por filtros de idioma e período, permaneceram 13.767 estudos para triagem inicial.

Na etapa de triagem por título e resumo, 13.730 estudos foram excluídos por não abordarem diretamente classificação sedimentar por imagens de satélite, resultando em 37 artigos para leitura integral.

Após a leitura completa e aplicação rigorosa dos critérios de elegibilidade, 32 estudos foram excluídos por tratarem predominantemente de batimetria isolada, mapeamento de habitats bentônicos sem classificação sedimentar ou uso exclusivo de dados acústicos. Assim, 5 estudos atenderam integralmente aos critérios definidos e foram incluídos na síntese qualitativa final (Figura 1).

**Imagem 1.** Fluxograma do processo de seleção dos estudos



**Fonte:** Autoria Própria, 2025

### 3. Resultados

Após a aplicação dos critérios de elegibilidade definidos na metodologia, 5 estudos foram selecionados por atenderem aos objetivos desta revisão sistemática. A Tabela 1 apresenta uma síntese comparativa dos trabalhos incluídos, destacando o problema central abordado, as soluções tecnológicas propostas, os algoritmos de aprendizado empregados, as metodologias de validação e as principais métricas e resultados obtidos.

**Tabela 1.** Síntese dos artigos de solução tecnológica selecionados para a revisão

Artigo (Autor, Ano)	Problema Central Abordado	Proposta / Solução Tecnológica	Técnica Aplicada	Metodologia de Validação	Principais Métricas Utilizadas	Principais Resultados
<b>Hedley et al. (2018)</b>	Necessidade de aprimorar a discriminação espectral de diferentes tipos de fundo marinho, com foco na diferenciação de padrões sedimentares.	Comparação do desempenho do Sentinel-2 e Landsat-8 na classificação de substratos sedimentares e feições associadas.	Inversão física e Mapeamento Orientado a Objetos (OBIA).	Dados in situ e batimetria de referência (Lizard Island).	Resolução espacial e erro médio de profundidade.	Sentinel-2 (10m) apresentou melhor capacidade na delimitação de classes sedimentares, evidenciando maior sensibilidade espectral para texturas e variações granulométricas.
<b>Li et al. (2023)</b>	Dificuldade de obter batimetria e classificação de sedimentos em áreas costeiras remotas.	Combinação de ICESat-2 (LiDAR) e imagens Sentinel-2 / GeoEye-1 para gerar mapas	Regressão linear e band ratio model.	Uso de modelos empíricos (regressão linear e <i>band ratio</i> ); validação com	-R <sup>2</sup> (coeficiente de determinação) -RMSE (Root Mean Square)	Melhora de até 15,5% no RMSE ao incluir classificação de sedimentos (R <sup>2</sup> =0,97; RMSE=0,65)

		batimétricos com classificação de sedimentos (areia, recife, coral/alga, entulho).		dados ICESat-2.	Error) -MAE (Mean Absolute Error)	m).
<b>Neto (2017)</b>	Falta de mapeamento de sedimentos costeiros precisos; limitações de métodos acústicos isolados.	Integração de Landsat 8/Sentinel-2 e sonar com classificação supervisionada (Máx. Verossimilhança, Árvore de Decisão, K-means).	Máxima Verossimilhança (MLC), Árvore de Decisão (DT) e K-means.	Comparação com amostras sedimentares de campo; validação estatística (matriz de confusão).	-Acurácia global -índice Kappa	Acurácia >80% para classificação integrada; melhor desempenho com dados multissensoriais.
<b>Poursanidis et al. (2019)</b>	Limitações da coluna d'água na identificação de classes sedimentares maiores profundidades.	Aplicação da banda costeira (443 nm) do Sentinel-2 para melhorar a discriminação espectral de sedimentos submersos.	Random Forest (RF) e downscaling espectral.	Dados de campo e batimetria multifeixe de referência.	R <sup>2</sup> (Coeficiente de determinação) e Acurácia.	A banda de 443 nm aumentou significativamente a acurácia na diferenciação de classes sedimentares em áreas com profundidade superior a 15 m.
<b>Van An et al., (2023)</b>	Dificuldade de mapear habitats bentônicos em águas costeiras turvas com alta heterogeneidade.	Integração de PlanetScope (óptico) e ICESat-2 (altimetria) com aprendizado de máquina.	Random Forest (RF), Support Vector Machine (SVM) e Convolutional Neural Network.	Validação com dados de campo e batimetria derivada de ICESat-2.	-Acurácia global -índice Kappa.	CNN alcançou 89,8% de acurácia e Kappa = 0,87, superando RF e SVM; BRI

dade espectral.	para classificaçã o de sedimentos e habitats.	(CNN).			apresentou melhor desempenh o que DII.
--------------------	---	--------	--	--	---

Fonte: Aatoria Própria, 2025

#### 4. Discussão

A presente revisão sistemática de literatura, baseada em estudos publicados nos últimos anos, evidencia o avanço significativo das técnicas de sensoriamento remoto óptico e aprendizado de máquina aplicadas à classificação de sedimentos do fundo marinho, destacando o papel central das imagens de satélite multiespectrais como alternativa eficiente, de baixo custo e com ampla cobertura espacial em relação aos métodos acústicos tradicionais. Os trabalhos analisados revelam abordagens complementares que, em conjunto, delineiam uma evolução metodológica clara no mapeamento sedimentar costeiro.

O estudo de Hedley et al. (2018) representa um marco na consolidação do Sentinel-2 como ferramenta eficaz na discriminação de classes sedimentares. Ao comparar seu desempenho com o Landsat-8, os autores demonstraram que a resolução espacial de 10 m e a configuração espectral aprimorada do Sentinel-2 permitem maior precisão na delimitação de texturas e padrões sedimentares, evidenciando ganhos na diferenciação entre areia, rochas e substratos consolidados.

Complementarmente, Poursanidis et al. (2019) destacam a importância da banda costeira (443 nm) do Sentinel-2 na melhoria da classificação sedimentar em maiores profundidades. A utilização dessa banda reduziu interferências da coluna d'água e aumentou a capacidade de discriminação espectral, demonstrando que

ajustes específicos na seleção de bandas podem impactar diretamente a acurácia da classificação de sedimentos submersos.

No contexto da integração multissensorial, Li et al. (2023) avançaram ao combinar ICESat-2 com imagens Sentinel-2 e GeoEye-1, associando modelagem empírica à classificação sedimentar. A obtenção de  $R^2 = 0,97$  e redução de 15,5% no RMSE evidencia que a inclusão de variáveis sedimentares melhora significativamente a precisão batimétrica, reforçando a interdependência entre caracterização do substrato e estimativas de profundidade.

Em perspectiva histórica e metodológica, Neto (2017) já indicava essa integração entre sensores ao combinar imagens Landsat 8 e Sentinel-2 com dados acústicos de sonar, utilizando classificadores supervisionados clássicos — Máxima Verossimilhança, Árvore de Decisão e K-means. A validação por meio de matriz de confusão e índice Kappa, associada à comparação com amostras sedimentares de campo, resultou em acurácia global superior a 80%. Embora anterior à consolidação de redes neurais profundas, o estudo se destaca por demonstrar empiricamente que a integração multissensorial melhora o desempenho classificatório, antecipando a lógica adotada por pesquisas mais recentes que incorporam algoritmos mais sofisticados.

Van An et al. (2023) exemplifica a aplicação de aprendizado profundo em ambientes costeiros heterogêneos, combinando imagens PlanetScope de alta resolução com dados ICESat-2. A comparação entre Random Forest, SVM e CNN demonstrou que a rede convolucional alcançou 89,8% de acurácia e Kappa = 0,87, evidenciando o potencial da fusão multissensorial e da correção da coluna d'água na melhoria da classificação do fundo marinho. Este estudo ilustra como técnicas modernas podem se integrar a métodos tradicionais e empíricos, fortalecendo a complementaridade entre abordagens.

Além dos estudos incluídos na Tabela 1, pesquisas recentes contribuem para contextualizar o avanço metodológico da área. Chen et al. (2023) propuseram uma estratégia de aprendizado ativo baseada em grafos (GAP), voltada à otimização do processo de rotulagem supervisionada. Embora não componha o corpus principal desta revisão, o estudo evidencia uma tendência crescente de redução da dependência de grandes conjuntos de dados rotulados, aspecto relevante para classificações sedimentares baseadas em imagens ópticas em larga escala.

De forma semelhante, Viña-Borja et al. (2023) destacam a importância do pré-processamento radiométrico ao demonstrar que correções atmosféricas e remoção de sunglint impactam diretamente a precisão das estimativas batimétricas e da discriminação espectral. Embora também não integrem a síntese principal apresentada na Tabela 1, seus achados reforçam a necessidade de rigor no tratamento espectral para melhorar a acurácia da classificação de sedimentos submersos.

De forma transversal, observa-se que modelos baseados em aprendizado profundo, como o de Van An et al. (2023), apresentam maior acurácia global quando comparados a classificadores tradicionais empregados por Neto (2017), ainda que demandem maior volume de dados rotulados e maior capacidade computacional. Em termos de escalabilidade, o uso do Sentinel-2 demonstrado por Hedley et al. (2018) e Poursanidis et al. (2019) destaca-se pela ampla cobertura espacial e acesso gratuito, favorecendo aplicações em larga escala. Por outro lado, integrações com ICESat-2, como em Li et al. (2023), aumentam a precisão vertical, porém dependem da disponibilidade de dados altimétricos. Limitações ambientais, especialmente turbidez e profundidade superior a 15 m, permanecem desafios relevantes, parcialmente mitigados por ajustes espectrais específicos, como o uso da banda costeira de 443 nm.

Cabe ressaltar, entretanto, que a comparação direta entre os estudos é metodologicamente limitada pela heterogeneidade das métricas empregadas. Enquanto alguns trabalhos utilizam coeficiente de determinação ( $R^2$ ) e RMSE para avaliar desempenho batimétrico, outros adotam acurácia global e índice Kappa para classificação categórica. Essas métricas avaliam dimensões distintas do desempenho modelado — regressiva versus classificatória — o que impede comparações absolutas entre resultados. Além disso, estudos que empregam redes neurais convolucionais frequentemente trabalham com conjuntos de dados relativamente restritos, o que pode aumentar o risco de overfitting e reduzir a generalização espacial dos modelos. Dessa forma, ganhos percentuais de acurácia devem ser interpretados com cautela, especialmente em aplicações costeiras com alta variabilidade ambiental.

Em síntese, os estudos analisados demonstram que as técnicas de classificação de sedimentos do fundo marinho por imagens de satélite evoluíram significativamente nos últimos anos, tanto em termos de refinamento espectral quanto de sofisticação algorítmica. Desde a aplicação de classificadores supervisionados tradicionais, como apresentado por Neto (2017), até o uso otimizado das bandas multiespectrais do Sentinel-2 evidenciado por Hedley et al. (2018) e Poursanidis et al. (2019), observa-se um aprimoramento consistente na capacidade de discriminação sedimentar. Esse avanço é potencializado por estratégias mais recentes que incorporam aprendizado profundo e integração com dados altimétricos orbitais, como demonstrado por Li et al. (2023) e Van An et al. (2023), ampliando a precisão e a robustez dos modelos. Assim, a literatura converge para a consolidação das imagens de satélite como ferramenta central no mapeamento sedimentar costeiro, indicando que o futuro da área reside no desenvolvimento de modelos

híbridos, escaláveis e metodologicamente padronizados, capazes de equilibrar acurácia, custo e aplicabilidade em diferentes contextos ambientais.

## 5. Limitações da Revisão

Esta revisão identificou um número reduzido de estudos dedicados especificamente à classificação de sedimentos do fundo marinho a partir de imagens de satélite, indicando que o tema ainda se encontra em fase inicial de consolidação científica. A maioria das pesquisas concentra-se em aplicações correlatas, como batimetria derivada de satélite e mapeamento de habitats bentônicos, o que limita o avanço de modelos voltados exclusivamente à discriminação sedimentar.

Observou-se também, grande heterogeneidade metodológica entre os estudos, tanto na escolha dos sensores (Sentinel-2, Landsat, PlanetScope, ICESat-2) quanto nos algoritmos e métricas utilizadas, dificultando a comparação direta dos resultados. No caso das redes neurais convolucionais (CNNs), as aplicações ainda são incipientes devido às restrições impostas pela atenuação da luz na coluna d'água, pela turbidez e pela escassez de dados rotulados para treinamento supervisionado.

A ausência de bases padronizadas e protocolos consistentes de pré-processamento e calibração espectral compromete a reprodutibilidade dos resultados. Assim, há uma necessidade evidente de estudos colaborativos que unifiquem metodologias e explorem a fusão multissensorial entre dados ópticos, acústicos e LiDAR, ampliando a precisão e a aplicabilidade dos modelos de aprendizado de máquina no sensoriamento remoto marinho.

Por fim, outro aspecto a ser considerado refere-se ao número reduzido de estudos incluídos na síntese final ( $n = 5$ ). Embora a busca inicial tenha identificado um grande volume de registros (17.220), a aplicação de critérios rigorosos de

elegibilidade, especialmente a exigência de uso concomitante de imagens de satélite e técnicas computacionais de modelagem voltadas especificamente à classificação sedimentar, resultou na exclusão da maioria dos trabalhos, que tratavam predominantemente de batimetria derivada ou mapeamento de habitats bentônicos. Dessa forma, o quantitativo final reflete não uma escassez de publicações na área de sensoriamento remoto marinho, mas a especificidade temática adotada nesta revisão. Essa delimitação rigorosa, embora resulte em número reduzido de estudos, aumenta a especificidade analítica da revisão e reduz vieses de escopo, priorizando trabalhos que efetivamente utilizam imagens orbitais associadas a técnicas computacionais de classificação sedimentar.

## 6. Conclusão

A presente revisão sistemática de literatura evidenciou que o uso de imagens de satélite multiespectrais e hiperespectrais, aliado a técnicas empíricas, estatísticas e de aprendizado de máquina, constitui uma abordagem promissora para a classificação de sedimentos do fundo marinho. Os estudos analisados indicam avanços relevantes na integração entre sensores ópticos e altimétricos, como Sentinel-2, Landsat e ICESat-2, bem como na aplicação de algoritmos supervisionados e modelos empíricos que contribuem para o aprimoramento das estimativas batimétricas e sedimentares.

Apesar desses progressos, o número reduzido de estudos dedicados especificamente à classificação sedimentar por imagens de satélite evidencia a necessidade de maior aprofundamento teórico e metodológico. As principais limitações observadas relacionam-se à interferência da coluna d'água, à turbidez e à escassez de dados rotulados, fatores que ainda restringem a aplicação mais ampla de redes neurais convolucionais (CNNs) e de outras técnicas avançadas de

aprendizado profundo. Além disso, a ausência de padronização nos procedimentos de calibração, validação e avaliação de desempenho limita a reprodutibilidade e a comparação direta entre estudos.

Ainda assim, observa-se uma trajetória metodológica consistente, que parte de modelos empíricos lineares, baseados em relações espectrais simples, e avança para abordagens supervisionadas e, mais recentemente, para modelos híbridos e de aprendizado profundo. Essa evolução sugere uma tendência crescente de integração multissensorial entre dados ópticos, acústicos e LiDAR, com potencial para ampliar a acurácia e reduzir, de forma progressiva, a dependência de levantamentos in situ.

As tendências identificadas, especialmente a fusão multissensorial de dados ópticos, acústicos e LiDAR, associada ao uso de aprendizado profundo e aprendizado ativo, indicam possibilidades relevantes para aplicações em gestão costeira e monitoramento ambiental. A adoção dessas metodologias pode contribuir para decisões relacionadas à conservação de habitats bentônicos, planejamento de intervenções costeiras e avaliação de impactos ambientais, desde que acompanhada de protocolos metodológicos rigorosos e validação adequada.

Conclui-se, portanto, que as técnicas de classificação de sedimentos do fundo marinho por imagens de satélite demonstram viabilidade e potencial de aplicação, particularmente quando associadas à integração de múltiplos sensores e ao uso criterioso de algoritmos supervisionados. O aprimoramento contínuo dessas metodologias, aliado ao desenvolvimento de bases de dados padronizadas, poderá fortalecer progressivamente o papel do sensoriamento remoto como ferramenta de apoio ao monitoramento sedimentar e à gestão ambiental das zonas costeiras.

## Referências

CARRERETTE, O. et al. Macrobenthic assemblages across deep-sea pockmarks and carbonate mounds at Santos Basin, SW Atlantic. *Ocean and Coastal Research*, v. 70, p. e22045, 2022. DOI: <https://doi.org/10.1590/2675-2824070.22081oc>.

CHEN, B.; MILLER, K.; BERTOZZI, A. L.; SCHWENK, J. Graph-based active learning for surface water and sediment detection in multispectral imagery. In: *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2023. arXiv:2306.10440. DOI: <https://doi.org/10.48550/arXiv.2306.10440>.

HEDLEY, John D.; ROELFSEMA, Chris; BRANDO, Vittorio; GIARDINO, Claudia; KUTSER, Tiit; PHINN, Stuart; MUMBY, Peter J.; BARRILERO, Omar; LAPORTE, Jean; KOETZ, Benjamin. Coral reef applications of Sentinel-2: coverage, characteristics, bathymetry and benthic mapping with comparison to Landsat 8. *Remote Sensing of Environment*, v. 216, p. 598–614, Oct. 2018. DOI: <https://doi.org/10.1016/j.rse.2018.07.014>.

HILGERT, S.; SOTIRI, K.; FUCHS, S. Review of sediment detection methods in reservoirs. *International Journal of Sediment Research*, v. 39, n. 1, p. 28–43, 2024. DOI: <https://doi.org/10.1016/j.ijsrc.2023.12.004>.

INÁCIO, M. et al. Mapping and assessing marine ecosystem services supply in the Baltic Sea. *Science of the Total Environment*, v. 950, p. 175199, 2024. DOI: <https://doi.org/10.1016/j.scitotenv.2024.175199>.

INNANGI, S.; INNANGI, M.; DI FEBBRARO, M.; DI MARTINO, G.; SACCHI, M.; TONIELLI, R. Continuous, high-resolution mapping of coastal seafloor sediment distribution. *Remote Sensing*, v. 14, n. 5, p. 1268, 2022. DOI: <https://doi.org/10.3390/rs14051268>.

KIM, K.-L.; WOO, H.-J.; JOU, H.-T.; JUNG, H. C.; LEE, S.-K.; RYU, J.-H. Surface sediment classification using a deep learning model and unmanned aerial vehicle data of tidal flats. *Marine Pollution Bulletin*, v. 198, p. 115823, 2024. DOI: <https://doi.org/10.1016/j.marpolbul.2023.115823>.

KUTSER, T.; HEDLEY, J.; GIARDINO, C.; ROELFSEMA, C.; BRANDO, V. E. Remote sensing of shallow waters: a 50 year retrospective and future directions. *Remote Sensing of Environment*, v. 240, p. 111619, 2020. DOI: <https://doi.org/10.1016/j.rse.2019.111619>.

LI, S.; WANG, X. H.; MA, Y.; YANG, F. Satellite-derived bathymetry with sediment classification using ICESat-2 and multispectral imagery: case studies in the South China Sea and Australia. *Remote Sensing*, v. 15, n. 4, p. 1026, 2023. DOI: <https://doi.org/10.3390/rs15041026>.

LOPES, [iniciais do nome]. Classificação de sedimentos da margem equatorial brasileira utilizando algoritmos. 2024. 67 f. Dissertação (Mestrado em Engenharia de Eletricidade) – Universidade Federal do Maranhão, São Luís, 2024. Disponível em: <https://tedebc.ufma.br/jspui/handle/tede/5313>. Acesso em: 9 out. 2025.

MENANDRO, P. S. et al. Multispectral multibeam backscatter response of heterogeneous rhodolith beds. *Scientific Reports*, v. 13, p. 20220, 2023. DOI: <https://doi.org/10.1038/s41598-023-46240-7>.

NETO, J. C. Geodiversidade da plataforma continental de Icapuí, Ceará: uma proposta de identificação de áreas chave em ambientes marinhos. 2017. 125 f. Tese (Doutorado em Geologia) – Universidade Federal do Ceará, Fortaleza, 2017. Disponível em: <http://repositorio.ufc.br/handle/riufc/29898>. Acesso em: 8 out. 2025.

OLIVEIRA, R. G. Mapeamento de habitats marinhos epibentônicos da porção nordeste da Baía de Todos os Santos – Bahia – Brasil. 2017. Dissertação (Mestrado em Geologia) – Universidade Federal da Bahia, Salvador, 2017. Disponível em: <https://repositorio.ufba.br/handle/ri/23634>. Acesso em: 8 out. 2025.

POURSANIDIS, Dimitris; TRAGANOS, Dimosthenis; REINARTZ, Peter; CHRYSOULAKIS, Nektarios. On the use of Sentinel-2 for coastal habitat mapping and satellite-derived bathymetry estimation using downscaled coastal aerosol band. *International Journal of Applied Earth Observation and Geoinformation*, v. 80, p. 58–70, Aug. 2019. DOI: <https://doi.org/10.1016/j.jag.2019.03.012>

VIÑA-BORJA, S. P.; FERNÁNDEZ-MORA, A.; STUMPF, R. P.; NAVARRO, G.; CABALLERO, I. Semi-automated bathymetry using Sentinel-2 for coastal monitoring in the Western Mediterranean. *International Journal of Applied Earth Observation and Geoinformation*, v. 120, p. 103328, 2023. DOI: <https://doi.org/10.1016/j.jag.2023.103328>.

VAN AN, N.; QUANG, N. H.; HOANG FILHO, T. P.; AN, T. T. Mapeamento de habitat bentônico de alta resolução a partir de aprendizado de máquina em imagens PlanetScope e dados ICESat-2. *Journal of Applied Remote Sensing*, 2023. DOI: <https://doi.org/10.1080/10106049.2023.2184875>.

WEI, C.; XIAO, Y.; FU, D.; ZHOU, T. Impact of turbidity on satellite-derived bathymetry: comparative analysis across seven ports in the South China Sea. *Remote Sensing*, v. 16, n. 23, p. 4349, 2024. DOI: <https://doi.org/10.3390/rs16234349>.

ZHAO, Y.; ZHU, K.; ZHAO, T.; ZHENG, L.; DENG, X. Small-sample seabed sediment classification based on deep learning. *Remote Sensing*, v. 15, n. 8, p. 2178, 2023. DOI: <https://doi.org/10.3390/rs15082178>.

ZHANG, N.; LI, H.; ZHANG, J.; CHEN, J.; WU, H.; GONG, Z. Study of the spatial and temporal distributions of tidal flat surface sediment based on multitemporal remote sensing. *Frontiers in Marine Science*, v. 10, p. 1109146, 2023. DOI: <https://doi.org/10.3389/fmars.2023.1109146>.