

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DIEGO DE OLIVEIRA DANTAS

**MAPEAMENTO DE SEDIMENTOS DA MARGEM
EQUATORIAL BRASILEIRA USANDO ALGORITMOS DE
APRENDIZADO DE MÁQUINA**

São Luís - MA

2026

DIEGO DE OLIVEIRA DANTAS

**MAPEAMENTO DE SEDIMENTOS DA MARGEM
EQUATORIAL BRASILEIRA USANDO ALGORITMOS DE
APRENDIZADO DE MÁQUINA**

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Doutor em Engenharia Elétrica.

Orientador: Prof. Dr. Allan Kardec Duailibe Barros Filho

São Luís - MA

2026

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

de Oliveira Dantas, Diego.

MAPEAMENTO DE SEDIMENTOS DA MARGEM EQUATORIAL
BRASILEIRA USANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA /
Diego de Oliveira Dantas. - 2026.
95 f.

Orientador(a): Allan Kardec Duailibe Barros Filho.
Tese (Doutorado) - Programa de Pós-graduação em
Engenharia Elétrica/ccet, Universidade Federal do
Maranhão, São Luis, 2026.

1. Sedimentos Marinhos. 2. Aprendizado de Máquina. 3.
Margem Equatorial Brasileira. 4. Sensoriamento Remoto. I.
Duailibe Barros Filho, Allan Kardec. II. Título.

DIEGO DE OLIVEIRA DANTAS

**MAPEAMENTO DE SEDIMENTOS DA MARGEM
EQUATORIAL BRASILEIRA USANDO ALGORITMOS DE
APRENDIZADO DE MÁQUINA**

Tese submetida ao Programa de Pós-Graduação em
Engenharia Elétrica da Universidade Federal do Ma-
ranhão, como parte dos requisitos necessários para
obtenção do grau de Doutor em Engenharia Elétrica.

Aprovado em:

BANCA EXAMINADORA

Prof. Dr. Allan Kardec Duailibe Barros Filho (Orientador)
Membro da Banca Examinadora (UFMA)

Prof. Dr. Ewaldo Éder Santana
Membro da Banca Examinadora (UFMA)

Prof. Dr. Antonio Fernando Lavareda Jacob Junior
Membro da Banca Examinadora (UFMA)

Prof. Dra. Marta de Oliveira Barreiros
Membro da Banca Examinadora (UEPA)

Prof. Dr. Jonathan Araujo Queiroz
Membro da Banca Examinadora (CEUMA)

Este trabalho é dedicado aos meus pais e irmãos.

AGRADECIMENTOS

Agradeço a Deus pela vida.

Aos meus pais, Claudio Matos Dantas e Francilene de Oliveira Dantas, por todo apoio, ajuda e incentivo durante toda a minha vida. Aos meus irmãos, Rodrigo de Oliveira Dantas e Gabriel de Oliveira Dantas, por sempre me apoiarem.

Aos meus amigos que estiveram presentes em diversos momentos ao longo desta trajetória, especialmente Bruno, Yuri, Gustavo, Fabrício, Márcio, Eduardo, Erick e Wendell, pela amizade, convivência e pelos momentos compartilhados.

Ao Prof. Dr. Allan Kardec Duailibe Barros Filho, pela confiança, orientação e acompanhamento ao longo desta trajetória.

Ao Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão (UFMA).

Às pessoas que conheci no Laboratório do PIB e na UFMA durante toda a minha trajetória acadêmica, em especial a Marta Barreiros e Luís Eugênio, pelas contribuições, convivência e apoio.

À robótica, que também fez parte importante da minha formação pessoal e profissional. Ao Diogo Lima, pelo companheirismo e apoio nessa caminhada. À minha equipe Falcons, por todos os desafios, aprendizados, conquistas e momentos compartilhados. Em especial, agradeço a Lara Rafaela, Giovanna, Maria Clara, Lara Jamile, Renata, Brunna, Maria Luiza, Kayo, Louise, Beatriz, Antonella, Annanda, Ravilla, Vitória e Lunna, pela dedicação e parceria.

Apoio financeiro do Programa de Formação de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (PRH-ANP), da Financiadora de Estudos e Projetos (FINEP) e da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2025/02550-5.

A todos que contribuíram direta ou indiretamente para a realização deste trabalho.

RESUMO

O mapeamento em larga escala de sedimentos do fundo marinho é fundamental para a gestão ambiental, a engenharia *offshore* e a exploração sustentável de recursos, especialmente em regiões costeiras opticamente complexas, como a Margem Equatorial Brasileira (MEB). Embora levantamentos acústicos tradicionais apresentem elevada precisão, sua aplicação é limitada pelo custo operacional e pela baixa frequência de aquisição. Esta tese apresenta um *pipeline* reproduzível de aprendizado de máquina para classificação regional de sedimentos a partir de imagens Sentinel-2, cobrindo sistematicamente a plataforma rasa entre 0 e 30 m de profundidade. A metodologia integra Análise de Componentes Principais (PCA), Perceptron de Múltiplas Camadas (MLP) e *Synthetic Minority Over-sampling Technique* (SMOTE), associados a um protocolo conservador de curadoria baseado em consistência granulométrica histórica, concordância espacial local e independência entre recortes. O escopo preditivo final foi definido no cenário binário Areia vs Lama, utilizando 2.199 amostras espacialmente independentes sob validação espacial por blocos de 25 km com cinco folds. Entre as famílias avaliadas, incluindo redes neurais convolucionais, MLPs, SVMs e modelos EfficientNet, o *pipeline* MLP+PCA+SMOTE foi selecionado como configuração recomendada por combinar desempenho competitivo, estabilidade e baixo custo computacional. A configuração otimizada atingiu acurácia de $92,64\% \pm 1,95$, F1 macro de $89,04\% \pm 2,40$ e custo computacional 6,6 vezes inferior ao da CNN-Base. Embora não tenham sido observadas diferenças estatisticamente significativas em relação às arquiteturas convolucionais avaliadas, a concordância cartográfica de 84,9% com mapeamento sedimentológico independente indica consistência cartográfica regional, sem constituir validação contemporânea *in situ*. Os resultados demonstram que modelos espectrais leves constituem alternativa viável e escalável para o mapeamento regional de sedimentos em ambientes costeiros complexos, desde que acompanhados por curadoria rigorosa, validação espacial adequada e interpretação cautelosa das limitações temporais dos dados.

Palavras-chave: Sedimentos Marinhos; Margem Equatorial Brasileira; Sensoriamento Remoto; Aprendizado de Máquina.

ABSTRACT

Large-scale mapping of seafloor sediments is essential for environmental management, offshore engineering, and the sustainable exploitation of resources, especially in optically complex coastal regions such as the Brazilian Equatorial Margin (BEM). Although traditional acoustic surveys provide high accuracy, their application is limited by operational costs and low acquisition frequency. This thesis presents a reproducible machine learning pipeline for regional sediment classification using Sentinel-2 imagery, systematically covering the shallow shelf between 0 and 30 m depth. The methodology integrates Principal Component Analysis (PCA), Multilayer Perceptron (MLP), and Synthetic Minority Over-sampling Technique (SMOTE), combined with a conservative curation protocol based on historical granulometric consistency, local spatial agreement, and independence between image patches. The final predictive scope was defined as the binary Sand vs Mud scenario, using 2,199 spatially independent samples under 25 km block-based spatial validation with five folds. Among the evaluated model families, including convolutional neural networks, MLPs, SVMs, and EfficientNet models, the MLP+PCA+SMOTE pipeline was selected as the recommended configuration because it combined competitive performance, stability, and low computational cost. The optimized configuration achieved an accuracy of $92.64\% \pm 1.95$, macro F1 of $89.04\% \pm 2.40$, and computational cost 6.6 times lower than that of CNN-Base. Although no statistically significant differences were observed in relation to the evaluated convolutional architectures, the cartographic agreement of 84.9% with an independent sedimentological map indicates regional cartographic consistency, without constituting contemporary *in situ* validation. The results demonstrate that lightweight spectral models represent a viable and scalable alternative for regional sediment mapping in complex coastal environments, provided that they are accompanied by rigorous curation, adequate spatial validation, and cautious interpretation of the temporal limitations of the data.

Keywords: Marine Sediments; Brazilian Equatorial Margin; Remote Sensing; Machine Learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Margem Equatorial Brasileira.	23
Figura 2 – Classificação simplificada de sedimentos marinhos a partir de componentes bióticos e abióticos.	26
Figura 3 – Resolução Espacial versus Comprimento de Onda: o satélite Sentinel-2 possui 13 bandas espectrais que se estendem do Visível (VIS) e Infravermelho Próximo (NIR) até o Infravermelho de Onda Curta (SWIR) com <i>pixels</i> de 10 a 60 m no solo.	28
Figura 4 – Estrutura básica de um neurônio biológico.	32
Figura 5 – Neurônio Artificial.	32
Figura 6 – Fronteira de decisão de um problema linearmente separável.	33
Figura 7 – Rede Neural Artificial <i>Perceptron</i>	33
Figura 8 – Rede Neural Artificial MLP.	34
Figura 9 – Arquitetura básica de uma RNC. A rede convolucional é formada por diversas camadas convolucionais, que aplica uma função matemática de convolução nos dados de entrada e depois realizar o agrupamento (<i>pooling</i>). Em seguida os dados são vetorizados e são enviados até chegar na última camada conhecida como camada Densa e totalmente conectada.	37
Figura 10 – Convolução 2D com um núcleo de tamanho 3×3 . O núcleo convolucional 3×3 desliza sobre a matriz da imagem para gerar a matriz de saída.	38
Figura 11 – Exemplo de <i>Average Pooling</i> e <i>Max Pooling</i>	39
Figura 12 – Bacias sedimentares da Margem Equatorial Brasileira.	43
Figura 13 – Distribuição espacial dos 5.515 registros sedimentológicos históricos (1956–2004) utilizados no estudo, cobrindo a Margem Equatorial Brasileira e registros complementares da Bacia Pernambuco-Paraíba.	44
Figura 14 – Fluxo de construção da base de dados: pré-processamento batimétrico do acervo histórico, aquisição de imagens Sentinel-2, controle visual de qualidade, curadoria conservadora baseada em consistência granulométrica e espacial, restrição de não sobreposição entre recortes, particionamento espacial, amostragem espectral, PCA e definição do escopo final binário Areia vs. Lama.	46
Figura 15 – Distribuição acumulada das amostras por classe sedimentológica, de 0 a -30 m, após o pré-processamento batimétrico.	47

Figura 16 – Exemplos de amostras descartadas durante o controle visual de qualidade. O mosaico ilustra artefatos que passaram pelo filtro automático de nuvens ($< 10\%$), mas ainda comprometiam a classificação de sedimentos: (a) estrutura portuária, (b) nuvens residuais, (c) interface costeira, (d) embarcações e esteiras, (e) borda de varredura do sensor, (f) falha de processamento, (g) turbidez extrema ou reflectância anômala, e (h) <i>sunglint</i> ou anomalia cromática.	49
Figura 17 – Exemplo ilustrativo do particionamento espacial por blocos de 25 km. Cada cor representa um <i>fold</i> distinto.	52
Figura 18 – Amostras representativas das classes Areia e Lama no conjunto final binário. (a)–(b) Recortes em composição RGB (B4–B3–B2), com estimamento de contraste (2–98%). (c) Assinaturas espectrais médias em B2, B3, B4 e B8, com faixa sombreada indicando ± 1 desvio padrão dos valores de reflectância dos <i>pixels</i> em cada recorte. O perfil espectral mostra sobreposição parcial entre as classes, mas também diferenças de amplitude e no comportamento da reflectância ao longo das bandas analisadas.	53
Figura 19 – Sensibilidade espectral sem batimetria: $F1$ <i>macro</i> em função do conjunto de bandas para MLP+PCA e CNN-SE (melhor configuração por conjunto, validação espacial por blocos, 5 <i>folds</i>). A MLP apresenta ganho monotônico até VIS+NIR+SWIR+AC, enquanto a CNN-SE mostra variação irregular com amplitude inferior a 1 p.p.	68
Figura 20 – Efeito das estratégias de tratamento do desbalanceamento na MLP com VIS+NIR+SWIR+AC, sem batimetria (média $\pm$ desvio padrão nos 5 <i>folds</i>). O SMOTE apresenta maior $F1$ <i>macro</i> e menor dispersão; a diferença em relação à ausência de balanceamento não é estatisticamente significativa ($p = 0,326$).	70
Figura 21 – Compromisso entre desempenho, estabilidade e custo computacional das principais configurações sem batimetria. Eixo x : tempo médio por <i>fold</i> em escala logarítmica; eixo y : $F1$ <i>macro</i> (%); tamanho da bolha: $\sigma(F1$ <i>macro</i>). O SVM+SMOTE destaca-se pela máxima eficiência ($83,8\times$ mais rápido que a CNN-Base; $165\times$ mais rápido que a CNN-SE); a MLP+SMOTE combina desempenho competitivo com a menor variabilidade entre <i>folds</i>	72

Figura 22 – Métricas médias nos cinco <i>folds</i> (acurácia, Kappa e <i>F1 macro</i>) do modelo PCA+MLP+SMOTE em função do número de componentes principais (k), no intervalo de $k = 2$ a $k = 50$, no cenário binário Areia vs. Lama. Observa-se ganho rápido para valores baixos de k , faixa ótima em torno de $k = 13$ a $k = 15$ e manutenção de desempenho competitivo em $k = 32$, seguida de leves oscilações e ganhos marginais no intervalo exibido.	73
Figura 23 – Contribuição espectral relativa (%) de cada banda Sentinel-2 por componente principal (PCA, $k = 13$, conjunto VIS+NIR+SWIR+AC), expressa como média nos cinco <i>folds</i> de treinamento da validação espacial por blocos de 25 km. Os valores foram obtidos agregando a energia dos <i>loadings</i> ($loadings^2$) sobre os <i>pixels</i> do recorte (96×96) e normalizando para somar 100% em cada PC. A linha tracejada separa os componentes com variância explicada maior que 1% (PC1–PC4) dos componentes residuais (PC5–PC13). A variância explicada de cada componente é indicada entre parênteses no eixo vertical.	74
Figura 24 – Mapa regional exploratório de dominância sedimentar Areia vs. Lama obtido por inferência direta do modelo MLP+PCA+SMOTE sobre uma grade independente de 606 nós, restrita à isóbata de -30 m e representada por tesselação de Voronoi dissolvida por classe dominante e suavizada. (a) Mapa integrado Areia vs. Lama.	80
Figura 25 – Domínios de areia: polígonos correspondentes aos nós da grade com predição dominante de areia.	80
Figura 26 – Domínios de lama: polígonos correspondentes aos nós da grade com predição dominante de lama.	80
Figura 27 – Índice de equilíbrio binário heurístico nos 606 nós da grade de inferência. (a) Distribuição dos nós por faixa de índice: 76,6% apresentam valores abaixo de 0,05, indicando clara dominância de uma classe. (b) Localização espacial dos 95 nós com índice $\geq 0,2$ (ambiguidade local), sobrepostos aos demais 511 nós em cinza (dominância clara); a escala de cores indica a intensidade do equilíbrio entre as classes Areia e Lama. O índice é apresentado apenas como descritor heurístico de ambiguidade local, e não como medida calibrada de incerteza preditiva.	82

LISTA DE TABELAS

Tabela 1	– Conjuntos espectrais avaliados e respectivas bandas Sentinel-2.	48
Tabela 2	– Configurações representativas de alto desempenho no cenário binário Areia vs. Lama sem batimetria explícita (validação espacial por blocos, 5 <i>folds</i>). Média $\pm$ desvio padrão (%).	64
Tabela 3	– Testes t pareados bicaudais entre configurações representativas sem batimetria. Nenhuma comparação atingiu significância estatística para $\alpha = 0,05$	65
Tabela 4	– Desempenho por classe das configurações mais competitivas sem batimetria (média nos 5 <i>folds</i> , %).	66
Tabela 5	– Efeito da batimetria em configurações representativas. Valores em $F1_{macro}$ (%). Significância do teste t pareado indicada na última coluna.	69
Tabela 6	– Controle adicional sobre a suficiência preditiva da batimetria na MLP com VIS+NIR+SWIR+AC e SMOTE. O cenário apenas com batimetria permanece substancialmente abaixo dos regimes espectrais.	69
Tabela 7	– Desempenho do modelo PCA+MLP+SMOTE para valores representativos de k (média $\pm$ desvio padrão nos 5 <i>folds</i>).	72
Tabela 8	– Correlação entre <i>scores</i> PCA (PC1–PC7) e batimetria média do recorte (96×96), expressa como média $\pm$ desvio padrão nos cinco <i>folds</i> de treinamento ($N_{treino} \approx 1.759$). Conjunto VIS+NIR+SWIR+AC, $k = 13$; batimetria tratada como variável externa, sem participação na PCA.	75
Tabela 9	– Métricas de concordância cartográfica entre o modelo óptico (MLP+PCA+SMOTE, $k = 13$) e o mapeamento sedimentológico independente de Santos Filho et al. (FILHO et al., 2025a), nos 530 nós comparáveis da grade regular. [†]	81

LISTA DE ABREVIATURAS E SIGLAS

ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
API	<i>Application Programming Interface</i>
BAMPETRO	Banco Nacional de Dados para a Indústria do Petróleo
BDCA	Banco de Dados de Caracterização Ambiental
BNDO	Banco Nacional de Dados Oceanográficos
CBAM	<i>Convolutional Block Attention Module</i>
CNN	<i>Convolutional Neural Networks</i> (Redes Neurais Convolucionais)
ESA	<i>European Space Agency</i> (Agência Espacial Europeia)
GEBCO	<i>General Bathymetric Chart of the Oceans</i>
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
LAGEMAR	Laboratório de Geologia e Geofísica Marinha
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
ML	<i>Machine Learning</i> (Aprendizado de Máquina)
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i> (Erro Quadrático Médio)
NLP	<i>Natural Language Processing</i> (Processamento de Linguagem Natural)
R^2	Coefficiente de Determinação (<i>Coefficient of Determination</i>)
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais
RNN	Redes Neurais Recorrentes
REMAC	Projeto REMAC
SIG	Sistema de Informações Geográficas

SWIR *Shortwave Infrared* (Infravermelho de Onda Curta)

UFF Universidade Federal Fluminense

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	17
1.1.1	Objetivo Geral	18
1.1.2	Objetivos Específicos	18
1.2	Trabalhos Relacionados	18
1.3	Estrutura do Trabalho	21
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Margem Equatorial Brasileira	23
2.2	Sedimentos marinhos e fácies bentônicas	25
2.3	Sensoriamento Remoto	27
2.4	Redes Neurais Artificiais	31
2.4.1	Neurônio	31
2.4.2	<i>Perceptron</i>	32
2.4.3	<i>Perceptron</i> de Múltiplas Camadas	34
2.4.4	Aprendizado das Redes Neurais Artificiais	35
2.5	Redes Neurais Convolucionais - RNC	36
2.5.1	Camada convolucional	37
2.5.2	Camadas de <i>Pooling</i> (Camada de agrupamento).	39
2.5.3	Funções de ativação	40
2.5.4	<i>Batch Normalization</i>	40
2.5.5	<i>Training Process</i>	41
2.5.6	Função de perda	41
2.5.7	Otimização	42
3	MATERIAIS E MÉTODOS	43
3.1	Área de estudo e base de dados sedimentológicos	43
3.2	Padronização das classes sedimentológicas	45
3.3	Fluxo metodológico	45
3.4	Pré-processamento dos dados históricos	46
3.5	Aquisição e pré-processamento das imagens Sentinel-2	47
3.6	Controle visual de qualidade	48
3.7	Curadoria conservadora dos rótulos e seleção espacial	49
3.8	Validação espacial por blocos	51
3.9	Representação espectral e preparação para modelagem	52
3.10	Redução de dimensionalidade por PCA	53

3.11	Algoritmos de classificação	54
3.11.1	Bloco profundo	54
3.11.2	Bloco clássico baseado em PCA	55
3.12	Tratamento do desbalanceamento	55
3.13	Procedimentos de treinamento	56
3.13.1	Bloco profundo	56
3.13.2	Bloco clássico	57
3.14	Ambiente computacional e reprodutibilidade	57
3.15	Métricas de avaliação	58
3.16	Critério de seleção do modelo e análise estatística	59
3.17	Análise do papel da batimetria	59
3.18	Análise de sensibilidade do número de componentes principais	60
3.19	Explicabilidade do modelo e interpretação física dos componentes	60
3.20	Inferência espacial e representação cartográfica	61
4	RESULTADOS E DISCUSSÃO	63
4.1	Escopo experimental final	63
4.2	Comparação estatística e desempenho global	64
4.3	Desempenho por classe e perfil de erro	65
4.4	Sensibilidade espectral	67
4.5	Papel da batimetria	68
4.6	Resultados do tratamento do desbalanceamento	70
4.7	Compromisso entre desempenho, estabilidade e custo computacional	71
4.8	Análise de sensibilidade do número de componentes principais	72
4.9	Explicabilidade do modelo e interpretação física dos componentes	73
4.10	Síntese dos resultados	76
4.11	Consistência espacial e interpretação geológica	79
4.12	Limitações e validade temporal dos dados	82
5	CONSIDERAÇÕES FINAIS	84
	REFERÊNCIAS	86

1 INTRODUÇÃO

A plataforma continental equatorial brasileira, incluindo a Margem Equatorial, é uma zona de transição dinâmica entre processos continentais e oceânicos, caracterizada por complexas interações entre a biota e os sedimentos (RAMESH et al., 2015). Esta região, que se estende por aproximadamente 2.200 km ao longo da costa, emerge como uma promissora fronteira para a extração de recursos não renováveis, tais como petróleo e gás natural, bem como para o desenvolvimento de energias renováveis, a exemplo da eólica *offshore*. A relevância da Margem Equatorial para a exploração de hidrocarbonetos decorre, em parte, das semelhanças geológicas com a costa ocidental da África, reconhecida por suas vastas reservas petrolíferas. Essa analogia geológica sugere condições petrolíferas similares no Brasil, corroboradas por descobertas recentes de reservatórios nas bacias de Barreirinhas e Pará-Maranhão (PELLEGRINI; RIBEIRO, 2018).

No contexto de diversificação da matriz energética, além do potencial petrolífero, a ampla extensão litorânea oferece condições favoráveis para a implementação de fazendas eólicas *offshore* no Brasil. Contudo, as políticas de regulação para licenciamento, monitoramento e proteção ambiental dessas instalações continuam em fase de discussão e desenvolvimento (GONZÁLEZ et al., 2020). Nesse sentido, compreender a distribuição de sedimentos marinhos, é fundamental para o desenvolvimento sustentável dessas atividades, garantindo a compatibilização entre a exploração de energia (fóssil ou renovável) e a conservação de ecossistemas marinhos sensíveis (BOSENCE, 2021; BAKER; PUGLISE; HARRIS, 2016).

O mapeamento dessas feições bentônicas é uma tarefa desafiadora devido à variabilidade inerente dos ambientes marinhos e à disponibilidade limitada de dados ambientais abrangentes (DEGRAER et al., 2008; HARRIS, 2020). Métodos tradicionais de amostragem direta de sedimentos fornecem informações detalhadas, porém são dispendiosos e cobrem áreas restritas (CLARKE; MAYER; WELLS, 1996; POST, 2008). Por outro lado, técnicas de sensoriamento remoto, incluindo imagens de satélite, permitem coletar informações em larga escala, mas exigem integração com dados de *ground truth* para interpretação precisa dos tipos de sedimento (BOSWARVA et al., 2018; MILLIMAN, 1977). Além disso, a aquisição extensiva de amostras de sedimentos marinhos muitas vezes não é operacionalmente viável para o reconhecimento ideal das fácies sedimentares da plataforma continental, o que reforça a necessidade de abordagens indiretas e modelagens preditivas.

Com o avanço das tecnologias digitais e o incremento de dados disponíveis, abordagens modernas têm buscado integrar informações de sedimentos provenientes de amostragem direta com de sensoriamento remoto. Tais abordagens incluem o uso de dados públicos de sedimento e sísmica multicanal 2D, bem como técnicas de aprendizado de

máquina para prever classes de sedimento (PELLEGRINI; RIBEIRO, 2018). Modelos empíricos supervisionados e algoritmos de aprendizado de máquina, como redes neurais convolucionais, têm sido amplamente adotados por sua capacidade de modelar relações complexas e não lineares, dispensando premissas estatísticas restritivas (BOSENCE, 2021; HARRIS, 2020). Essas técnicas têm mostrado grande potencial no mapeamento de habitats bentônicos, permitindo prever tipos de sedimento em locais não amostrados e gerar mapas de cobertura total quando acopladas a dados ambientais contínuos (BAKER; HARRIS, 2020; DEGRAER et al., 2008).

Apesar desses avanços, grande parte do assoalho oceânico permanece não mapeado e inexplorado (GINSBURG; JAMES, 1974; VALE et al., 2018), o que dificulta a implementação de planos de monitoramento que colem dados de distribuição de sedimentos e contextualizem objetivamente os potenciais impactos da exploração de recursos energéticos, sejam eles fósseis ou renováveis (CLARKE; MAYER; WELLS, 1996; HARRIS, 2020). Nesse contexto, a reutilização de dados históricos de geologia marinha, empregando técnicas modernas de processamento e análise espacial, torna-se fundamental para o mapeamento em escala regional (FIGUEIREDO et al., 2016; FILHO et al., 2022).

Nesse contexto, este trabalho investiga a classificação de sedimentos rasos (areia e lama) na plataforma continental da MEB a partir de imagens Sentinel-2, cobrindo sistematicamente o intervalo de 0 a 30 m de profundidade. Esse intervalo corresponde a uma lacuna entre os mapeamentos geofísicos e mesofóticos mais profundos de Santos Filho et al. (FILHO et al., 2025a; FILHO et al., 2025b), que abrangem a faixa de 30 a 200 m, enquanto a faixa de 0 a 30 m ainda carecia de abordagens supervisionadas sistemáticas com curadoria conservadora e validação espacial rigorosa na MEB. A metodologia emprega técnicas de PCA para reduzir a complexidade espectral e realçar a informação discriminativa, seguida do treinamento e da comparação de classificadores supervisionados capazes de capturar padrões não lineares associados a diferentes classes sedimentares. A principal contribuição do estudo reside na organização e avaliação de um *pipeline* reproduzível, baseado em curadoria conservadora de dados, validação espacial por blocos e análise de sensibilidade, para investigar o sinal sedimentar regional e gerar mapas coerentes com o conhecimento geológico disponível.

1.1 Objetivos

A seguir é apresentado o objetivo geral deste trabalho e também os objetivos específicos.

1.1.1 Objetivo Geral

Mapear os sedimentos do fundo marinho da Margem Equatorial Brasileira, no intervalo de 0 a 30 m, a partir de imagens de satélite.

1.1.2 Objetivos Específicos

- Revisar a literatura sobre classificação de sedimentos do fundo marinho por sensoriamento remoto, dados acústicos, dados sedimentológicos e aprendizado de máquina;
- Organizar e padronizar uma base histórica de registros sedimentológicos da Margem Equatorial Brasileira e áreas adjacentes;
- Construir uma base de recortes multiespectrais Sentinel-2 associada aos registros sedimentológicos elegíveis;
- Aplicar um protocolo de curadoria conservadora, controle de qualidade visual e seleção espacial para reduzir inconsistências de rótulo e dependência entre amostras;
- Implementar e comparar modelos supervisionados leves e profundos, incluindo MLP+PCA, SVM+PCA, CNNs e arquiteturas baseadas em EfficientNet;
- Avaliar o desempenho dos modelos por validação espacial em blocos, considerando acurácia, Kappa, *F1 macro*, desempenho por classe, estabilidade e custo computacional;
- Gerar mapas exploratórios de dominância sedimentar Areia vs Lama para a plataforma rasa da Margem Equatorial Brasileira e avaliar sua consistência cartográfica com mapeamentos sedimentológicos independentes.

1.2 Trabalhos Relacionados

A caracterização e o mapeamento de sedimentos do fundo marinho têm sido tradicionalmente fundamentados em amostragens físicas e análises laboratoriais, consideradas referências diretas para a determinação da granulometria e da composição do substrato (BLOTT; PYE, 2001). Apesar da elevada confiabilidade, esses procedimentos são pontuais, custosos e de difícil repetição em grandes áreas. Essa limitação motivou o uso crescente de métodos indiretos, especialmente levantamentos acústicos, dados sísmicos, batimetria, atributos geomorfológicos, sensoriamento remoto óptico e modelos estatísticos ou de aprendizado de máquina.

No domínio acústico, avanços recentes demonstram que dados de batimetria e retroespalhamento podem ser explorados não apenas para classificação categórica, mas também para modelagem contínua de propriedades sedimentares. Innangi et al. (INNANGI et al., 2022), por exemplo, propuseram um modelo de regressão linear para gerar mapas contínuos de distribuição granulométrica a partir de atributos acústicos. Galvez et al. (GALVEZ et al., 2021), por sua vez, empregaram técnicas de *ensemble modelling* para produzir mapas sedimentares mesmo em cenários com dados de campo limitados e desbalanceados. Essas abordagens demonstram alta utilidade para mapeamento regional, mas ainda dependem de campanhas oceanográficas dedicadas, o que limita a frequência de atualização e aumenta o custo operacional.

Na Margem Equatorial Brasileira, Santos Filho et al. (FILHO et al., 2025a) integraram 5.515 amostras sedimentológicas históricas e 384 linhas sísmicas 2D para mapear fácies do fundo marinho. Por meio de Análise de Componentes Principais (PCA), os autores correlacionaram atributos sísmicos, como intensidade, frequência e coerência, com propriedades sedimentares, incluindo teor de cascalho e carbonato. O resultado foi a extrapolação espacial da classificação sedimentar e o mapeamento de aproximadamente 29.830 km² de depósitos bioclásticos associados a ecossistemas mesofóticos. Em estudo complementar, Santos Filho et al. (FILHO et al., 2025b) mapearam bioclastos e cascalhos carbonáticos na zona mesofótica da margem brasileira, contribuindo para a interpretação regional dos domínios sedimentares entre 30 e 200 m.

Esses estudos geofísicos são particularmente relevantes para esta tese porque evidenciam a organização regional dos sedimentos na MEB e oferecem uma base independente para comparação cartográfica. Entretanto, eles se concentram sobretudo em faixas batimétricas mais profundas ou em produtos derivados de dados geofísicos e sedimentológicos históricos. O intervalo raso de 0 a 30 m, que é justamente a faixa com maior potencial de observação por sensoriamento óptico orbital, ainda carece de abordagens supervisionadas sistemáticas, com curadoria conservadora e validação espacial rigorosa.

No domínio óptico, o Sentinel-2 tem se destacado por sua cobertura ampla, revisita frequente e resolução espacial de 10 m nas bandas do visível e do infravermelho próximo (PAHLEVAN et al., 2017). Essas características tornam a missão atrativa para aplicações costeiras, incluindo mapeamento bentônico em águas rasas e análise de substratos em ambientes com maior transparência (POURSANIDIS et al., 2019). Contudo, a inferência sedimentar por imagens ópticas é desafiadora em regiões turvas, pois a reflectância registrada pelo sensor é influenciada pela coluna d'água, por material em suspensão, pelo *sun glint*, por efeitos atmosféricos, pela profundidade e pela mistura espectral entre água, fundo e sedimentos (KUTSER et al., 2020; CABALLERO; STUMPF, 2023). Na MEB, esses desafios são intensificados pela pluma amazônica, pela elevada descarga fluvial e pela forte variabilidade hidrodinâmica regional.

Estudos recentes reforçam o potencial de características espectrais do fundo marinho para inferir propriedades físicas e sedimentares. Li et al. (LI et al., 2023) aplicaram modelos empíricos de regressão e razões de bandas para mapear diferentes tipos de sedimento, obtendo melhorias em métricas de erro associadas à estimativa batimétrica e sedimentar. Chen et al. (CHEN et al., 2023) propuseram uma abordagem de aprendizado ativo baseada em grafos, capaz de alcançar alta acurácia com quantidade reduzida de dados rotulados. Esses trabalhos indicam que modelos supervisionados podem explorar informação espectral mesmo em cenários de escassez amostral, desde que o desenho experimental controle adequadamente ruídos, viés espacial e incertezas de rotulagem.

No contexto brasileiro, Neto (NETO, 2017) antecipou parte dessa discussão ao empregar imagens Landsat 8 e Sentinel-2 integradas a dados acústicos e técnicas de classificação supervisionada, como Máxima Verossimilhança, Árvore de Decisão e *K-means*, no mapeamento sedimentar da plataforma continental do Rio Grande do Norte. Embora anterior à ampla adoção de redes neurais profundas em mapeamento bentônico, o estudo demonstrou a viabilidade de imagens multiespectrais para identificação de tipos sedimentares, alcançando acurácia global superior a 80%. Essa contribuição é relevante por marcar uma transição entre abordagens empíricas tradicionais e estratégias modernas baseadas em aprendizado de máquina.

Técnicas de aprendizado profundo também têm sido aplicadas à classificação sedimentar, especialmente em dados acústicos e imagens de alta dimensão. Qin et al. (QIN et al., 2021), utilizando dados de sonar de varredura lateral, aplicaram redes neurais convolucionais e modelos adversariais generativos para classificação de sedimentos, obtendo taxas de erro inferiores a 3,5%. Em sensoriamento óptico, CNNs e arquiteturas profundas podem explorar padrões espaciais e texturais dos recortes, mas exigem maior volume de dados, maior custo computacional e maior cuidado com autocorrelação espacial. Em problemas com amostras históricas heterogêneas e classes desbalanceadas, modelos leves baseados em atributos espectrais reduzidos podem representar uma alternativa operacionalmente mais simples e reproduzível.

Além das arquiteturas, a validação é um aspecto crítico. Em dados ambientais georreferenciados, amostras próximas tendem a ser espacialmente autocorrelacionadas; por isso, particionamentos aleatórios podem superestimar a capacidade de generalização dos modelos. Protocolos baseados em blocos espaciais, como o adotado nesta tese, são mais conservadores porque impedem que amostras muito próximas sejam simultaneamente usadas em treino e teste. Esse ponto é especialmente importante na classificação de sedimentos por imagens, pois recortes vizinhos podem compartilhar condições ópticas, padrões de turbidez, profundidade e domínio sedimentar.

Outro desafio recorrente é o desbalanceamento entre classes. Em bases sedimentológicas regionais, classes como lama e cascalho podem ser naturalmente menos frequentes

ou espacialmente concentradas, dificultando a avaliação independente. Estratégias como SMOTE, ADASYN e Borderline-SMOTE (CHAWLA et al., 2002; HE et al., 2008; HAN; WANG; MAO, 2005), além de ponderação de classes e *focal loss* (HE; GARCIA, 2009; LIN et al., 2017), têm sido usadas para reduzir o viés em favor da classe majoritária. No entanto, quando a classe minoritária está concentrada em poucos blocos geográficos, o problema não é apenas estatístico, mas também espacial. Nesse caso, a redefinição do escopo preditivo pode ser necessária para preservar a integridade da validação.

Abordagens probabilísticas e modelos de distribuição espacial também têm contribuído para o mapeamento sedimentar. Capizzano et al. (CAPIZZANO et al., 2024) aplicaram um modelo MaxEnt para prever sedimentos superficiais no Atlântico Norte com dados geoespaciais públicos, destacando a importância de variáveis batimétricas, como profundidade e declividade. Brenan et al. (BRENAN et al., 2024) ampliaram esse escopo ao modelar propriedades biogeoquímicas por *Random Forest* e *kriging* bayesiano, conectando a caracterização do substrato à estimativa de variáveis ambientais, como estoques de carbono orgânico. Esses estudos reforçam que o mapeamento sedimentar contemporâneo tende a combinar amostras legadas, atributos ambientais, modelos supervisionados e análise espacial.

Diante desse panorama, a contribuição desta tese situa-se na interseção entre sensoriamento remoto óptico, curadoria de dados sedimentológicos históricos e aprendizado de máquina eficiente. Diferentemente de levantamentos acústicos dedicados, a abordagem proposta explora a cobertura frequente e de baixo custo do Sentinel-2. Diferentemente de validações aleatórias, adota blocos espaciais de 25 km para avaliar generalização geográfica. Diferentemente de uma classificação ternária forçada, reconhece a limitação espacial da classe cascalho e concentra o escopo final no cenário Areia vs Lama. Assim, o trabalho busca preencher uma lacuna específica: avaliar se modelos espectrais leves, combinados com PCA, SMOTE e curadoria conservadora, podem gerar mapas regionais coerentes para a plataforma rasa da MEB no intervalo de 0 a 30 m, respeitando os limites interpretativos impostos pela ausência de validação contemporânea *in situ*.

1.3 Estrutura do Trabalho

Para se chegar às conclusões necessárias, a pesquisa foi organizada em cinco capítulos. O Capítulo 1 apresenta a introdução, a contextualização do problema, os objetivos e os trabalhos relacionados ao mapeamento sedimentar por sensoriamento remoto, dados acústicos, dados geofísicos e aprendizado de máquina. O Capítulo 2 reúne a fundamentação teórica sobre a Margem Equatorial Brasileira, os sedimentos marinhos e fácies bentônicas, o uso de imagens Sentinel-2 em águas rasas e os modelos de aprendizado de máquina avaliados. O Capítulo 3 descreve a metodologia, incluindo a construção do acervo sedimentológico, a aquisição das imagens, a curadoria conservadora, o particionamento

espacial, a representação espectral, os modelos supervisionados, as métricas de avaliação e o procedimento de geração dos mapas. O Capítulo 4 apresenta os resultados e a discussão, com ênfase no desempenho dos modelos, na sensibilidade espectral, no papel da batimetria, no tratamento do desbalanceamento, no compromisso entre desempenho, estabilidade e custo computacional, na análise de componentes principais, na consistência cartográfica e nas limitações do estudo. Por fim, o Capítulo 5 apresenta as considerações finais e as propostas para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica que serve como base para a elaboração deste trabalho. Nele, são discutidos conceitos fundamentais relacionados ao estudo de Imagens de Satélite e Redes Neurais. Esses tópicos são essenciais para compreender os métodos e abordagens utilizados na análise de dados para classificação de sedimentos marinhos, integrando sensoriamento remoto e inteligência artificial.

2.1 Margem Equatorial Brasileira

A Margem Equatorial Brasileira compreende uma extensa faixa costeira que se estende pelos estados do Amapá, Pará, Maranhão, Piauí, Ceará e Rio Grande do Norte. Nessa região, situam-se as bacias sedimentares da Foz do Amazonas, Pará-Maranhão, Barreirinhas, Ceará e Potiguar (Figura 1), totalizando cerca de 576.997 km² (MILANI et al., 2000). Além de sua relevância geográfica, essa área tem grande importância econômica, pois abriga recursos naturais consideráveis, como petróleo, gás natural e minerais. A localização próxima à Linha do Equador confere clima tipicamente tropical, com altas temperaturas e umidade, favorecendo a formação de ecossistemas ricos, como florestas, manguezais e extensos sistemas estuarinos e deltaicos.

Figura 1 – Margem Equatorial Brasileira.



Fonte: Adaptado de Jornal O Liberal.

Do ponto de vista geológico, a Margem Equatorial Brasileira é uma extensão da plataforma continental do país, cuja formação está ligada a eventos de distensão litosférica ocorridos desde o Mesozoico (MILANI et al., 2000). O processo de ruptura do supercontinente Gondwana levou à separação das placas Sul-Americana e Africana, culminando na abertura do Oceano Atlântico Sul. Assim, a maior parte dessa margem

tem natureza distensiva, estendendo-se do sul da Argentina até o extremo nordeste do Brasil. Há também um segmento transformante no Atlântico Equatorial, onde processos distensionais ainda ocorrem atualmente (MILANI et al., 2000).

As bacias sedimentares que compõem essa margem evoluíram a partir do Neo-Triássico e Cretáceo, apresentando características tectonosedimentares distintas em comparação a outras áreas da plataforma brasileira. O cisalhamento dextrogiro da crosta gerou falhas oblíquas subverticais responsáveis pelo rifteamento, que evoluiu para grandes zonas de fratura oceânicas, tais como São Paulo e Romanche (MILANI et al., 2000). Um destaque é o trecho ao norte da Foz do Amazonas, inserido em um contexto distensivo mais antigo, relacionado ao Oceano Atlântico Central. De modo geral, essas bacias compartilham três fases tectonosedimentares principais: rifte, transicional e marinha aberta.

A exploração de petróleo e gás na região reforça sua importância estratégica. Já existem campos produtivos consolidados nas bacias Potiguar e Ceará, enquanto as bacias em águas profundas, como Pará-Maranhão e Barreirinhas, permanecem relativamente pouco exploradas. Entretanto, o interesse por essas áreas vem crescendo em razão de descobertas de petróleo em bacias geologicamente semelhantes na margem equatorial africana, em especial no Golfo da Guiné e na Guiana Francesa. Tais correlações se devem ao contexto tectônico transformante, que resultou na abertura do Atlântico Equatorial durante o Cretáceo (MILANI et al., 2000).

Além do potencial energético, a Margem Equatorial Brasileira destaca-se pela alta biodiversidade marinha e costeira. A presença de manguezais, florestas tropicais e águas rasas ricas em nutrientes sustenta ecossistemas essenciais para a manutenção do equilíbrio ecológico. Contudo, a exploração desses recursos, sobretudo de petróleo e gás, exige cautela para minimizar impactos ambientais, dada a sensibilidade de áreas costeiras e marinhas. O Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) reforça a necessidade de práticas seguras e sustentáveis para proteger habitats vulneráveis a riscos de contaminação e degradação.

Em síntese, a Margem Equatorial Brasileira reúne fatores geológicos, econômicos e ambientais que a tornam um importante eixo de desenvolvimento do país. Sua exploração energética precisa ser pautada pelo equilíbrio entre crescimento econômico, preservação ambiental e bem-estar das comunidades locais. O aprofundamento do conhecimento geológico e a adoção de políticas públicas adequadas são essenciais para assegurar um aproveitamento responsável dos recursos naturais, de forma que os benefícios gerados se estendam a toda a sociedade.

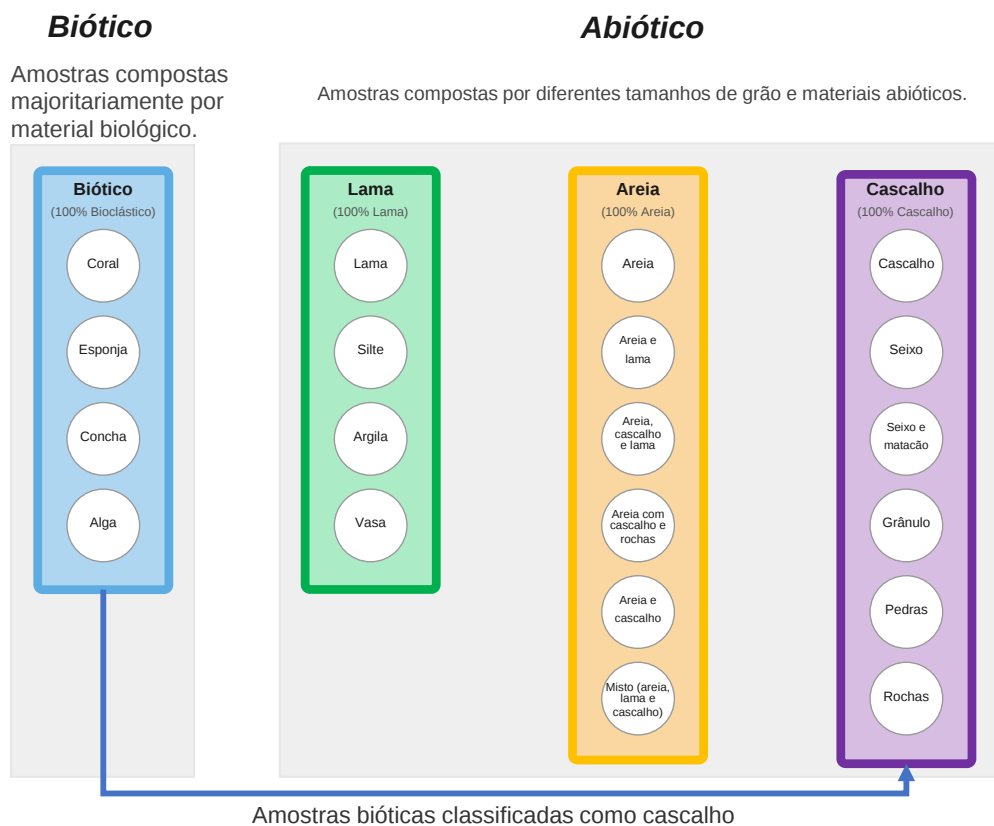
Do ponto de vista bentônico, a MEB também se destaca pela coexistência de domínios sedimentares siliciclásticos, depósitos lamosos associados à influência amazônica, fundos bioclásticos e feições recifais mesofóticas. Estudos recentes na margem amazônica e semiárida indicam que a distribuição desses ambientes não é aleatória, mas condicionada

por gradientes de profundidade, energia hidrodinâmica, aporte terrígeno, disponibilidade de carbonato e herança morfosedimentar (LAVAGNINO et al., 2020; FILHO et al., 2025a; FILHO et al., 2025b). Essa complexidade reforça a necessidade de abordagens de mapeamento capazes de combinar dados sedimentológicos históricos, informação óptica orbital e validação espacial rigorosa, especialmente na plataforma rasa, onde a interação entre coluna d'água e fundo marinho afeta diretamente a resposta espectral observada por sensores como o Sentinel-2.

2.2 Sedimentos marinhos e fácies bentônicas

Sedimentos marinhos superficiais são materiais particulados que recobrem o fundo oceânico e cujas características refletem a interação entre aporte continental, produção biogênica, energia hidrodinâmica, profundidade e história deposicional. Do ponto de vista granulométrico, esses materiais são organizados conforme a proporção relativa de suas frações: a lama reúne as frações mais finas, silte e argila, enquanto a areia compreende partículas de tamanho intermediário e o cascalho engloba grânulos, seixos e fragmentos maiores. Além dessas classes abióticas, descrições sedimentológicas de origem biótica, como corais, esponjas, conchas e algas, indicam a presença de componentes biogênicos no fundo marinho. Essa organização, ilustrada na Figura 2, é amplamente adotada em estudos regionais por permitir integrar dados de diferentes campanhas e resoluções analíticas, mantendo coerência sedimentológica em escala de plataforma (SHEPARD, 1954; FILHO, 2022).

Figura 2 – Classificação simplificada de sedimentos marinhos a partir de componentes bióticos e abióticos.



Fonte: Adaptado de (FILHO, 2022).

A granulometria, porém, não esgota a descrição geológica do fundo marinho. Um mesmo tipo textural pode ter origens e composições muito distintas dependendo da fonte sedimentar e do ambiente deposicional: sedimentos de origem continental, denominados litoclásticos, convivem com sedimentos de origem biogênica, denominados bioclásticos, cuja composição é dominada por fragmentos de organismos marinhos. Na margem continental brasileira, o teor de carbonato de cálcio é utilizado para separar essas classes composicionais, com sedimentos ricos em carbonato associados à origem biogênica e sedimentos pobres em carbonato associados ao aporte continental (LARSONNEUR, 1977; FILHO, 2022). Nesse contexto, a distinção textural entre areia e lama representa uma síntese operacional da variabilidade sedimentar, útil para análises regionais em bases históricas heterogêneas.

A cobertura sedimentar da Margem Equatorial Brasileira não se distribui de maneira uniforme. Nas áreas sob influência amazônica, o intenso aporte de material fino favorece extensos domínios lamosos, especialmente ao longo das costas do Pará e do Amapá, onde marés e correntes são os principais agentes de transporte e retrabalhamento sedimentar (KUEHL; DEMASTER; NITTROUER, 1986; ARAUJO et al., 2021). Nos setores mais orientais e semiáridos, a redução do aporte fluvial e o aumento relativo da produção carbonática favorecem sedimentos mais grossos, com predominância de areias e

cascalhos (VITAL et al., 2010; FILHO et al., 2025a). Esse contraste regional, associado à variabilidade de profundidade, morfologia do fundo e condições ópticas da coluna d'água, torna a MEB um ambiente desafiador para o mapeamento sedimentar por sensoriamento remoto, motivando as escolhas metodológicas descritas nos capítulos seguintes.

2.3 Sensoriamento Remoto

O sensoriamento remoto tem se tornado uma ferramenta essencial na obtenção de informações em larga escala espacial e temporal. Na escolha da fonte de imagens de satélite para classificação, dois parâmetros conflitantes são geralmente considerados: a resolução espacial (superfície representada por um *pixel*) e a resolução espectral (número de bandas espectrais disponíveis e a precisão na detecção de comprimentos de onda pelo sensor) (BOTHA et al., 2013).

A resolução espacial tem um efeito direto: uma resolução mais alta permite um mapeamento mais detalhado, mas exige maior esforço computacional. Por outro lado, a resolução espectral influencia a precisão dos modelos, que geralmente aumenta com o número de bandas visíveis disponíveis [(BOTHA et al., 2013; COLLIN et al., 2021), incluindo bandas de infravermelho (COLLIN; ARCHAMBAULT; PLANES, 2013). Embora não haja uma definição clara, distingue-se geralmente entre satélites multiespectrais, com menos de 20 ou 30 canais, e hiperespectrais, que fornecem dados em centenas de bandas estreitas, como o Hyperion da NASA com 220 canais.


Satélites hiperespectrais têm como desvantagem principal a resolução espacial relativamente baixa, geralmente de dezenas de metros, chegando a até 1 km em alguns casos (HEDLEY et al., 2016), enquanto a maioria dos sensores multiespectrais tem resolução melhor que 4 m. A alta resolução espectral combinada com baixa resolução espacial resulta no problema conhecido como mistura espectral, que é o processo de decompor um *pixel* misto em seus componentes e proporções respectivas. Algoritmos existentes podem abordar esse problema com alta precisão (BIOUCAS-DIAS et al., 2012; GUILLAUME et al., 2020). No entanto, ao desmisturar *pixels*, os algoritmos podem enfrentar erros devido à heterogeneidade da reflectância do fundo do mar, que interfere na radiância com a luz espalhada em elementos vizinhos (GUILLAUME; MICHELS; JAY, 2015). Esse processo, chamado de efeito de adjacência, tem efeitos negativos na precisão do sensoriamento remoto (BULGARELLI; KISELEV; ZIBORDI, 2017) e pode modificar a radiância em até 26%, dependendo da turbidez e profundidade da água (CHAMI et al., 2019).

O Sentinel-2 (HEDLEY et al., 2018a), satélite da Agência Espacial Europeia (ESA), destaca-se por oferecer um equilíbrio adequado entre resolução espacial e espectral para estudos costeiros e marinhos. Projetado inicialmente para monitoramento terrestre (MARTIMORT et al., 2007), o Sentinel-2 (Figura 3) tem sido utilizado para monitoramento de oceanos e, especificamente, para mapeamento de recifes de coral (BRISSET et al., 2021;

WOUTHUYZEN et al., 2019). As bandas espectrais específicas do Sentinel-2, como as bandas SWIR-cirrus e vapor d'água, são especialmente úteis para algoritmos de detecção e remoção de nuvens (EBEL et al., 2021; SINGH; KOMODAKIS, 2018). Vantagens do Sentinel-2:

1. Resolução Espacial Aprimorada: Com *pixels* de 10 metros nas bandas visíveis e infravermelho próximo, o Sentinel-2 permite a identificação de padrões bentônicos com maior detalhe em comparação com satélites de resolução mais baixa.
2. Resolução Espectral Adequada: As 13 bandas espectrais do Sentinel-2, incluindo bandas no SWIR e bandas específicas para detecção de vapor d'água e cirros, facilitam a correção atmosférica e a remoção de nuvens.
3. Revisita Frequente: Com dois satélites operacionais (Sentinel-2A e Sentinel-2B), o tempo de revisita é de aproximadamente 5 dias no equador, aumentando a probabilidade de obter imagens sem cobertura de nuvens.
4. Acesso Livre aos Dados: Os dados do Sentinel-2 são disponibilizados gratuitamente, o que é vantajoso para pesquisas acadêmicas e projetos com recursos limitados.

Figura 3 – Resolução Espacial versus Comprimento de Onda: o satélite Sentinel-2 possui 13 bandas espectrais que se estendem do Visível (VIS) e Infravermelho Próximo (NIR) até o Infravermelho de Onda Curta (SWIR) com *pixels* de 10 a 60 m no solo.



Fonte: Modificado de (ESA, 2015).

Apesar das vantagens, o uso de imagens de satélite enfrenta diversos desafios que podem afetar a qualidade e a precisão dos resultados. No caso do Sentinel-2, muitos desses desafios são mitigados pelas características do próprio satélite e pelos processos de pré-processamento já aplicados aos dados.

1. Correção Radiométrica: O Sentinel-2 fornece produtos já calibrados radiometricamente, permitindo que as imagens sejam comparáveis e consistentes (HEDLEY et al., 2018a). Isso é essencial para análises multitemporais e para garantir a precisão na detecção de mudanças ao longo do tempo. A correção radiométrica aplicada aos produtos de nível 1C e 2A assegura que as variações de radiância devido a condições atmosféricas e ângulo solar sejam minimizadas.
2. Correção Geométrica: As imagens do Sentinel-2 são ortorretificadas e georreferenciadas, corrigindo distorções geométricas causadas pela posição do satélite, topografia e movimentação da plataforma (HEDLEY et al., 2018a). Isso assegura que os elementos mapeados correspondam precisamente às suas localizações reais, facilitando a integração com outros dados geoespaciais e a validação com pontos de controle em campo.
3. Remoção de Brilho Solar (*Sunglint*): Embora o *sunglint* seja um desafio comum em imagens de superfícies aquáticas, o Sentinel-2 inclui bandas que permitem a detecção e mitigação desse efeito. Técnicas de remoção de *sunglint* podem ser aplicadas utilizando as bandas disponíveis, melhorando a visibilidade do fundo marinho (HEDLEY; HARBORNE; MUMBY, 2005). Por exemplo, a aplicação de modelos de regressão linear entre bandas com diferentes sensibilidades ao *sunglint* pode reduzir significativamente esse efeito (EUGENIO; MARCELLO; MARTIN, 2015; MARTIN et al., 2016).
4. Mascaramento: O Sentinel-2 fornece máscaras de nuvens e sombras de nuvens como parte de seus produtos de nível 1C e 2A, auxiliando na exclusão de áreas não relevantes ou que podem introduzir erros na classificação (HEDLEY et al., 2018a; EBEL et al., 2021). Além disso, as bandas específicas para detecção de vapor d'água e cirros facilitam o mascaramento de interferências atmosféricas. O uso dessas máscaras melhora a precisão na classificação dos habitats bentônicos ao remover *pixels* afetados por nuvens e sombras.
5. Dispersão da Luz (*Light Scattering*): A dispersão da luz na atmosfera e na coluna d'água pode alterar a reflectância observada pelo sensor. O Sentinel-2, com suas bandas espectrais adequadas, permite a aplicação de modelos de correção atmosférica e da coluna d'água, como os propostos por Lyzenga (ZOFFOLI; FROUIN; KAMPEL, 2014). Esses modelos ajustam a reflectância observada, considerando a atenuação da luz devido à absorção e espalhamento, melhorando a precisão no mapeamento bentônico.
6. Penetração da Água e Heterogeneidade Bentônica: A penetração da luz diminui com a profundidade e varia conforme o comprimento de onda. As bandas no espectro

azul-verde do Sentinel-2 penetram mais profundamente na água, sendo úteis para mapeamento de áreas submersas (LI et al., 2020). Contudo, a heterogeneidade do habitat bentônico e variações na profundidade podem introduzir confusão espectral, dificultando a distinção entre diferentes classes de substrato (HEDLEY et al., 2012; WICAKSONO; ARYAGUNA, 2020). O uso de algoritmos de classificação robustos e a aplicação de correções da coluna d'água ajudam a mitigar esses efeitos (MUMBY et al., 1998; ZOFFOLI; FROUIN; KAMPEL, 2014).

7. Nuvens e Sombras de Nuvens: A presença de nuvens é um dos principais desafios no uso de imagens ópticas de satélite. O Sentinel-2, além de possuir bandas específicas para detecção de nuvens, oferece uma alta frequência de revisita, permitindo a composição de imagens livres de nuvens a partir de múltiplas datas (ZHU; WOODCOCK, 2012; QIU; ZHU; HE, 2019). Algoritmos como o Fmask são utilizados para detectar e mascarar áreas cobertas por nuvens e suas sombras, melhorando a qualidade das imagens para análise (HUGHES; HAYES, 2014; MAGNO et al., 2021).
8. API para *Download* de Dados: O acesso aos dados do Sentinel-2 é facilitado por meio de APIs, como o Copernicus Open Access Hub e o Sentinel Hub, que permitem a busca, filtragem e *download* automatizado de imagens (HEDLEY et al., 2018a). Essas plataformas oferecem serviços de processamento em nuvem, agilizando a obtenção de dados atualizados e personalizados conforme os critérios do pesquisador, como área de interesse, datas específicas e nível de processamento.

O Sentinel-2 disponibiliza produtos pré-processados em diferentes níveis:

1. Nível 1C: Imagens ortorretificadas, georreferenciadas e com correção radiométrica aplicada. Inclui máscaras de nuvens e informações de qualidade dos dados.
2. Nível 2A: Além das correções do nível 1C, aplica correção atmosférica para fornecer reflectância de superfície, considerando a influência da atmosfera na radiância medida pelo sensor (GORDON, 1978; MOGRANE et al., 2019). A correção atmosférica é essencial para reduzir os efeitos de dispersão e absorção atmosférica, especialmente em análises multitemporais e comparações entre diferentes regiões.

Essas correções facilitam o processamento posterior das imagens, reduzindo a necessidade de aplicar correções complexas e permitindo que os pesquisadores se concentrem na análise e classificação dos habitats bentônicos. Contudo, é importante notar que, apesar das correções aplicadas, a precisão final do mapeamento depende da aplicação adequada de algoritmos de classificação e da validação com dados de campo (LIN et al., 2015). A heterogeneidade do fundo marinho e as variações nas condições ambientais ainda podem introduzir desafios que requerem abordagens específicas.

No caso de águas rasas, a interpretação de imagens ópticas exige cautela adicional, pois a reflectância registrada pelo satélite não representa apenas o fundo marinho. Ela resulta da interação entre iluminação solar, atmosfera, superfície da água, profundidade, turbidez, material em suspensão e propriedades ópticas do substrato (CABALLERO; STUMPF, 2023; KUTSER et al., 2020). Por isso, mesmo quando o Sentinel-2 oferece resolução espacial e temporal adequada, a separação entre classes sedimentares depende de protocolos de curadoria, controle de qualidade e validação que reduzam o risco de associar artefatos atmosféricos, efeitos da coluna d'água ou autocorrelação espacial ao desempenho do classificador.

Essa limitação é particularmente relevante na Margem Equatorial Brasileira. A influência da pluma amazônica e a elevada variabilidade da turbidez tornam o sinal óptico do fundo mais frágil do que em ambientes tropicais claros, frequentemente usados como referência em aplicações de mapeamento bentônico com Sentinel-2 (CABALLERO; STUMPF, 2023; HEDLEY et al., 2018b; POURSANIDIS et al., 2019). Assim, nesta tese, o uso do Sentinel-2 não é tratado como substituto direto de levantamentos sedimentológicos ou acústicos, mas como uma fonte complementar, de baixo custo e alta cobertura, cuja utilidade depende de curadoria conservadora, restrição batimétrica, avaliação de sensibilidade espectral e validação espacial independente.


2.4 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são sistemas computacionais com inspiração no sistema nervoso de seres vivos e que adquirem conhecimento através da experiência. Os neurônios artificiais são interligados por sinapses artificiais representadas por vetores de peso sináptico (HAYKIN, 2007). As RNAs solucionam diversos problemas que necessitam de alto processamento de dados. Os principais problemas que as RNAs podem resolver são classificação de padrões, aproximação de funções, reconhecimento de fala, visão computacional e processamento de texto.

2.4.1 Neurônio

O sistema nervoso possui um conjunto complexo de células, por exemplo, os neurônios biológicos responsáveis pelo funcionamento e comportamento do corpo e da mente. O neurônio biológico é uma célula dividida em 3 partes distintas: os dendritos responsáveis por receber informações, o corpo celular responsável por armazenar as informações e o axônio responsável por enviar as informações para os próximos neurônios (AZEVEDO, 2016). A figura 4 abaixo ilustra um neurônio biológico.


Figura 4 – Estrutura básica de um neurônio biológico.



Fonte: Retirado de (AZEVEDO, 2016).

De forma análoga, o neurônio artificial (apresentado na figura 5) possui funcionamento semelhante ao neurônio biológico, sendo a unidade de processamento fundamental para a operação de uma Rede Neural Artificial com inspiração em um neurônio biológico, é composto pelos seguintes elementos: conjunto de entradas, somador e função de ativação (HAYKIN, 2007).

Figura 5 – Neurônio Artificial.




Fonte: Retirado de (HAYKIN, 2007).

2.4.2 Perceptron

Segundo Silva, Spatti e Flauzino (2016) o *Perceptron* é a configuração de RNA mais simples, pois é constituído por apenas uma camada e tem apenas um neurônio nela. Tinha como aplicação, inicialmente, identificar padrões geométricos.


Só consegue classificar padrões com apenas duas classes linearmente separáveis, exemplo figura 6, sendo utilizada para classificação de itens linearmente separáveis, padrões que se encontram em lados opostos por um hiperplano (HAYKIN, 2007).

Figura 6 – Fronteira de decisão de um problema linearmente separável.



Fonte: Retirado de (HAYKIN, 2007).

A Figura 7 apresenta a estrutura de uma RNA do tipo *Perceptron* com n entradas e uma única saída.

Figura 7 – Rede Neural Artificial *Perceptron*.

Fonte: Retirado de (SILVA; SPATTI; FLAUZINO, 2016).

As entradas (x) são ponderadas pelos seus respectivos pesos sinápticos (w) e combinados (somatório), tendo como valor agregado o *bias* (θ) necessário para ativação do neurônio. Por último, temos a função de ativação, $g(\cdot)$, delimitando o intervalo de saída (y) do neurônio (SILVA; SPATTI; FLAUZINO, 2016).

O funcionamento do neurônio ocorre matematicamente por meio da aplicação das Equações 2.1 e 2.2:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$


Onde $x_1, x_2, \dots, x_m$ são os sinais de entrada, $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k e y_k é a saída do neurônio. A saída do neurônio é definida através da função de ativação $g(\cdot)$ (SILVA; SPATTI; FLAUZINO, 2016).

O *Perceptron* utiliza o treinamento supervisionado para ajuste dos pesos e limiar, ou seja, para cada amostra dos sinais de entrada se tem a respectiva saída desejada (HAYKIN, 2007).

2.4.3 *Perceptron* de Múltiplas Camadas

Enquanto o *Perceptron* simples só tem uma camada neural, o *Multilayer Perceptron* (MLP) tem, pelo menos, uma camada oculta entre as camadas de entrada e saída da rede (SILVA; SPATTI; FLAUZINO, 2016). Na figura 8 podemos observar as camadas ocultas que permite o aprendizado de tarefas mais complexas, como, por exemplo, o problema do OU Exclusivo segundo Haykin (2007), tratando classes que não são linearmente separáveis.

Figura 8 – Rede Neural Artificial MLP.



Fonte: (SILVA; SPATTI; FLAUZINO, 2016).

A arquitetura da MLP é organizada em três ou mais camadas: camada de entrada, camadas ocultas e camada de saída. A camada de entrada é responsável por propagar as entradas da rede para todos os neurônios da camada seguinte. As camadas ocultas estão localizadas entre a camada de entrada e saída, onde cada neurônio desta camada se comporta como um *Perceptron* simples com saída conectada na entrada dos neurônios da camada seguinte. E a camada de saída é onde os neurônios processadores estão presentes para classificação (SILVA; SPATTI; FLAUZINO, 2016).

Entre as camadas de entrada e saída, uma ou mais camadas ocultas são normalmente conectadas por matrizes de peso, *bias* e várias funções de ativação. Essas

redes neurais possuem um poder computacional aplicadas em diversos tipos de problemas em diferentes áreas do conhecimento, sendo consideradas uma das arquiteturas mais versáteis quanto à aplicabilidade (HAYKIN, 2007).

Na MLP, os nós são conectados diretamente na camada seguinte, de forma que os sinais seguem um fluxo da entrada até a saída, conhecidas como redes do tipo *feedforward* (AZEVEDO, 2016). Neste caso, o fluxo de informações inicia na camada de entrada, passa pelas camadas intermediárias e finaliza na camada neural de saída, e não existe realimentação de informações entre as camadas na rede convencional (SILVA; SPATTI; FLAUZINO, 2016).

2.4.4 Aprendizado das Redes Neurais Artificiais

O treinamento (fase de aprendizado) da RNA, é a etapa onde ocorrem os ajustes dos pesos sinápticos para melhorar o desempenho da rede (HAYKIN, 2007). O aprendizado pode ocorrer de duas formas, supervisionada ou não supervisionada.

O treinamento não supervisionado não possui saída desejada, normalmente, apresenta apenas um único neurônio na camada de saída que envia uma resposta. No aprendizado supervisionado já são conhecidas as saídas desejadas e o treinamento é realizado através da diferença da resposta desejada e a resposta observada na saída da RNA. Essa diferença (erro) vai para o algoritmo de ajuste dos pesos minimizando o erro na próxima iteração (CHAVES, 2019). O algoritmo mais utilizado de propagação de erro é o *backpropagation*.

A etapa de *backpropagation* é o treinamento realizado dentro da rede MLP, consistindo em um método útil no tratamento de informações não linearmente separáveis. Seu funcionamento consiste em duas fases distintas, a propagação (*foward*) e a retropropagação (*backpropagation*). Diferente da fase *foward* na fase do *backpropagation* acontece a atualização dos pesos sinápticos dos neurônios (SILVA; SPATTI; FLAUZINO, 2016). Então, o erro atual é propagado de volta para uma camada anterior, calculando a função de perda. Assim, os gradientes tendem a se tornar menores à medida que o cálculo é estabelecido a cada neurônio, retrocedendo na rede. Dessa forma, os neurônios nas camadas anteriores aprendem de forma muito lenta e o processo de treinamento leva muito mais tempo enquanto a precisão do modelo diminui. Sendo um problema crítico desse tipo de algoritmo (LE et al., 2019). O tempo de treinamento depende da taxa de atualização dos pesos. Se a taxa de atualização dos pesos for muito baixa o algoritmo demora para convergir; no entanto, se ela for alta converge rápido, podendo ficar instável com outras entradas (HAYKIN, 2007).

2.5 Redes Neurais Convolucionais - RNC

As Redes Neurais Convolucionais (RNCs) são uma arquitetura de Redes Neurais Artificiais (RNAs), derivadas do *Multilayer Perceptron* (MLP). Inspiradas no processamento biológico de dados visuais, as RNCs são amplamente utilizadas em tarefas de detecção, classificação e reconhecimento de padrões, especialmente em imagens e vídeos (CHAVES, 2019; ALBAWI; MOHAMMED; AL-ZAWI, 2017). Como o próprio nome sugere, essas redes utilizam a operação matemática de convolução, que as diferencia das RNAs tradicionais baseadas exclusivamente em multiplicações matriciais (GOODFELLOW; BENGIO; COURVILLE, 2016).

O termo *Deep Learning* refere-se a RNAs profundas, com múltiplas camadas densas. Ao longo das últimas décadas, essa abordagem tem se destacado como uma das mais poderosas ferramentas para lidar com grandes volumes de dados, superando métodos clássicos em diversos campos, como visão computacional e processamento de linguagem natural (NLP) (ALBAWI; MOHAMMED; AL-ZAWI, 2017). Nesse contexto, as RNCs se tornaram uma das arquiteturas mais populares de aprendizado profundo, com aplicações que incluem desde classificação de imagens em grandes conjuntos de dados, como o ImageNet, até tarefas avançadas de reconhecimento de padrões (ALBAWI; MOHAMMED; AL-ZAWI, 2017; DSA, 2022).

As RNCs possuem vantagens significativas em relação às RNAs tradicionais. Enquanto as RNAs tratam todos os *pixels* de entrada de maneira uniforme, as RNCs exploram as correlações espaciais entre os *pixels*, o que as torna mais eficazes na análise de dados matriciais, como séries temporais (1-D), imagens (2-D) e vídeos (3-D) (DSA, 2022). Além disso, essas redes possuem uma arquitetura especialmente adaptada para a classificação de imagens, o que as torna mais rápidas de treinar e altamente precisas (ALBAWI; MOHAMMED; AL-ZAWI, 2017; GU et al., 2018).


A arquitetura básica das RNCs consiste em três tipos de camadas principais: a camada convolucional (*convolutional layer*), a camada de agrupamento (*pooling layer*) e a camada totalmente conectada (*fully-connected layer*) (GU et al., 2018). Essas camadas trabalham de maneira intercalada, aumentando a complexidade da rede à medida que os dados avançam por cada estágio, permitindo a identificação de características simples nas primeiras camadas, como bordas e cores, e elementos mais complexos nas camadas finais.

Na Figura 9, pode-se observar os componentes básicos de uma RNC, incluindo as principais etapas do processamento.

Hoje, as RNCs, ou suas variantes, são amplamente utilizadas em redes neurais voltadas para reconhecimento de imagens, consolidando-se como uma ferramenta essencial em aprendizado profundo (ALBAWI; MOHAMMED; AL-ZAWI, 2017; GU et al., 2018).

Apesar dessa relevância, o uso de RNCs em sensoriamento remoto costeiro

Figura 9 – Arquitetura básica de uma RNC. A rede convolucional é formada por diversas camadas convolucionais, que aplica uma função matemática de convolução nos dados de entrada e depois realizar o agrupamento (*pooling*). Em seguida os dados são vetorizados e são enviados até chegar na última camada conhecida como camada Densa e totalmente conectada.



Fonte: (MURUGAN, 2017)

não garante, por si só, desempenho superior. Em bases amostrais limitadas, com forte autocorrelação espacial ou com rótulos históricos heterogêneos, arquiteturas profundas podem aprender padrões locais, texturas ou condições ópticas específicas dos recortes, sem necessariamente generalizar melhor para áreas geograficamente independentes. Por esse motivo, a comparação entre modelos profundos e modelos leves deve considerar não apenas acurácia média, mas também estabilidade entre partições, custo computacional, sensibilidade ao desbalanceamento e protocolo de validação. Essa distinção é central para esta tese, na qual modelos baseados em PCA e classificadores leves são avaliados como alternativa operacional às arquiteturas convolucionais.

2.5.1 Camada convolucional

As camadas convolucionais utilizam filtros, também conhecidos como núcleos convolucionais (*convolutional kernels*), para extrair características da imagem de entrada.

Os dados de imagem são representados como uma matriz, onde cada elemento corresponde ao valor de um *pixel* na imagem. As linhas e colunas da matriz da imagem representam a altura e a largura da imagem, enquanto cada elemento indica a intensidade ou informação de cor do *pixel* na posição correspondente. O núcleo de convolução também é uma pequena matriz. Portanto, aplicar a convolução em dados de imagem envolve calcular a convolução entre o núcleo convolucional e a matriz da imagem.


O núcleo de convolução pode ser considerado como uma pequena matriz de pesos, e a convolução consiste em deslizar o núcleo sobre a matriz de entrada. Em cada posição, os elementos do núcleo convolucional são multiplicados pelos elementos correspondentes da matriz de entrada, e os resultados são somados para obter um único elemento da matriz de saída. A Figura 10 apresenta um exemplo de convolução 2D com

um núcleo de tamanho $k \times l$. O valor de um único elemento na matriz de saída é calculado pela Equação 2.3:

$$y_{m,n} = \sum_{s=1}^l \sum_{t=1}^k w_{st} v_{i+s-1,j+t-1} \quad (2.3)$$

onde $y_{m,n}$ é o valor de um único elemento na matriz de saída, $v_{i+s-1,j+t-1}$ é o valor de um único elemento na matriz de entrada, e w_{kl} é o valor do peso de um único elemento no núcleo convolucional.

Figura 10 – Convolução 2D com um núcleo de tamanho 3×3 . O núcleo convolucional 3×3 desliza sobre a matriz da imagem para gerar a matriz de saída.



Fonte: Autor.

O cálculo descrito na Equação 2.3 corresponde a um único núcleo convolucional 2D. No entanto, em uma camada convolucional, múltiplos núcleos podem ser utilizados, e cada núcleo gera um canal de mapas de características. Assim, o número de núcleos convolucionais é igual ao número de canais de saída.

Em diferentes aplicações, podem ser utilizados núcleos convolucionais de diferentes tamanhos, tipos e quantidades. O tipo da camada convolucional está relacionado ao núcleo convolucional utilizado. Uma camada convolucional 1D emprega núcleos convolucionais 1D, que deslizam ao longo de uma única dimensão da entrada. De forma semelhante, em camadas convolucionais 2D, núcleos convolucionais 2D deslizam ao longo de duas dimensões da entrada. Já em camadas convolucionais 3D, núcleos convolucionais 3D são empregados e deslizam ao longo de três dimensões da entrada.


Além do tamanho, tipo e número de núcleos convolucionais, outro parâmetro importante da camada convolucional é o *stride*. *Stride* refere-se ao tamanho do passo quando o núcleo convolucional desliza sobre os dados de entrada. Esse parâmetro influencia o tamanho do mapa de características de saída.

2.5.2 Camadas de *Pooling* (Camada de agrupamento).

A principal função da camada de agrupamento (*pooling layer*) é reduzir as dimensões dos dados de entrada, preservando as informações mais importantes. As duas camadas de agrupamento mais comumente usadas são o *max pooling* e o *average pooling*. (GHOLAMALINEZHAD; KHOSRAVI, 2020) fornece uma visão geral sobre os diferentes tipos de camadas de agrupamento.

O *max pooling* seleciona o valor máximo dentro de uma região, preservando assim as características mais dominantes. Por outro lado, o *average pooling* calcula a média dos valores dentro de uma região, o que ajuda a reduzir o ruído. A Figura 11 apresenta um exemplo de *average pooling* e *max pooling*, onde, para regiões de diferentes cores, o *average pooling* retém o valor médio dentro dessas regiões e o *max pooling* o valor máximo dentro dessas regiões. Assim como nas camadas convolucionais, para as camadas de agrupamento, também é necessário escolher o tipo de agrupamento (2D ou 3D), o tamanho do núcleo de agrupamento e o *stride*.

Figura 11 – Exemplo de *Average Pooling* e *Max Pooling*.



Fonte: Autor.

Outro tipo de camada de agrupamento amplamente utilizado é o *adaptive average pooling*. Diferentemente do *average pooling*, o *adaptive average pooling* ajusta automaticamente o tamanho do núcleo de agrupamento com base nas dimensões de entrada e na dimensão de saída desejada, em vez de usar um tamanho de janela fixo. Ao utilizá-lo, basta especificar o tamanho da saída desejada.

2.5.3 Funções de ativação

A função de ativação é um componente importante em redes neurais, servindo para introduzir características não lineares que permitem à rede aprender e representar relações não lineares complexas.

As principais funções de ativação incluem: a função Sigmoide, a função Tanh, a função ReLU, e a função Softmax.

A função Sigmoide mapeia a entrada para um intervalo entre 0 e 1, sendo frequentemente usada em problemas de classificação binária. A expressão matemática é:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.4)$$

A função Tanh é semelhante à Sigmoide, mas seu intervalo de saída está entre $[-1, 1]$. A expressão matemática é:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

A ReLU é uma função de ativação simples e amplamente utilizada. Para um valor de entrada x , a saída é x se $x > 0$, caso contrário, a saída é zero:

$$f(x) = \max(0, x) \quad (2.6)$$

A função Softmax é amplamente utilizada para problemas de classificação multiclasse, mapeando os valores de entrada para uma distribuição de probabilidades. Suponha que temos n classes, a função Softmax é representada por:

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2.7)$$

2.5.4 Batch Normalization

Batch normalization (IOFFE; SZEGEDY, 2015a) e *layer normalization* (BA; KIROU; HINTON, 2016) são técnicas de normalização usadas em redes neurais para acelerar o processo de treinamento e reduzir o *overfitting* (XU et al., 2019). *Batch normalization* é comumente usada em RNC, enquanto *layer normalization* é frequentemente empregada em redes neurais recorrentes (RNNs) e modelos baseados em autoatenção, como o Transformer. O efeito da *batch normalization* depende do tamanho do *batch*. Para RNNs e alguns modelos baseados em autoatenção, os comprimentos das sequências de entrada podem variar ou o tamanho do *batch* pode ser pequeno. Assim, a *layer normalization*, que não depende do tamanho do *batch* e pode lidar com sequências de comprimento variável, é uma escolha melhor (BA; KIROU; HINTON, 2016).

Batch normalization normaliza cada característica entre todas as amostras em um *batch* de treinamento, enquanto *layer normalization* normaliza cada amostra individualmente em todas as características.

Ambas as normalizações são calculadas como segue:

$$y_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \epsilon}} \cdot \gamma + \beta \quad (2.8)$$

onde x_i é o valor de entrada, y_i é o valor normalizado, μ é a média, σ^2 é a variância, γ é o parâmetro de escala, β é o parâmetro de deslocamento e ϵ é um pequeno número positivo adicionado ao denominador para evitar divisão por zero.

Na *batch normalization*, a média e a variância para cada característica são calculadas com base em todas as amostras nos *mini-batches*. Na *layer normalization*, a média e a variância são calculadas com base em todas as características para cada amostra individual.

2.5.5 Training Process

No treinamento de redes neurais, o modelo ajusta continuamente seus parâmetros para minimizar uma função de perda, buscando melhorar seu desempenho. Para isso, algoritmos de otimização são usados, atualizando os parâmetros do modelo com base nos gradientes da função de perda, calculados por retropropagação (WERBOS, 1990). O processo de treinamento envolve ajustes iterativos para que o modelo extraia padrões e características dos dados de entrada, reduzindo o valor da função de perda e melhorando sua precisão.

2.5.6 Função de perda

A função de perda mede as diferenças entre as previsões do modelo e os rótulos verdadeiros. Para tarefas de classificação multiclasse, a função de perda de entropia cruzada (*Cross-Entropy*) é definida como:

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (2.9)$$

onde $p(x)$ é a distribuição verdadeira e $q(x)$ é a distribuição prevista pelo modelo.

Nos algoritmos de aprendizado de máquina, para tarefas de classificação multiclasse, a função de perda de entropia cruzada (*Cross-Entropy*) é definida como:

$$L = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^m y_{ij} \log \hat{y}_{ij} \quad (2.10)$$

onde n é o número total de amostras de treinamento, que, em tarefas de processamento de imagens, corresponde ao número total de *pixels* em um lote de treinamento; m é o número de classes; y_{ij} é igual a 0 ou 1, indicando se a amostra i pertence à classe j ; e $\hat{y}_{ij}$ é a saída do modelo, ou seja, a probabilidade prevista pelo modelo de que a amostra i pertença à classe j .

2.5.7 Otimização

Em aprendizado de máquina, o problema de otimização refere-se ao processo de ajustar os parâmetros do modelo para minimizar a função de perda, que é definida na Equação 2.11. Por meio da busca de combinações adequadas de parâmetros, o modelo pode ajustar-se melhor aos dados.

$$\theta = \arg \min_{\theta} L(\theta) \quad (2.11)$$

onde $L(\theta)$ é a função de perda, e θ representa o conjunto de parâmetros do modelo.

Um método de otimização comum no aprendizado de máquina é o *gradient descent* (descida do gradiente). O método consiste em calcular o gradiente da função de perda em relação aos parâmetros e, em seguida, atualizar os parâmetros na direção que reduz a perda. Esse processo é iterado continuamente até que uma condição de parada seja atendida. A Equação 2.12 representa uma iteração no método de descida do gradiente:

$$\theta' = \theta - \alpha \nabla L(\theta) \quad (2.12)$$

onde θ representa os parâmetros atuais, θ' são os parâmetros atualizados, $L(\theta)$ é a função de perda, e α é a taxa de aprendizado, que indica o tamanho do passo de cada atualização em cada iteração.

3 MATERIAIS E MÉTODOS


Este capítulo apresenta os materiais utilizados e os procedimentos metodológicos adotados para a classificação e o mapeamento de sedimentos marinhos superficiais na Margem Equatorial Brasileira (MEB), a partir da integração entre dados sedimentológicos históricos, imagens multiespectrais do satélite Sentinel-2 e algoritmos de aprendizado de máquina.

A pesquisa caracteriza-se como exploratória, descritiva e aplicada, com abordagem predominantemente quantitativa. A metodologia foi estruturada de forma a contemplar a definição da área de estudo, a construção e curadoria do acervo sedimentológico, a aquisição e o pré-processamento das imagens Sentinel-2, a seleção espacial das amostras, a representação espectral dos recortes, a redução de dimensionalidade, a modelagem supervisionada, a validação espacial, a análise de sensibilidade e a geração de mapas exploratórios de distribuição sedimentar.

3.1 Área de estudo e base de dados sedimentológicos

A área de estudo abrange a plataforma continental da Margem Equatorial Brasileira (MEB), incluindo as bacias sedimentares da Foz do Amazonas, Pará-Maranhão, Barreirinhas, Ceará e Potiguar. Para ampliar a base amostral, também foram considerados registros da Bacia Pernambuco-Paraíba, adjacente à Bacia Potiguar. Cabe destacar que a MEB constitui a principal área de análise deste estudo, enquanto a inclusão da Bacia Pernambuco-Paraíba teve papel complementar, com o objetivo específico de ampliar a representatividade amostral em uma bacia vizinha à Potiguar. A Figura 12 apresenta as bacias sedimentares que compõem a região.

Figura 12 – Bacias sedimentares da Margem Equatorial Brasileira.




Fonte: Elaborado pelo autor.

A MEB possui elevada relevância econômica, ecológica e estratégica para o Brasil, sendo caracterizada por alta produtividade, intensa atividade pesqueira, presença de infraestrutura portuária nas cidades de São Luís, Belém e Macapá, e crescente interesse associado à exploração de hidrocarbonetos (ARAUJO et al., 2021). A dinâmica costeira da região é fortemente condicionada pela Corrente Norte do Brasil, pela pluma do Rio Amazonas, por um regime macromareal com amplitudes que podem superar 11 m e por grande aporte de sedimentos fluviais (ARAUJO et al., 2021; ASSAD et al., 2020). A combinação desses fatores resulta em um mosaico bentônico complexo, com expressiva variabilidade espacial na distribuição dos sedimentos superficiais.

A base sedimentológica utilizada neste estudo foi construída a partir da integração de um acervo histórico de amostras de fundo e imagens de satélite, evitando redundâncias entre as etapas de seleção. O conjunto inicial compreendeu 5.515 registros sedimentológicos das bacias da MEB e da Bacia Pernambuco-Paraíba, coletados entre 1956 e 2004 e obtidos em fontes públicas, como o Banco Nacional de Dados Oceanográficos (BNDO) e o Banco de Dados de Exploração e Produção (BDEP) da Agência Nacional do Petróleo (ANP).

O conhecimento sedimentológico associado a esse acervo tem origem em levantamentos clássicos, como o Projeto REMAC (KOWSMANN; COSTA, 1979), e sua organização seguiu estratégias compatíveis com estudos recentes de mapeamento regional (FILHO et al., 2025a). A Figura 13 apresenta a distribuição espacial dos registros históricos utilizados.

Figura 13 – Distribuição espacial dos 5.515 registros sedimentológicos históricos (1956–2004) utilizados no estudo, cobrindo a Margem Equatorial Brasileira e registros complementares da Bacia Pernambuco-Paraíba.



Fonte: Elaborado pelo autor.

Esse acervo reúne descrições visuais do fundo marinho e resultados de análises laboratoriais. As descrições visuais, frequentemente associadas a levantamentos hidrográficos, apresentam variabilidade terminológica e dependem do contexto de coleta e do observador. As análises laboratoriais, por sua vez, fornecem maior confiabilidade granu-

lométrica, embora também possam refletir diferenças metodológicas entre campanhas, laboratórios e períodos de aquisição.

3.2 Padronização das classes sedimentológicas

Para integrar registros de origens distintas, adotou-se uma padronização granulométrica simplificada inspirada no diagrama ternário de Shepard (SHEPARD, 1954), agrupando os sedimentos em três classes principais: areia, lama e cascalho. Para amostras com dados laboratoriais, a classe foi definida pela fração granulométrica dominante:


- **Lama:** teor de lama maior ou igual a 50%;
- **Areia:** teor de areia maior ou igual a 50%;
- **Cascalho:** teor de cascalho maior ou igual a 50%.

O conteúdo de carbonato de cálcio foi mantido como informação sedimentológica complementar, a partir da classificação de Larssonneur adaptada por Dias, distinguindo sedimentos litoclásticos, litobioclásticos, biolitoclásticos e bioclásticos. Embora essa variável não tenha sido utilizada como alvo principal da modelagem final, ela auxiliou na caracterização geológica do acervo e na interpretação dos domínios mapeados.

3.3 Fluxo metodológico

O fluxo metodológico da pesquisa é apresentado na Figura 14. O processo inclui: aquisição do acervo histórico; filtragem batimétrica; aquisição das imagens Sentinel-2 com critério automático de nuvens; inspeção visual de qualidade; curadoria conservadora baseada em consistência granulométrica histórica, concordância espacial local e restrição explícita de não sobreposição entre recortes; particionamento espacial por blocos; definição do bloco profundo (arquiteturas baseadas em imagem) e do bloco clássico (modelos leves sobre atributos reduzidos por PCA); treinamento e avaliação sob validação espacial por blocos de 25 km com cinco *folds*; redefinição do escopo preditivo para o cenário binário Areia vs. Lama após diagnóstico da inviabilidade amostral da classe Cascalho; e, por fim, geração de mapas exploratórios compatíveis com o escopo final.

Figura 14 – Fluxo de construção da base de dados: pré-processamento batimétrico do acervo histórico, aquisição de imagens Sentinel-2, controle visual de qualidade, curadoria conservadora baseada em consistência granulométrica e espacial, restrição de não sobreposição entre recortes, particionamento espacial, amostragem espectral, PCA e definição do escopo final binário Areia vs. Lama.



Fonte: Elaborado pelo autor.

3.4 Pré-processamento dos dados históricos


O pré-processamento dos registros históricos foi realizado antes da aquisição das imagens. Inicialmente, aplicou-se um filtro batimétrico, retraindo registros com profundidade maior ou igual a -30 m. Esse limite foi adotado para maximizar a cobertura amostral sem extrapolar excessivamente a faixa de aplicabilidade dos métodos ópticos. Após essa etapa, o conjunto elegível para inspeção visual e curadoria compreendeu 3.647 registros.

Embora o limite de 30 m exceda a faixa frequentemente adotada como referência para mapeamento óptico do fundo marinho (KUTSER et al., 2020), estudos com modelos físicos aplicados a imagens Sentinel-2 demonstram a possibilidade de estimativas batimétricas nessa profundidade sob condições adequadas (HEDLEY et al., 2018b). A integração entre dados sedimentológicos históricos (1956–2004) e imagens recentes (2017–2024) foi tratada como uma hipótese operacional plausível em escala cartográfica, e não como uma condição empiricamente demonstrada para todos os pontos. Estudos clássicos indicam intenso retrabalhamento físico na plataforma interna, favorecendo a persistência de fácies

dominantes em escala decadal (KUEHL; DEMASTER; NITTROUER, 1986); essa persistência é compatível com padrões granulométricos regionais descritos em levantamentos posteriores (APRILE et al., 2019). Ainda assim, essa premissa não substitui validação moderna *in situ* independente, nem elimina a possibilidade de alterações locais ao longo do tempo associadas a retrabalhamento sedimentar, dinâmica costeira e interferência antrópica.

A Figura 15 resume a composição do acervo após o pré-processamento batimétrico, destacando a predominância de areia nas porções mais rasas e a maior ocorrência relativa de cascalho e lama abaixo de 20 m. Para as classes menos representadas, os ganhos amostrais tornam-se progressivamente menores nas maiores profundidades do intervalo, de modo que o limite de -30 m foi identificado como o patamar a partir do qual as contribuições incrementais de cada classe passam a ser residuais, justificando sua adoção como limite operacional do estudo.

Figura 15 – Distribuição acumulada das amostras por classe sedimentológica, de 0 a -30 m, após o pré-processamento batimétrico.



Fonte: Elaborado pelo autor.

3.5 Aquisição e pré-processamento das imagens Sentinel-2

Somente após o pré-processamento do acervo sedimentológico foi realizada a aquisição das imagens. Para cada um dos 3.647 registros elegíveis, foram obtidas imagens Sentinel-2 Nível 2A, correspondentes à reflectância de superfície, por meio da API do SentinelHub, cobrindo o período de 2017 a 2024. Como critério automático de pré-seleção, adotou-se cobertura de nuvens inferior a 10%, priorizando cenas com maior utilidade óptica (KUTSER et al., 2020).

O uso de produtos de reflectância de superfície reduz parte dos efeitos atmosféricos, mas não elimina as incertezas associadas à propagação da luz na coluna d'água, à turbidez, ao *sun glint* e à mistura entre resposta da água e do fundo (CABALLERO; STUMPF, 2023; HEDLEY et al., 2018b; KUTSER et al., 2020). Por essa razão, a etapa de aquisição não foi tratada como garantia automática de qualidade óptica: ela foi seguida

por inspeção visual, curadoria conservadora dos rótulos, avaliação de diferentes conjuntos espectrais e validação espacial independente.

Para cada par sedimento–imagem, foi extraído um recorte de 96×96 *pixels*, em resolução de 10 m, centrado na coordenada da amostra sedimentológica. Cada recorte corresponde a uma área aproximada de 1 km², dimensão adotada para representar a heterogeneidade sedimentar local sem inviabilizar o processamento computacional.

O estudo avaliou sete conjuntos espectrais do Sentinel-2, apresentados na Tabela 1. Essa organização permitiu comparar desde um núcleo estritamente visível até configurações multiespectrais mais amplas, incluindo infravermelho próximo, bandas *Red-Edge*, SWIR e aerossol costeiro. A avaliação progressiva dos conjuntos espectrais visou investigar se bandas além do visível acrescentam informação discriminativa para separar areia e lama, sem assumir previamente que a expansão espectral seria sempre benéfica, uma vez que bandas reamostradas e fortemente afetadas pela absorção da água podem carregar tanto informação útil quanto ruído, dependendo da profundidade, da turbidez e do modelo utilizado.

Tabela 1 – Conjuntos espectrais avaliados e respectivas bandas Sentinel-2.

Conjunto	Bandas
RGB	B2, B3, B4
VIS+NIR	B2, B3, B4, B8
VIS+RE+NIR	B2, B3, B4, B5, B6, B7, B8, B8A
VIS+NIR+SWIR	B2, B3, B4, B8, B11, B12
VIS+NIR+SWIR+AC	B1, B2, B3, B4, B8, B11, B12
<i>Full</i> S2 sem AC	B2, B3, B4, B5, B6, B7, B8, B8A, B9, B10, B11, B12
<i>Full</i> S2	B1, B2, B3, B4, B5, B6, B7, B8, B8A, B9, B10, B11, B12

Fonte: Elaborado pelo autor.

As bandas com resolução nativa de 20 m e 60 m foram disponibilizadas em grade de 10 m pela API de processamento do SentinelHub, usando reamostragem por vizinho mais próximo. Como esse procedimento não adiciona detalhe espacial real e pode introduzir artefatos, as bandas extra-visíveis foram avaliadas empiricamente em configurações com e sem sua inclusão. Em seguida, os valores de reflectância de superfície foram normalizados pela divisão por 10.000, resultando em valores adimensionais no intervalo $[0, 1]$.


3.6 Controle visual de qualidade

Apesar do filtro automático de nuvens, diversos artefatos permaneceram nas cenas. Assim, foi realizada inspeção visual rigorosa para remover amostras comprometidas por quatro grupos principais de problemas, exemplificados na Figura 16:

- **Obstruções atmosféricas:** nuvens densas, cirrus residuais e sombras de nuvens projetadas sobre a superfície;

- **Interferências antropogênicas:** presença de embarcações, esteiras de turbulência e estruturas portuárias;
- **Contaminação por terra:** *pixels* mistos na interface terra-água não completamente removidos pela máscara de terra;
- **Artefatos do sensor e anomalias radiométricas:** falhas de varredura, bordas de faixa do satélite, falhas de processamento, reflexões especulares intensas (*sunlint*) e padrões de reflectância anômalos associados à turbidez extrema.

Figura 16 – Exemplos de amostras descartadas durante o controle visual de qualidade. O mosaico ilustra artefatos que passaram pelo filtro automático de nuvens ($< 10\%$), mas ainda comprometiam a classificação de sedimentos: (a) estrutura portuária, (b) nuvens residuais, (c) interface costeira, (d) embarcações e esteiras, (e) borda de varredura do sensor, (f) falha de processamento, (g) turbidez extrema ou reflectância anômala, e (h) *sunlint* ou anomalia cromática.



Fonte: Elaborado pelo autor.

A inspeção visual removeu 192 amostras com artefatos, reduzindo o conjunto elegível a 3.455 pontos. Essa etapa foi aplicada antes da modelagem supervisionada, evitando que imagens fisicamente comprometidas influenciassem a curadoria dos rótulos e a avaliação dos classificadores.

3.7 Curadoria conservadora dos rótulos e seleção espacial

A curadoria final do conjunto de dados foi realizada em quatro etapas. Após o filtro batimétrico, permaneceram 3.647 registros; a inspeção visual removeu 192 amostras, resultando em 3.455 pontos elegíveis. Sobre esse conjunto, aplicou-se um procedimento

conservador baseado nas proporções granulométricas históricas e na organização espacial local.

Para cada amostra i , as proporções disponíveis de areia, cascalho e lama foram normalizadas para somar 1. Seja $p_{\text{rotulo},i}$ a proporção associada ao rótulo histórico e pureza $_i$ a fração da classe dominante. Em paralelo, calculou-se a concordância espacial local A_i , medindo o suporte espacial do rótulo histórico com base nos $k = 14$ vizinhos mais próximos dentro de um raio $R = 14,07$ km:

$$A_i = \frac{\sum_{j \in \mathcal{N}_i} w_{ij} \mathbf{1}(y_j = y_i)}{\sum_{j \in \mathcal{N}_i} w_{ij}} \quad (3.1)$$

$$w_{ij} = \exp(-d_{ij}/\sigma) \mathbf{1}(d_{ij} \leq R) \quad (3.2)$$

em que $\mathcal{N}_i$ representa os vizinhos da amostra i , y_i e y_j são os rótulos históricos, d_{ij} é a distância entre amostras e $\sigma = 5,36$ km é o fator de decaimento. Na ausência de vizinhos no raio de busca, A_i assumiu a proporção empírica da classe correspondente.

Os limiares de descarte foram definidos de forma conservadora, com o objetivo de remover apenas os casos mais evidentemente inconsistentes, evitando redução excessiva das classes menos representadas no acervo histórico. Nesse sentido, a condição de incompatibilidade de alta pureza adotou pureza $_i \geq 0,699$, de modo a sinalizar contradições claras entre o rótulo histórico e a composição granulométrica dominante. Da mesma forma, os limiares de suporte granulométrico ($p_{\text{rotulo},i} < 0,471$) e de concordância espacial local ($A_i < 0,253$) foram escolhidos para descartar amostras com baixa consistência histórica e espacial, sem impor critérios excessivamente restritivos que pudessem penalizar desproporcionalmente as classes lama e cascalho, naturalmente mais escassas e com menor densidade amostral.

Uma amostra foi descartada quando atendia a pelo menos uma das seguintes condições:

- **Incompatibilidade de alta pureza:** o rótulo histórico diferia da classe dominante, e a classe dominante apresentava pureza $_i \geq 0,699$;
- **Baixo suporte granulométrico:** $p_{\text{rotulo},i} < 0,471$;
- **Baixa concordância espacial local:** $A_i < 0,253$.

Essa curadoria foi realizada antes do treinamento e sem acesso às representações espectrais utilizadas na modelagem, evitando circularidade entre seleção de dados e avaliação supervisionada. A etapa rejeitou 250 amostras (53 de areia, 96 de cascalho e 101 de lama), restando 3.205 candidatas.

Para ranquear a seleção espacial posterior, priorizando amostras com maior consistência, foi definido o escore S_i :

$$S_i = \begin{cases} 0,809 p_{\text{rotulo},i} + 0,191 A_i, & \text{se a composição granulométrica está disponível,} \\ A_i, & \text{caso contrário.} \end{cases} \quad (3.3)$$

A seleção espacial final utilizou um procedimento guloso para evitar sobreposição entre recortes de 96×96 *pixels* ($L_{\text{patch}} = 960$ m), priorizando amostras com maior S_i . Com base na distância de Chebyshev e uma margem fixa (*gap*) de 5,86%, adotou-se separação mínima efetiva de 1.016,25 m:

$$L_{\text{eff}} = L_{\text{patch}}(1 + \text{gap}) \quad (3.4)$$

O procedimento guloso priorizou amostras com maior S_i , de modo que, em situações de conflito de sobreposição entre candidatas próximas, aquelas com maior consistência histórica e espacial foram preservadas. Na prática, esse ordenamento tende a reduzir perdas desproporcionais entre classes menos representadas, para as quais a remoção de poucas amostras já pode afetar mais sensivelmente a composição do conjunto final.

Esse critério removeu 872 candidatas adicionais por conflito de sobreposição (784 de areia, 21 de cascalho e 67 de lama). O conjunto curado inicial reteve 2.333 amostras, distribuídas em 1.760 de areia, 134 de cascalho e 439 de lama.


3.8 Validação espacial por blocos

Para avaliar a capacidade de generalização em contexto geoespacial e reduzir o risco de vazamento associado à autocorrelação espacial, adotou-se validação espacial por blocos de 25 km com cinco *folds*. As coordenadas geográficas das amostras curadas foram convertidas para um sistema plano em metros, e cada amostra foi atribuída a um bloco espacial quadrado com lado de 25 km. Em seguida, cada bloco foi atribuído integralmente a apenas um *fold*, garantindo que amostras espacialmente próximas não fossem distribuídas simultaneamente entre treino e teste.

Em estágio diagnóstico, o particionamento por blocos foi aplicado ao conjunto curado de três classes, composto por 2.333 amostras distribuídas em 298 blocos, resultando em *folds* com 468, 466, 466, 465 e 468 amostras. Esse diagnóstico evidenciou que as 134 amostras de cascalho, concentradas em poucos blocos, não podiam ser adequadamente distribuídas sem violar a independência espacial, limitação que não constituiu uma simplificação arbitrária, mas uma consequência direta do protocolo conservador adotado. Por essa razão, o escopo final de modelagem foi redefinido para o cenário binário Areia vs. Lama, com 2.199 amostras espacialmente independentes (1.760 de areia e 439 de lama)

e *folds* de teste contendo 441, 439, 439, 438 e 442 amostras. A integridade da partição foi verificada automaticamente, confirmando ausência de vazamento entre blocos e uma comparação justa entre métodos, conforme ilustrado na Figura 17.

Figura 17 – Exemplo ilustrativo do particionamento espacial por blocos de 25 km. Cada cor representa um *fold* distinto.




Fonte: Elaborado pelo autor.

3.9 Representação espectral e preparação para modelagem

A Figura 18 apresenta amostras representativas das classes areia e lama no conjunto final binário curado. A análise visual dos recortes em composição RGB revela diferenças de tonalidade e contraste entre as classes, enquanto a distribuição dos valores de intensidade de *pixels* ao longo das bandas indica que, embora haja sobreposição parcial, os perfis de reflectância exibem padrões distintos de dispersão e amplitude entre as classes.

Para a modelagem supervisionada, foram adotadas duas formas de representação complementares, de acordo com a família de modelos avaliada. No bloco profundo, os recortes multibanda foram preservados como tensores $96 \times 96 \times C$. No bloco clássico, os mesmos recortes foram vetorizados por concatenação dos valores de reflectância *pixel* a *pixel*, gerando vetores $x \in \mathbb{R}^p$, com $p = 96 \times 96 \times C$, variável conforme o conjunto espectral e a possível inclusão da batimetria em cada configuração avaliada.

Figura 18 – Amostras representativas das classes Areia e Lama no conjunto final binário. (a)–(b) Recortes em composição RGB (B4–B3–B2), com estiramento de contraste (2–98%). (c) Assinaturas espectrais médias em B2, B3, B4 e B8, com faixa sombreada indicando ± 1 desvio padrão dos valores de reflectância dos *pixels* em cada recorte. O perfil espectral mostra sobreposição parcial entre as classes, mas também diferenças de amplitude e no comportamento da reflectância ao longo das bandas analisadas.



Fonte: Elaborado pelo autor.

3.10 Redução de dimensionalidade por PCA

No bloco clássico, após a vetorização dos recortes, empregou-se Análise de Componentes Principais (PCA) para reduzir linearmente a dimensionalidade da representação espacial-espectral e mitigar a maldição da dimensionalidade (JOLLIFFE, 2002). O objetivo foi projetar os dados em um subespaço ortogonal que maximizasse a variância explicada, capturando redundâncias lineares entre bandas e entre as posições fixas de *pixels* no recorte vetorizado.

Seja $X \in \mathbb{R}^{n_{\text{treino}} \times p}$ a matriz de dados contendo os vetores de reflectância padronizados, em que n_{treino} é o número de amostras de treinamento em cada *fold* e $p = H \times W \times C$ é o número de atributos originais, com H e W representando as dimensões espaciais do recorte e C o número de bandas utilizadas. A matriz de covariância é dada por:

$$S = \frac{1}{n_{\text{treino}} - 1} X^\top X \quad (3.5)$$

A decomposição espectral da matriz de covariância é expressa por:

$$S = Q\Lambda Q^\top \quad (3.6)$$

em que Q contém os autovetores (direções principais) e Λ é a matriz diagonal dos autovalores. A projeção para o subespaço reduzido Z é dada pela transformação linear:

$$Z = XQ_k \quad (3.7)$$

em que Q_k contém apenas os k autovetores associados aos maiores autovalores. O número de componentes principais k (tal que $k \ll p$) foi tratado como hiperparâmetro crítico do modelo e submetido à análise de sensibilidade, descrita na Seção 3.18, com o objetivo de identificar o ponto ótimo entre compressão dos dados (eficiência computacional) e preservação da informação discriminativa (fidelidade da representação reduzida).

Importante destacar que todas as técnicas de reamostragem para tratamento do desbalanceamento foram aplicadas *após* a transformação PCA, ou seja, no espaço de atributos reduzido de cada *fold*, e nunca com acesso aos dados de validação ou teste, preservando a integridade do protocolo de validação espacial.

3.11 Algoritmos de classificação

Foram avaliadas duas famílias complementares de modelos, com o objetivo de caracterizar o compromisso entre capacidade preditiva e custo computacional: arquiteturas profundas, que processam os recortes multibanda diretamente; e classificadores leves, aplicados aos atributos espectrais reduzidos por PCA.

3.11.1 Bloco profundo

O bloco profundo operou diretamente sobre os recortes multibanda, extraindo padrões sem necessidade de redução de dimensionalidade prévia. Foram avaliadas quatro arquiteturas:

- **CNN-Base:** rede convolucional customizada composta por três blocos de extração sequenciais. O primeiro e o segundo contêm, cada um, duas convoluções 3×3 (64 e 128 filtros, respectivamente), *batch normalization*, ativação ReLU e *max-pooling*. O terceiro contém uma convolução 3×3 (256 filtros), seguida das mesmas operações. A classificação final é realizada por *global average pooling* e

uma camada densa com 128 neurônios e *dropout* de 25% (LECUN; BENGIO; HINTON, 2015; IOFFE; SZEGEDY, 2015b; NAIR; HINTON, 2010);

- **CNN-SE**: variante da arquitetura anterior que incorpora blocos *Squeeze-and-Excitation*, adicionando recalibração de canais antes do *max-pooling* em cada um dos três estágios convolucionais (64, 128 e 256 filtros), mantendo a mesma estrutura densa de classificação (LECUN; BENGIO; HINTON, 2015; IOFFE; SZEGEDY, 2015b; NAIR; HINTON, 2010; HU et al., 2017);
- **EfficientNetV2-B0**: arquitetura pré-treinada no ImageNet com módulo de adaptação multiespectral composto por convoluções 1×1 e 3×3 , *batch normalization*, ativação Swish e atenção de canais, para projeção dos dados em três canais. A extração de atributos é agregada por *global average pooling*, *dropout* e camada densa intermediária de 128 neurônios (TAN; LE, 2021; RUSSAKOVSKY et al., 2015);
- **EfficientNetV2-B0 Fusion**: variante que adiciona um ramo espectral auxiliar processando o tensor original (agregação espacial global, duas camadas densas com 64 neurônios, Swish e *dropout*). Esse descritor recalibra a saída do *backbone* por meio de *gating*. Os vetores são concatenados e classificados por uma cabeça densa dupla (192 e 96 neurônios, Swish e *dropout*) (TAN; LE, 2021).

3.11.2 Bloco clássico baseado em PCA

No bloco clássico, os recortes foram vetorizados, padronizados e projetados por PCA. Sobre os atributos reduzidos, foram avaliados dois modelos:

- **SVM**: máquina de vetores de suporte com núcleo radial (CORTES; VAPNIK, 1995);
- **MLP**: perceptron de múltiplas camadas com seis camadas ocultas totalmente conectadas (512, 256, 128, 64, 32 e 16 neurônios) e ativação ReLU (HAYKIN, 2009; NAIR; HINTON, 2010).

3.12 Tratamento do desbalanceamento

O desbalanceamento entre classes foi tratado de maneira distinta em cada família de modelos, sempre aplicando os procedimentos exclusivamente no subconjunto de treinamento de cada *fold*, para evitar vazamento de informação.

No bloco clássico baseado em PCA, foram avaliadas quatro configurações de reamostragem, todas aplicadas no espaço de atributos já reduzido pela PCA:

- ausência de balanceamento explícito;
- **SMOTE**: sobreamostragem por interpolação linear entre vizinhos da classe minoritária, aplicada no espaço de atributos reduzido pela PCA, conforme proposto originalmente por Chawla et al. (CHAWLA et al., 2002);
- **ADASYN**: método adaptativo que estende o SMOTE concentrando a geração de dados sintéticos nas instâncias minoritárias mais difíceis de aprender (HE et al., 2008);
- **Borderline-SMOTE**: variação que restringe a interpolação às instâncias minoritárias localizadas na região de fronteira de decisão entre classes (HAN; WANG; MAO, 2005).

No bloco profundo, não foi realizada reamostragem explícita de imagens. O desbalanceamento foi tratado diretamente na função de perda, por meio de três regimes:

- ausência de balanceamento adicional;
- **ponderação de classes**: a função de perda atribui pesos inversamente proporcionais às frequências de classe observadas no subconjunto de treinamento (HE; GARCIA, 2009);
- **focal loss**: formulação esparsa com $\gamma = 2,0$, combinada com vetor de ponderação derivado das frequências de classe no subconjunto de treinamento, aumentando a contribuição relativa de exemplos difíceis e reforçando a sensibilidade à classe minoritária (LIN et al., 2017).

3.13 Procedimentos de treinamento

Os procedimentos de treinamento foram definidos de forma distinta para as duas famílias de modelos, respeitando suas características arquiteturais e necessidades de otimização.

3.13.1 Bloco profundo

As arquiteturas neurais profundas foram treinadas com os seguintes parâmetros e mecanismos de controle:

- **Otimização e épocas**: foi utilizado o otimizador Adam (KINGMA; BA, 2014), com taxa inicial de aprendizado de 1×10^{-4} e limite de até 500 épocas. O tamanho do lote foi ajustado adaptativamente (64, 32, 16 ou 8) conforme disponibilidade de memória;

- **Monitoramento e validação:** a convergência foi controlada por meio de uma partição estratificada interna (10% do subconjunto de treinamento reservado para validação) dentro de cada *fold* espacial. A normalização por banda foi estimada exclusivamente no subconjunto de treinamento;
- **Regularização e parada antecipada:** foram aplicados redução adaptativa da taxa de aprendizado em platô, *early stopping* com retenção e restauração dos melhores pesos conforme a perda de validação, e mecanismo explícito de interrupção em caso de instabilidade numérica;
- **Ajuste fino (EfficientNetV2-B0):** os *backbones* foram inicializados com pesos ImageNet e submetidos a ajuste fino parcial, mantendo as camadas de *batch normalization* estritamente congeladas.

3.13.2 Bloco clássico

Para os modelos tradicionais, os recortes foram previamente vetorizados, padronizados e projetados por PCA antes do treinamento:

- **SVM:** ajustado diretamente sobre os atributos transformados por PCA;
- **MLP:** treinada por até 500 iterações com o otimizador Adam (KINGMA; BA, 2014), incorporando regularização L_2 , fração de validação interna de 10% e critério de parada antecipada com tolerância de 25 iterações sem melhoria.

Este estudo não constitui uma busca exaustiva de hiperparâmetros, estratégias de regularização ou procedimentos de otimização profunda. Não foram incorporados *data augmentation* nem ajuste sistemático de hiperparâmetros. Assim, as conclusões sobre desempenho relativo restringem-se às arquiteturas, regimes de balanceamento e configurações efetivamente testadas sob o protocolo de validação espacial. As arquiteturas convolucionais e baseadas em EfficientNet devem ser interpretadas como *baselines* representativos de aprendizado profundo avaliados em um ambiente de validação espacial controlado, e não como soluções completamente otimizadas.

3.14 Ambiente computacional e reprodutibilidade

Os experimentos foram executados em ambiente Google Colab, com CPU de 12 núcleos lógicos a 2,20 GHz, 167 GB de memória RAM e GPU NVIDIA A100-SXM4 com 80 GB de VRAM. A padronização do ambiente buscou assegurar comparabilidade entre tempos médios por *fold* e reprodutibilidade operacional.

3.15 Métricas de avaliação

O desempenho dos modelos foi avaliado por acurácia, precisão, *recall*, *F1-score*, *F1-score macro*, coeficiente Kappa e eficiência computacional (CONGALTON, 1991; SOKOLOVA; LAPALME, 2009). O uso conjunto dessas métricas segue recomendações para avaliação rigorosa em sensoriamento remoto e apoia a avaliação de aplicabilidade em larga escala.

A acurácia foi calculada por:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.8)$$

A precisão foi calculada por:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (3.9)$$

O *recall* foi calculado por:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.10)$$

O *F1-score* foi calculado por:

$$F1\text{-score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (3.11)$$

Nas equações 3.8 a 3.11, os termos referem-se aos componentes da matriz de confusão: *TP* (verdadeiros positivos), *TN* (verdadeiros negativos), *FP* (falsos positivos) e *FN* (falsos negativos). A versão macro do *F1-score* calcula a média aritmética dos *F1-scores* individuais, atribuindo peso igual a todas as classes independentemente do suporte amostral, penalizando assim modelos que negligenciam classes minoritárias (SOKOLOVA; LAPALME, 2009).

O coeficiente Kappa mede a concordância entre rótulos observados e previstos, descontando a concordância esperada ao acaso (COHEN, 1960):

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (3.12)$$

em que p_o é a concordância observada e p_e a concordância esperada ao acaso. A eficiência computacional foi mensurada pelo tempo médio de treinamento e inferência por *fold*, métrica crucial para determinar a escalabilidade dos modelos propostos ao lidar com grandes volumes de dados de sensoriamento remoto. Todas as métricas foram calculadas individualmente em cada *fold* espacial e reportadas como média e desvio padrão.

3.16 Critério de seleção do modelo e análise estatística

Os modelos finais foram selecionados com base em três critérios: desempenho médio nos *folds*, especialmente *macro F1*, Kappa e acurácia; estabilidade, expressa pela baixa variância entre *folds*; e eficiência computacional. Esses critérios foram aplicados exclusivamente aos *folds* da validação espacial por blocos de 25 km, de modo que a seleção final do modelo refletisse um cenário mais conservador de generalização geoespacial. Quando nenhuma diferença estatisticamente significativa foi detectada entre as configurações avaliadas, a priorização considerou conjuntamente a simplicidade do modelo, a estabilidade entre *folds* e a eficiência computacional, com o objetivo de favorecer a alternativa com melhor compromisso operacional.

Para as comparações estatísticas, foram empregados o teste de Friedman, para avaliação global de diferenças entre múltiplas configurações, e testes *t* pareados bicaudais para comparações específicas entre pares. Os resultados foram considerados estatisticamente significativos para $p < 0,05$.

3.17 Análise do papel da batimetria

A influência da batimetria foi avaliada por meio de três estratégias complementares, com o objetivo de examinar o papel da profundidade como informação auxiliar e testar a hipótese de dependência predominante de proxies batimétricos.

1. **Comparações pareadas com e sem canal batimétrico:** para cada combinação de modelo e conjunto espectral, as configurações com e sem inclusão da batimetria como canal adicional foram comparadas por testes *t* pareados bicaudais com $\alpha = 0,05$, permitindo identificar casos em que a batimetria foi significativamente benéfica, neutra ou prejudicial ao desempenho.
2. **Experimento de embaralhamento (*shuffle*):** o canal batimétrico foi embaralhado aleatoriamente entre as amostras antes do treinamento, rompendo o alinhamento espacial entre profundidade e imagem. A comparação entre o desempenho com batimetria real, batimetria embaralhada e sem batimetria permite verificar em que medida o ganho associado à batimetria depende de informação geoespacialmente alinhada. Esse experimento foi conduzido em 4 modelos $\times$ 7 conjuntos espectrais, totalizando 28 configurações de controle distribuídas ao longo dos cinco *folds*.
3. **Modelos treinados exclusivamente com batimetria (*bathymetry only*):** modelos foram treinados utilizando apenas o canal batimétrico como entrada, sem qualquer informação espectral. Esse experimento testa diretamente se a batimetria seria suficiente, por si só, para sustentar a discriminação entre areia e lama. Foram avaliadas configurações com *bathymetry only* para CNN-SE e CNN-Base

(três estratégias de balanceamento cada) e para MLP e SVM (quatro estratégias de balanceamento cada).

Cabe ressaltar que, como a distribuição sedimentar, os efeitos da coluna d'água e a batimetria são fisicamente correlacionados na MEB, esses testes não podem excluir completamente efeitos indiretos de aprendizado de proxies. No entanto, a combinação das três estratégias fornece evidências complementares sobre o papel relativo da batimetria na discriminação supervisionada de areia e lama.

3.18 Análise de sensibilidade do número de componentes principais

Após a seleção do *pipeline* baseado em PCA como configuração recomendada, foi conduzida uma análise de sensibilidade para determinar o número mínimo de componentes principais necessário para manter o desempenho. Utilizando os mesmos *folds* da validação espacial por blocos, o número de componentes k foi variado sistematicamente de 2 a 255. Para cada valor de k , foram registrados acurácia, Kappa, *macro F1*, F1 por classe, tempo médio de treinamento por *fold* e tamanho efetivo do modelo.

O valor ótimo mínimo de k foi identificado a partir de dois critérios: estabilidade de desempenho, definida como o menor k cuja diferença relativa em *macro F1* e Kappa permanecesse dentro de uma margem prática em relação a valores de referência com maior número de componentes; e similaridade estatística, avaliada por testes t pareados bicaudais com $\alpha = 0,05$. O monitoramento do F1 por classe garantiu que a redução de dimensionalidade não degradaria desproporcionalmente a classe minoritária, lama.

3.19 Explicabilidade do modelo e interpretação física dos componentes

Para investigar como a variabilidade espectral é organizada no subespaço PCA, foi realizada uma análise da contribuição relativa de cada banda de entrada em cada componente principal. Para cada componente, a contribuição de cada banda foi estimada agregando, sobre todos os *pixels* do recorte (96×96), a energia dos pesos da PCA (*loadings*²), normalizando o resultado de modo que somasse 100% em cada PC. Os valores reportados correspondem à média calculada sobre os cinco *folds* de treinamento da validação espacial por blocos.

Em paralelo, foi avaliado em que medida os componentes PCA capturam informação correlacionada com a profundidade, mesmo quando a batimetria não é fornecida como canal de entrada ao modelo. Para isso, os *scores* PCA de cada amostra foram correlacionados com a batimetria média estimada sobre a área de cada recorte (96×96), tratada estritamente como variável externa sem participação no treinamento da PCA. Os coeficientes de correlação de Pearson e Spearman foram calculados por *fold* sobre o

subconjunto de treinamento e agregados como média $\pm$ desvio padrão ao longo dos cinco *folds*.

3.20 Inferência espacial e representação cartográfica

Para a etapa de inferência cartográfica, o modelo selecionado ao final da avaliação supervisionada foi treinado no conjunto completo de amostras binárias espacialmente independentes e aplicado a uma grade regular de pontos espaçados 16,7 km ao longo da MEB, dentro do limite batimétrico de -30 m. Essa grade gera nós de inferência independentes dos dados de treinamento, evitando o uso das previsões do próprio modelo como pontos de controle adicionais, o que poderia reforçar vieses e introduzir circularidade no processo cartográfico.

Para cada nó da grade, as probabilidades por classe foram obtidas por meio da função *Softmax* aplicada às ativações da camada de saída do modelo, de modo que as probabilidades previstas em cada nó satisfizessem $P_{\text{areia}} + P_{\text{lama}} = 1$, eliminando a necessidade de qualquer etapa de normalização posterior.

Para converter as previsões pontuais em uma representação regional contínua, adotou-se tesselação de Voronoi como procedimento cartográfico. Essa abordagem particiona o espaço de forma que cada polígono corresponda ao nó de inferência mais próximo, herdando diretamente sua classe dominante (argmax das probabilidades *Softmax*) e demais atributos, sem interpolação entre pontos. Essa propriedade garante que nenhum valor seja gerado artificialmente entre os nós da grade, tornando a representação cartográfica consistente com a afirmação de que cada célula representa a classe dominante no nó de inferência correspondente, sem impor continuidade espacial artificial como etapa central do procedimento.

O processamento geoespacial foi implementado no QGIS 3.36. Inicialmente, os polígonos de Voronoi foram gerados a partir dos nós de inferência, com aplicação de um *buffer* regional de 30% para evitar lacunas nas bordas da área de estudo. Em seguida, polígonos adjacentes pertencentes à mesma classe dominante foram dissolvidos em domínios contínuos. O resultado foi recortado pela máscara batimétrica de -30 m, restringindo a representação à faixa de aplicabilidade do modelo óptico. Por fim, aplicou-se suavização de bordas com 5 iterações e deslocamento de 0,25, com o objetivo de atenuar a geometria angular característica da grade regular, procedimento análogo ao descrito por Santos Filho et al. (FILHO et al., 2025b), que aplicou generalização de polígonos com tolerância de 10 km sobre polígonos de interseção de fácies sedimentares.

Para a comparação cartográfica com mapeamentos sedimentológicos independentes disponíveis na literatura, a classe granulométrica dominante do mapeamento de referência será extraída em cada nó de inferência da grade regular e comparada com a

predição do modelo óptico supervisionado. Nós localizados fora da cobertura espacial do mapeamento de referência, ou que coincidam com polígonos de classes não previstas pelo modelo binário, serão excluídos da comparação, e a análise de concordância cartográfica será conduzida sobre os nós comparáveis restantes.

Como descritor heurístico de ambiguidade local nas previsões pontuais, calculou-se o Índice de Equilíbrio Binário diretamente a partir das probabilidades *Softmax* de cada nó da grade regular:

$$I_{eq} = 1 - |P_{areia} - P_{lama}| \quad (3.13)$$

em que P_{areia} e P_{lama} representam as probabilidades previstas para as classes Areia e Lama em cada nó. Como essas probabilidades satisfazem $P_{areia} + P_{lama} = 1$, o índice varia de 0 a 1: valores próximos de 0 indicam clara dominância de uma das classes, enquanto valores próximos de 1 indicam probabilidades aproximadamente equilibradas entre Areia e Lama. Esse índice será utilizado exclusivamente como descritor heurístico de equilíbrio local entre as duas classes previstas, não devendo ser interpretado como medida estatisticamente rigorosa de incerteza, probabilidade calibrada de erro ou substituto para quantificação formal de incerteza. Os mapas correspondentes devem, portanto, ser interpretados como produtos cartográficos exploratórios em escala regional, e não como validação contemporânea direta do estado atual do fundo marinho.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta a avaliação quantitativa e qualitativa do *pipeline* proposto sob validação espacial por blocos de 25 km com cinco *folds*. A análise concentra-se no cenário final binário Areia vs. Lama, definido após o diagnóstico de inviabilidade da classe cascalho no protocolo espacial independente. O conjunto final utilizado na modelagem supervisionada foi composto por 2.199 amostras espacialmente independentes, sendo 1.760 de areia e 439 de lama, distribuídas em cinco *folds* de teste com 441, 439, 439, 438 e 442 amostras, respectivamente. A análise está organizada em dez etapas: desempenho global e comparação estatística; desempenho por classe; sensibilidade espectral; papel da batimetria; tratamento do desbalanceamento; compromisso entre desempenho, estabilidade e custo computacional; análise de sensibilidade do número de componentes principais; explicabilidade do PCA; síntese dos resultados; e consistência espacial dos mapas gerados. A análise principal concentra-se nas configurações sem o canal batimétrico; o efeito da batimetria como variável opcional é discutido separadamente. Na interpretação dos resultados, deu-se prioridade ao *F1 macro*, ao coeficiente Kappa e ao comportamento da classe lama, enquanto a acurácia foi utilizada como métrica complementar.

4.1 Escopo experimental final

O protocolo experimental reporta 322 configurações, correspondentes a 1.610 execuções considerando os cinco *folds* espaciais. Desse total, 294 configurações pertencem ao conjunto principal de experimentos: 174 do bloco profundo e 120 do bloco clássico baseado em PCA. No bloco profundo, foram avaliadas 168 configurações da grade principal, resultantes de quatro arquiteturas, sete conjuntos espectrais, dois regimes de batimetria (com e sem) e três estratégias de tratamento de desbalanceamento [4 arquiteturas $\times$ 7 conjuntos espectrais $\times$ 2 regimes de batimetria $\times$ 3 estratégias de desbalanceamento], além de seis controles com batimetria apenas, distribuídos entre duas arquiteturas convolucionais (CNN-SE e CNN-Base) e três estratégias de tratamento de desbalanceamento. No bloco clássico, foram avaliadas 112 configurações da grade principal, combinando duas arquiteturas, sete conjuntos espectrais, dois regimes de batimetria e quatro estratégias de balanceamento [2 arquiteturas $\times$ 7 conjuntos espectrais $\times$ 2 regimes de batimetria $\times$ 4 configurações de balanceamento], além de oito controles com batimetria apenas, distribuídos entre MLP e SVM sob quatro estratégias de balanceamento. Também foram conduzidos 28 controles com embaralhamento da batimetria, distribuídos entre quatro modelos e sete conjuntos espectrais, com o objetivo de verificar se eventual ganho associado ao canal batimétrico dependia do alinhamento espacial real.

4.2 Comparação estatística e desempenho global

A Tabela 2 apresenta sete configurações representativas de alto desempenho no cenário sem batimetria explícita, ordenadas pelo *F1 macro*. As diferenças entre elas foram pequenas e não sustentaram superioridade estatística de nenhuma configuração em termos de *F1 macro*, acurácia ou Kappa.

Para a comparação estatística global, foram selecionadas seis configurações-chave: CNN-Base (VIS+NIR+SWIR, *focal loss*), CNN-SE (RGB, pesos), CNN-SE (VIS+RE+NIR, sem balanceamento), MLP+PCA (VIS+NIR+SWIR+AC, SMOTE), SVM+PCA(VIS+NIR+SWIR, SMOTE) e EfficientNetV2-B0 Fusion (RGB, pesos). O teste de Friedman aplicado ao *F1 macro* dessas seis configurações nos cinco *folds* não rejeitou a hipótese nula de igualdade ($\chi^2 = 3,629$; $p = 0,604$). Além disso, todos os 15 testes *t* pareados bicaudais entre pares de configurações resultaram em $p > 0,05$.

Em termos nominais, a CNN-Base com VIS+NIR+SWIR e *focal loss* obteve o maior *F1 macro* médio ($88,93\% \pm 3,16$), seguida pela CNN-SE com RGB e ponderação de classes ($88,73\% \pm 2,94$) e pela CNN-SE com VIS+RE+NIR sem balanceamento ($88,72\% \pm 2,57$), que apresentou a maior acurácia média ($92,64\% \pm 1,81$) e o menor desvio padrão entre as arquiteturas convolucionais. No bloco clássico, a MLP com VIS+NIR+SWIR+AC e SMOTE alcançou *F1 macro* de $88,49\% \pm 1,18$, destacando-se pela estabilidade e pelo baixo custo computacional. A variante EffNetV2-B0 Fusion, apesar da maior complexidade, não superou as demais famílias (*F1 macro* = $87,96\% \pm 5,10$), enquanto o SVM com VIS+NIR+SWIR e SMOTE alcançou $87,53\% \pm 3,81$. A EffNetV2-B0 padrão, mais pesada e variável, obteve *F1 macro* de $86,43\% \pm 5,61$.

Tabela 2 – Configurações representativas de alto desempenho no cenário binário Areia vs. Lama sem batimetria explícita (validação espacial por blocos, 5 *folds*). Média $\pm$ desvio padrão (%).

Configuração	Acurácia (%)	Kappa (%)	<i>F1 Macro</i> (%)	Tempo (s)
CNN-Base (VIS+NIR+SWIR, <i>focal</i>)	$92,59 \pm 2,49$	$77,89 \pm 6,25$	$88,93 \pm 3,16$	51,12
CNN-SE (RGB, pesos)	$92,37 \pm 2,20$	$77,51 \pm 5,82$	$88,73 \pm 2,94$	100,63
CNN-SE (VIS+RE+NIR, sem bal.)	$92,64 \pm 1,81$	$77,45 \pm 5,14$	$88,72 \pm 2,57$	102,49
MLP+PCA (VIS+NIR+SWIR+AC, SMOTE)	$92,27 \pm 1,17$	$77,03 \pm 2,32$	$88,49 \pm 1,18$	7,78
EffNetV2-B0 Fusion (RGB, pesos)	$91,32 \pm 4,70$	$76,21 \pm 9,64$	$87,96 \pm 5,10$	198,00
SVM+PCA (VIS+NIR+SWIR, SMOTE)	$91,00 \pm 3,53$	$75,30 \pm 7,24$	$87,53 \pm 3,81$	0,61
EffNetV2-B0 (VIS+NIR+SWIR+AC, <i>focal</i>)	$89,78 \pm 5,20$	$73,34 \pm 10,48$	$86,43 \pm 5,61$	185,83

Fonte: Elaborado pelo autor.

A Tabela 3 apresenta os testes *t* pareados entre as configurações representativas. Nenhuma comparação atingiu significância estatística para *F1 macro*, acurácia ou Kappa. A comparação entre CNN-Base e SVM+PCA apresentou o maior valor de *t* ($t = 2,516$; $p = 0,066$), próximo ao limiar, mas ainda insuficiente para indicar superioridade estatística com cinco *folds*.

Tabela 3 – Testes t pareados bicaudais entre configurações representativas sem batimetria. Nenhuma comparação atingiu significância estatística para $\alpha = 0,05$.

Modelo A	Modelo B	t (F1M)	p	Sig.
CNN-Base (<i>focal</i>)	CNN-SE (pesos)	0,332	0,756	n.s.
CNN-Base (<i>focal</i>)	CNN-SE (sem bal.)	0,159	0,881	n.s.
CNN-Base (<i>focal</i>)	MLP+SMOTE	0,321	0,765	n.s.
CNN-Base (<i>focal</i>)	SVM+SMOTE	2,516	0,066	n.s.
CNN-Base (<i>focal</i>)	EffNetV2-B0 Fusion	0,977	0,384	n.s.
CNN-SE (pesos)	CNN-SE (sem bal.)	0,009	0,993	n.s.
CNN-SE (pesos)	MLP+SMOTE	0,207	0,846	n.s.
CNN-SE (pesos)	SVM+SMOTE	2,136	0,100	n.s.
CNN-SE (pesos)	EffNetV2-B0 Fusion	0,646	0,553	n.s.
MLP+SMOTE	SVM+SMOTE	0,608	0,576	n.s.
MLP+SMOTE	EffNetV2-B0 Fusion	0,254	0,812	n.s.
CNN-SE (sem bal.)	MLP+SMOTE	0,337	0,753	n.s.
CNN-SE (sem bal.)	SVM+SMOTE	0,901	0,418	n.s.
CNN-SE (sem bal.)	EffNetV2-B0 Fusion	0,437	0,685	n.s.
SVM+SMOTE	EffNetV2-B0 Fusion	0,574	0,597	n.s.

Fonte: Elaborado pelo autor.

Em termos práticos, as diferenças nominais entre as configurações mais competitivas foram da mesma ordem que a variação entre *folds*. Entre as quatro melhores, a amplitude em *F1 macro* foi inferior a 0,5 pontos percentuais, reforçando a similaridade prática entre os melhores modelos dentro do espaço de configurações testado. Esses resultados indicam competitividade dos modelos leves baseados em PCA, mas essa conclusão não deve ser interpretada como equivalência geral entre modelos leves e arquiteturas profundas totalmente otimizadas. As arquiteturas convolucionais e baseadas em EfficientNet foram concebidas como *baselines* representativos para comparação controlada e não foram submetidas a *data augmentation* exaustivo, busca de arquiteturas ou otimização sistemática de hiperparâmetros. Portanto, a ausência de diferenças estatisticamente significativas deve ser interpretada como evidência de competitividade do *pipeline* leve proposto dentro deste cenário experimental, e não como afirmação geral de equivalência com modelos de aprendizado profundo completamente otimizados.

4.3 Desempenho por classe e perfil de erro

A Tabela 4 detalha o desempenho por classe das configurações mais competitivas. Para a classe areia, todas as abordagens apresentaram F1 superior a 94%, com diferenças pequenas entre modelos. A classe lama concentrou as diferenças mais relevantes entre as configurações.

Na classe lama, os modelos exibiram compromissos distintos entre precisão e *recall*. A CNN-SE com ponderação de classes priorizou a recuperação da classe minoritária,

obtendo *recall* de 88,61%, mas com menor precisão (77,12%), resultando em média de 23,6 falsos positivos por *fold*. A CNN-SE sem balanceamento com VIS+RE+NIR apresentou perfil mais conservador, com precisão de 80,26% e *recall* de 84,07%, produzindo em média 18,4 falsos positivos e o menor desvio padrão entre as arquiteturas convolucionais (3,99 p.p.). A MLP com SMOTE ficou em posição intermediária, com precisão de 77,84% e *recall* de 87,21%, e apresentou a maior estabilidade entre as configurações, com desvio padrão do F1 da lama de 1,58 p.p. O SVM com SMOTE obteve o maior *recall* para lama (93,36%), ao custo de menor precisão (72,15%) e alta variabilidade entre *folds* (desvio padrão de 5,07 p.p.), perfil compartilhado pelo EffNetV2-B0 Fusion (precisão de 74,21%, *recall* de 92,24%, desvio padrão de 6,77 p.p.).

Tabela 4 – Desempenho por classe das configurações mais competitivas sem batimetria (média nos 5 *folds*, %).

Classe / Configuração	Precisão	<i>Recall</i>	F1	$\sigma(\text{F1})$
Areia				
CNN-Base (VIS+NIR+SWIR, <i>focal</i>)	96,55	94,10	95,29	1,68
CNN-SE (RGB, pesos)	97,06	93,30	95,13	1,47
CNN-SE (VIS+RE+NIR, sem bal.)	95,97	94,77	95,36	1,17
MLP+PCA (VIS+NIR+SWIR+AC, SMOTE)	96,75	93,53	95,08	0,84
SVM+PCA (VIS+NIR+SWIR, SMOTE)	98,26	90,40	94,08	2,57
EffNetV2-B0 Fusion (RGB, pesos)	97,97	91,09	94,28	3,44
Lama				
CNN-Base (VIS+NIR+SWIR, <i>focal</i>)	79,14	86,56	82,56	4,64
CNN-SE (RGB, pesos)	77,12	88,61	82,33	4,44
CNN-SE (VIS+RE+NIR, sem bal.)	80,26	84,07	82,08	3,99
MLP+PCA (VIS+NIR+SWIR+AC, SMOTE)	77,84	87,21	81,90	1,58
EffNetV2-B0 Fusion (RGB, pesos)	74,21	92,24	81,65	6,77
SVM+PCA (VIS+NIR+SWIR, SMOTE)	72,15	93,36	80,97	5,07

Fonte: Elaborado pelo autor.

Em termos operacionais, a escolha entre essas abordagens depende do objetivo da aplicação. Quando a prioridade é recuperar o máximo possível de áreas lamosas, modelos com maior *recall* podem ser preferíveis. Quando o objetivo é minimizar falsos alarmes para lama, configurações mais conservadoras, como a CNN-SE sem balanceamento, são mais adequadas. A ausência de diferenças estatisticamente significativas entre as configurações indica que, dentro do espaço experimental testado, essa decisão pode ser guiada pelos requisitos da aplicação, em vez de pela superioridade preditiva clara de um modelo sobre os demais.

4.4 Sensibilidade espectral


A sensibilidade espectral foi avaliada exclusivamente em configurações sem batimetria, para isolar a contribuição das bandas do efeito da profundidade. A Figura 19 mostra o melhor *F1 macro* obtido, por conjunto espectral, para MLP+PCA e CNN-SE.

No bloco clássico, a expansão espectral produziu ganhos monotônicos e consistentes até o conjunto VIS+NIR+SWIR+AC. A MLP evoluiu de 86,13% de *F1 macro* com RGB para 88,49% com VIS+NIR+SWIR+AC, um ganho acumulado de 2,36 pontos percentuais. A inclusão dos conjuntos mais amplos, *Full S2* sem AC e *Full S2*, não produziu ganho adicional, resultando em pequenas regressões de 0,85 e 0,87 p.p., respectivamente. Esse comportamento é consistente com a hipótese de que a redução PCA se beneficia da incorporação de informações fora do visível para aumentar a separabilidade entre areia e lama no subespaço projetado, mas que bandas com menor relevância discriminativa introduzem ruído na projeção.

No bloco profundo, a CNN-SE apresentou comportamento irregular, sem tendência monotônica. O melhor *F1 macro* ocorreu com RGB e ponderação de classes (88,73%), valor muito próximo ao obtido com VIS+RE+NIR (88,72%) e *Full S2* (88,59%), enquanto VIS+NIR (87,94%) e VIS+NIR+SWIR+AC (87,76%) foram menores. A amplitude total de variação foi inferior a 1 ponto percentual, sugerindo que a CNN-SE, ao operar com mecanismo de atenção de canais (SE), não apresenta vantagem sistemática dos conjuntos espectrais mais amplos sobre RGB neste problema, embora a variação entre conjuntos seja irregular.

Em termos práticos, a expansão espectral foi claramente benéfica para a MLP, mas não ofereceu vantagem consistente para a CNN-SE.

Figura 19 – Sensibilidade espectral sem batimetria: $F1$ macro em função do conjunto de bandas para MLP+PCA e CNN-SE (melhor configuração por conjunto, validação espacial por blocos, 5 *folds*). A MLP apresenta ganho monotônico até VIS+NIR+SWIR+AC, enquanto a CNN-SE mostra variação irregular com amplitude inferior a 1 p.p.



Fonte: Elaborado pelo autor.

4.5 Papel da batimetria

A influência da batimetria foi avaliada por três estratégias complementares: comparações pareadas entre configurações com e sem canal batimétrico, experimentos com embaralhamento da profundidade no conjunto de treinamento, e modelos treinados exclusivamente com batimetria. Esses testes permitem examinar o papel complementar da profundidade e testar a hipótese de dependência predominante de *proxies* batimétricos. Cabe ressaltar, entretanto, que como a distribuição sedimentar, os efeitos da coluna d'água e a batimetria são fisicamente correlacionados na MEB, esses testes não podem excluir completamente efeitos indiretos de aprendizado de *proxies*.

O efeito da batimetria foi heterogêneo. O benefício mais claro ocorreu no SVM com *Full* S2 e SMOTE, em que a inclusão da batimetria aumentou o $F1$ macro em 1,33 p.p. ($t = 3,007$; $p = 0,040$). Em sentido oposto, a CNN-Base com VIS+NIR+SWIR e *focal loss* sofreu queda significativa de 3,61 p.p. ($t = 3,640$; $p = 0,022$), sugerindo interferência da profundidade no processo de aprendizado dessa arquitetura. Para os modelos baseados em PCA, os ganhos foram modestos e sem significância estatística: a MLP com VIS+NIR+SWIR+AC e SMOTE aumentou de 88,49% para 89,04% ($\Delta = +0,55$ p.p.; $p = 0,481$), enquanto a MLP com RGB e SMOTE registrou o maior ganho absoluto no grupo PCA ($\Delta = +2,77$ p.p.; $p = 0,296$). A Tabela 5 sumariza essas comparações pareadas.

A hipótese de dependência predominante de informação batimétrica foi investigada pelo experimento de embaralhamento. Na MLP com VIS+NIR+SWIR+AC, a

Tabela 5 – Efeito da batimetria em configurações representativas. Valores em *F1 macro* (%). Significância do teste *t* pareado indicada na última coluna.

Configuração	Sem BAT	Com BAT	$\Delta F1M$	<i>p</i>
SVM (<i>Full</i> S2, SMOTE)	86,75	88,08	+1,33	0,040*
MLP (RGB, SMOTE)	86,13	88,90	+2,77	0,296
MLP (VIS+NIR+SWIR+AC, SMOTE)	88,49	89,04	+0,55	0,481
MLP (VIS+NIR+SWIR, SMOTE)	87,83	88,53	+0,70	0,504
CNN-SE (RGB, pesos)	88,73	87,80	−0,93	0,316
SVM (VIS+NIR+SWIR, SMOTE)	87,53	87,20	−0,32	0,685
CNN-Base (VIS+NIR+SWIR, <i>focal</i>)	88,93	85,31	−3,61	0,022*

*Significativo para $\alpha = 0,05$.

Fonte: Elaborado pelo autor.

batimetria embaralhada reduziu o *F1 macro* de 89,04% para 82,25% ($\Delta = -6,79$ p.p.), ficando abaixo até mesmo da configuração sem batimetria (88,49%). Esse resultado indica que a batimetria espacialmente alinhada pode carregar informação útil adicional, mas que, quando corrompida, passa a atuar como ruído.

O teste mais direto da suficiência preditiva da batimetria foi fornecido pelos modelos treinados exclusivamente com profundidade. Se a batimetria fosse o fator dominante na discriminação, seria esperado que esses modelos alcançassem desempenho próximo ao dos *pipelines* espectrais. Isso não foi observado: mesmo no melhor cenário com batimetria apenas (MLP, ADASYN), o desempenho não superou 60,90% de *F1 macro*, 69,31% de acurácia, Kappa de 24,40 e F1 da lama de 43,15%, valores substancialmente inferiores aos obtidos pelas configurações espectrais correspondentes. A Tabela 6 sintetiza essas comparações de controle.

Tabela 6 – Controle adicional sobre a suficiência preditiva da batimetria na MLP com VIS+NIR+SWIR+AC e SMOTE. O cenário apenas com batimetria permanece substancialmente abaixo dos regimes espectrais.

Métrica	Sem batimetria	Com batimetria	Batimetria embaralhada	Apenas batimetria
Acurácia (%)	92,27	92,64	88,63	69,31
Kappa	77,03	78,15	64,57	24,40
<i>F1 Macro</i> (%)	88,49	89,04	82,25	60,90
F1 Lama (%)	81,90	82,78	71,63	43,15

Fonte: Elaborado pelo autor.

Em síntese, os resultados apontam para um regime de complementaridade condicional entre profundidade e espectro: a batimetria beneficia significativamente apenas configurações específicas, é neutra na maioria dos casos e é prejudicial para CNN-Base com *focal loss*. Tomados em conjunto com os modelos apenas-batimetria, esses achados indicam que a profundidade deve ser interpretada como fonte complementar de variação, e não como substituta das assinaturas espectrais. A discriminação entre areia e lama é sustentada primariamente pelas assinaturas radiométricas, e não por gradientes batimétricos, embora


efeitos indiretos de aprendizado de proxies não possam ser totalmente descartados.

4.6 Resultados do tratamento do desbalanceamento

O efeito das estratégias de balanceamento foi avaliado de forma controlada, fixando o modelo e o conjunto espectral e variando apenas a técnica de tratamento. A Figura 20 mostra os resultados para a MLP com VIS+NIR+SWIR+AC, sem batimetria, caso mais informativo por permitir comparação direta entre três estratégias de reamostragem e treinamento sem balanceamento explícito.

O SMOTE obteve o maior *F1 macro* ($88,49\% \pm 1,18$) e a menor dispersão entre *folds*, seguido por ADASYN ($87,50\% \pm 2,48$) e Borderline-SMOTE ($87,39\% \pm 2,27$). O treinamento sem balanceamento ficou em último lugar ($87,27\% \pm 3,22$), mas a diferença em relação ao SMOTE não foi estatisticamente significativa ($t = 1,118$; $p = 0,326$ para *F1 macro*). Esse resultado indica que, embora o SMOTE ofereça vantagens práticas em termos de estabilidade e ligeira melhora na detecção da lama (*recall* de $87,21\%$ vs. $84,73\%$ sem balanceamento), a significância do efeito é limitada sob a restrição de cinco *folds* espaciais.

Figura 20 – Efeito das estratégias de tratamento do desbalanceamento na MLP com VIS+NIR+SWIR+AC, sem batimetria (média $\pm$ desvio padrão nos 5 *folds*). O SMOTE apresenta maior *F1 macro* e menor dispersão; a diferença em relação à ausência de balanceamento não é estatisticamente significativa ($p = 0,326$).



Fonte: Elaborado pelo autor.

No bloco profundo, o comportamento foi dependente da arquitetura. A CNN-SE obteve seu melhor resultado com ponderação de classes, enquanto a CNN-Base apresentou melhor desempenho com *focal loss*. Entre as variantes EffNetV2-B0, a versão Fusion beneficiou-se da ponderação de classes, enquanto a versão padrão obteve seu melhor resultado sem batimetria e com *focal loss*. Essa dependência arquitetural reforça que o

tratamento do desbalanceamento não admite solução universal e deve ser ajustado ao regime de representação e à família de modelo.

4.7 Compromisso entre desempenho, estabilidade e custo computacional


A equivalência estatística entre as configurações mais competitivas desloca o critério de seleção do modelo para fatores operacionais: estabilidade entre *folds*, custo computacional e facilidade de implantação. A Figura 21 sintetiza esse compromisso para as configurações sem batimetria.

Em termos de estabilidade, a MLP com SMOTE apresentou os menores desvios padrão entre todas as configurações de topo: 1,17 p.p. para acurácia, 1,18 p.p. para *F1 macro* e 1,58 p.p. para F1 da lama, indicando o comportamento mais previsível e reprodutível. A CNN-SE sem balanceamento com VIS+RE+NIR também exibiu alta estabilidade (desvio padrão de acurácia de 1,81 p.p. e de F1 da lama de 3,99 p.p.). Em contraste, as variantes EffNetV2-B0 atingiram até 5,61 p.p. de desvio padrão em *F1 macro* e, no caso da EffNetV2-B0 Fusion, 6,77 p.p. de desvio padrão em F1 da lama.

Em termos de custo computacional, o SVM com VIS+NIR+SWIR e SMOTE completou o processamento médio por *fold* em 0,61 s, sendo mais de 83 vezes mais rápido que a CNN-Base (51,12 s) e aproximadamente 165 vezes mais rápido que a CNN-SE (100,63 s). A MLP com SMOTE exigiu 7,78 s por *fold*, representando redução de aproximadamente 6,6 vezes em relação à CNN-Base, com diferença nominal inferior a 0,5 p.p. em *F1 macro*.

Para mapeamento regional com inferência repetida em grandes áreas costeiras, a diferença de velocidade entre classificadores leves e CNNs é operacionalmente relevante. Como o desempenho preditivo foi estatisticamente equivalente dentro do espaço experimental avaliado, a MLP+PCA+SMOTE foi adotada como configuração recomendada por combinar estabilidade, eficiência e desempenho competitivo. O SVM é a opção mais rápida entre todos os modelos avaliados. As CNNs permanecem válidas quando os recursos computacionais estão disponíveis, com ênfase na CNN-SE VIS+RE+NIR sem balanceamento devido à sua maior acurácia e menor variabilidade.

Figura 21 – Compromisso entre desempenho, estabilidade e custo computacional das principais configurações sem batimetria. Eixo x : tempo médio por *fold* em escala logarítmica; eixo y : $F1$ macro (%); tamanho da bolha: $\sigma(F1$ macro). O SVM+SMOTE destaca-se pela máxima eficiência ($83,8\times$ mais rápido que a CNN-Base; $165\times$ mais rápido que a CNN-SE); a MLP+SMOTE combina desempenho competitivo com a menor variabilidade entre *folds*.



Fonte: Elaborado pelo autor.

4.8 Análise de sensibilidade do número de componentes principais

Após a seleção do *pipeline* PCA+MLP+SMOTE como configuração recomendada no cenário binário Areia vs. Lama, avaliou-se o efeito do número de componentes principais k retidos. A análise variou k sistematicamente de 2 a 255, mantendo fixos o conjunto espectral VIS+NIR+SWIR+AC, a exclusão da batimetria explícita e o balanceamento por SMOTE. A Figura 22 apresenta o comportamento das métricas médias no intervalo de $k = 2$ a $k = 50$, e a Tabela 7 resume valores representativos.


Tabela 7 – Desempenho do modelo PCA+MLP+SMOTE para valores representativos de k (média $\pm$ desvio padrão nos 5 *folds*).

k	Acurácia (%)	Kappa	$F1$ Macro (%)	F1 Lama (%)
2	77,98 $\pm$ 6,82	0,4841 $\pm$ 0,1211	73,11 $\pm$ 6,77	61,81 $\pm$ 8,41
13	92,64 $\pm$ 1,95	0,7812 $\pm$ 0,0474	89,04 $\pm$ 2,40	82,77 $\pm$ 3,49
14	92,50 $\pm$ 2,08	0,7814 $\pm$ 0,0474	89,03 $\pm$ 2,42	82,88 $\pm$ 3,40
15	92,46 $\pm$ 1,80	0,7804 $\pm$ 0,0369	88,98 $\pm$ 1,91	82,80 $\pm$ 2,56
32	92,27 $\pm$ 1,17	0,7703 $\pm$ 0,0232	88,49 $\pm$ 1,18	81,90 $\pm$ 1,58

Fonte: Elaborado pelo autor.

Os resultados indicam que o desempenho melhora substancialmente ao passar de representações muito compactas, como $k = 2$, para uma faixa intermediária. O melhor

Figura 22 – Métricas médias nos cinco *folds* (acurácia, Kappa e *F1 macro*) do modelo PCA+MLP+SMOTE em função do número de componentes principais (k), no intervalo de $k = 2$ a $k = 50$, no cenário binário Areia vs. Lama. Observa-se ganho rápido para valores baixos de k , faixa ótima em torno de $k = 13$ a $k = 15$ e manutenção de desempenho competitivo em $k = 32$, seguida de leves oscilações e ganhos marginais no intervalo exibido.



Fonte: Elaborado pelo autor.


desempenho concentrou-se entre $k = 13$ e $k = 15$: a maior acurácia média e o maior *F1 macro* ocorreram em $k = 13$ (92,64% e 89,04%), enquanto o melhor Kappa e o melhor F1 da lama foram obtidos em $k = 14$ (0,7814 e 82,88%). Acima dessa faixa, os ganhos tornam-se marginais ou ligeiramente negativos. Em $k = 32$, o desempenho permanece competitivo (92,27% de acurácia, Kappa de 0,7703 e *F1 macro* de 88,49%), mas fica abaixo da faixa ótima identificada. Esse comportamento demonstra que o modelo não requer muitos componentes para capturar a informação discriminativa relevante: a maior parte do sinal útil já está concentrada em uma representação espectral compacta, enquanto a inclusão de componentes adicionais tende a produzir ganhos marginais ou ligeiras perdas.

Em termos práticos, a escolha de k deve priorizar a faixa entre 13 e 15 componentes, que oferece o melhor equilíbrio entre compacidade e desempenho.

4.9 Explicabilidade do modelo e interpretação física dos componentes

A Figura 23 sintetiza como a variabilidade espectral é organizada no subespaço PCA para o conjunto VIS+NIR+SWIR+AC, composto pelas bandas B1 (Aerossol Costeiro), B2 (Azul), B3 (Verde), B4 (Vermelho), B8 (NIR), B11 (SWIR-1) e B12 (SWIR-2). Para cada componente, a contribuição de cada banda foi estimada agregando, sobre todos os *pixels* do recorte (96×96), a energia dos pesos da PCA (*loadings*²), normalizando o resultado de modo que somasse 100% em cada PC. Os valores reportados correspondem à média calculada sobre os cinco *folds* de treinamento da validação espacial por blocos.

Figura 23 – Contribuição espectral relativa (%) de cada banda Sentinel-2 por componente principal (PCA, $k = 13$, conjunto VIS+NIR+SWIR+AC), expressa como média nos cinco *folds* de treinamento da validação espacial por blocos de 25 km. Os valores foram obtidos agregando a energia dos *loadings* ($loadings^2$) sobre os *pixels* do recorte (96×96) e normalizando para somar 100% em cada PC. A linha tracejada separa os componentes com variância explicada maior que 1% (PC1–PC4) dos componentes residuais (PC5–PC13). A variância explicada de cada componente é indicada entre parênteses no eixo vertical.



Fonte: Elaborado pelo autor.

A variância explicada é fortemente concentrada nos três primeiros componentes: PC1 explica $61,61\% \pm 0,79\%$, PC2 explica $17,16\% \pm 0,81\%$ e PC3 explica $13,90\% \pm 0,63\%$, totalizando 92,66% da variância acumulada. O PC4 contribui com $1,80\% \pm 0,19\%$, enquanto os demais componentes são residuais, contribuindo cada um com cerca de 0,56% ou menos da variância.

Do ponto de vista espectral, o PC1 apresenta contribuições relativamente distribuídas entre os domínios visível, NIR e SWIR, com leve predominância de B3 (17,0%), B8 (15,7%) e B2 (14,6%), seguidos por B11 (13,8%), B12 (13,6%), B1 (12,9%) e B4 (12,4%). Esse perfil é compatível com um eixo amplo de brilho multiespectral, sem dominância de nenhum domínio espectral específico. O PC2 é dominado por B1 (32,7%), seguido por B2 (24,2%), B4 (21,9%) e B8 (15,9%), com contribuições negligenciáveis de B3, B11 e B12 ($< 3\%$ cada), sugerindo que esse eixo captura contrastes nos comprimentos

de onda curtos e no NIR, possivelmente associados à dispersão atmosférica residual ou a variações de turbidez superficial. O PC3 é marcadamente dominado pelas bandas B11 e B12 ($\approx 29,8\%$ e $30,2\%$, respectivamente), com contribuições secundárias de B3 ($17,8\%$) e B4 ($17,3\%$), capturando o contraste entre SWIR e visível, domínio espectral reconhecidamente sensível às propriedades de turbidez e à composição óptica da coluna d'água (KUTSER et al., 2020; HEDLEY et al., 2018b).

Em paralelo a essa análise de contribuição espectral, foi verificado em que medida os componentes PCA capturam informação correlacionada com a profundidade, mesmo quando a batimetria não é fornecida como entrada ao modelo. Para isso, os *scores* PCA foram correlacionados com a batimetria média estimada sobre a área de cada recorte (96×96), tratada estritamente como variável externa sem participação no treinamento da PCA. A Tabela 8 apresenta os coeficientes de Pearson e Spearman calculados por *fold* sobre o subconjunto de treinamento e agregados como média $\pm$ desvio padrão.

Tabela 8 – Correlação entre *scores* PCA (PC1–PC7) e batimetria média do recorte (96×96), expressa como média $\pm$ desvio padrão nos cinco *folds* de treinamento ($N_{\text{treino}} \approx 1.759$). Conjunto VIS+NIR+SWIR+AC, $k = 13$; batimetria tratada como variável externa, sem participação na PCA.

PC	Var. (%)	Pearson r (média $\pm$ dp)	Spearman ρ (média $\pm$ dp)
PC1	$61,61 \pm 0,79$	$-0,314 \pm 0,002$	$-0,342 \pm 0,002$
PC2	$17,16 \pm 0,81$	$-0,182 \pm 0,080$	$-0,170 \pm 0,048$
PC3	$13,90 \pm 0,63$	$0,506 \pm 0,038$	$0,576 \pm 0,036$
PC4	$1,80 \pm 0,19$	$0,262 \pm 0,046$	$0,339 \pm 0,046$
PC5	$0,56 \pm 0,11$	$0,027 \pm 0,044$	$0,092 \pm 0,041$
PC6	$0,37 \pm 0,03$	$-0,125 \pm 0,043$	$-0,155 \pm 0,046$
PC7	$0,33 \pm 0,05$	$-0,023 \pm 0,031$	$0,032 \pm 0,072$

Fonte: Elaborado pelo autor.

Os resultados revelam um padrão estruturado e fisicamente interpretável de correlação entre os componentes principais e a batimetria. O PC3, dominado pelas bandas SWIR e responsável por $13,90\%$ da variância, exibe a correlação mais expressiva ($r = 0,506 \pm 0,038$; $\rho = 0,576 \pm 0,036$), classificável como moderada a forte e notavelmente estável entre *folds* (coeficientes por *fold*: $r \in [0,44; 0,54]$). Esse resultado é fisicamente coerente: as bandas SWIR são quase completamente absorvidas pela coluna d'água a partir de poucos metros de profundidade (KUTSER et al., 2020; HEDLEY et al., 2018b), de modo que a reflectância nessa região espectral é sistematicamente modulada pela profundidade. Assim, o eixo PC3 codifica implicitamente um gradiente batimétrico mediado pelo comportamento óptico do SWIR, mesmo sem que a batimetria seja fornecida como entrada.

O PC1, eixo amplo de brilho multiespectral responsável por $61,61\%$ da variância, exibe correlação negativa moderada com a batimetria ($r = -0,314 \pm 0,002$; $\rho = -0,342 \pm 0,002$), compatível com a redução de brilho total em locais mais profundos, onde a absorção da coluna d'água atenua simultaneamente o sinal de fundo em múltiplos comprimentos de onda. A estabilidade dessa correlação entre *folds* ($r \in [-0,32; -0,31]$) indica que ela

reflete um padrão geoespacial estrutural da cena, e não ruído amostral. O PC2 apresenta correlação fraca em média ($r = -0,182$), mas com alta variabilidade entre *folds* ($\sigma = 0,080$; amplitude $r \in [-0,28; -0,08]$), sugerindo que a relação desse eixo com a batimetria é instável e depende da composição geográfica de cada partição espacial. Essa instabilidade inter-*fold* do PC2 constitui, por si só, evidência de que o modelo não opera exclusivamente por atalhos batimétricos: se o desempenho dependesse predominantemente desse gradiente de profundidade codificado pelo PC2, seria esperada maior consistência entre partições. O PC4 exibe correlação moderada ($r = 0,262 \pm 0,046$; $\rho = 0,339 \pm 0,046$), indicando que parte da variância residual capturada por esse componente também carrega sinal batimétrico. Os componentes PC5 e PC7 apresentam correlações negligenciáveis ($|r| < 0,03$), enquanto o PC6 exibe correlação fraca e relativamente consistente ($r = -0,125 \pm 0,043$).

Esses resultados têm implicações diretas para a interpretação dos experimentos de batimetria apresentados anteriormente. O fato de o PC3, responsável por 13,90% da variância e presente entre os 13 componentes utilizados pelo classificador, já codificar um gradiente batimétrico robusto ($r \approx 0,51$) explica mecanisticamente por que a inclusão explícita da batimetria oferece ganho marginal ou nulo para a maioria dos modelos: a informação batimétrica já está implicitamente disponível na representação espectral comprimida. Da mesma forma, a correlação moderada do PC1 com a batimetria reforça que o classificador tem acesso a informações relacionadas à profundidade por múltiplos eixos espectrais. Ainda assim, a existência desse proxy implícito não implica que o classificador opere predominantemente por atalhos batimétricos: os modelos apenas-batimetria demonstram que a profundidade por si só é claramente insuficiente (60,90% vs. 89,04% de *F1 macro*), e a instabilidade inter-*fold* do PC2 indica que a decisão do modelo é sustentada pela estrutura radiométrica de amplo espectro, e não exclusivamente pela covariância profundidade-sedimento codificada no PC3. No entanto, a presença desse componente implícito relacionado à profundidade significa que efeitos residuais de aprendizado de proxies podem ainda influenciar a fronteira de decisão aprendida e devem ser considerados na interpretação do desempenho reportado, particularmente em regiões onde profundidade e composição sedimentar tendem a ser espacialmente associadas, como o setor amazônico da MEB.

4.10 Síntese dos resultados

Os resultados do cenário binário Areia vs. Lama, obtidos sob validação espacial por blocos de 25 km com cinco *folds*, podem ser sintetizados em sete achados principais:

1. **Similaridade estatística entre famílias arquiteturais no espaço experimental avaliado:** as configurações com maior *F1 macro*, abrangendo cinco famílias (CNN-Base, CNN-SE, SVM, MLP e EffNetV2-B0 Fusion), não diferiram significati-

vamente entre si em *F1 macro*, acurácia ou Kappa (Friedman $\chi^2 = 3,629$, $p = 0,604$; todos os 15 testes t pareados com $p > 0,05$). Entre as quatro melhores configurações, as diferenças nominais em *F1 macro* são inferiores a 0,5 p.p., permanecendo menores que a dispersão inter-*fold* de cada modelo individualmente. Embora os modelos leves baseados em PCA tenham alcançado desempenho comparável às arquiteturas convolucionais avaliadas, essa comparação restringe-se às configurações testadas. Os *baselines* de aprendizado profundo foram concebidos como arquiteturas representativas para comparação controlada e não foram submetidos a *data augmentation* exaustivo, busca de arquiteturas ou otimização sistemática de hiperparâmetros. Portanto, a ausência de diferenças estatisticamente significativas deve ser interpretada como evidência de competitividade do *pipeline* leve proposto neste cenário experimental, e não como afirmação geral de equivalência com modelos de aprendizado profundo completamente otimizados.

2. **Contribuição espectral assimétrica entre famílias de modelos:** a expansão de bandas além do visível beneficiou monotonicamente a MLP (de 86,13% com RGB a 88,49% com VIS+NIR+SWIR+AC, +2,36 p.p.), mas a adição de conjuntos mais amplos reverteu marginalmente esse ganho, sugerindo que bandas com menor relevância discriminativa introduzem ruído na projeção PCA. Para a CNN-SE, a variação entre os sete conjuntos espectrais foi irregular e inferior a 1 p.p., sem vantagem sistemática de configurações mais amplas sobre RGB.
3. **Batimetria como complemento condicional; batimetria insuficiente como preditor isolado:** a batimetria explícita foi significativamente benéfica apenas para o SVM com *Full S2* e SMOTE ($p = 0,040$), neutra para a maioria dos modelos e significativamente prejudicial para a CNN-Base com *focal loss* ($p = 0,022$). O experimento de embaralhamento confirmou que a informação espectral é o preditor dominante: com batimetria aleatória, o *F1 macro* da MLP caiu 6,79 p.p., ficando abaixo até mesmo do desempenho sem batimetria. De forma mais conclusiva, os modelos apenas-batimetria demonstraram que a profundidade por si só é insuficiente para sustentar a discriminação sedimentar: o melhor modelo apenas-batimetria (MLP, ADASYN) alcançou 60,90% de *F1 macro*, frente a 89,04% do *pipeline* espectral completo, uma diferença de 28 p.p. que confirma que a discriminação entre areia e lama é sustentada primariamente por assinaturas espectrais.
4. **Estabilidade e eficiência dos modelos leves:** a MLP+SMOTE apresentou os menores desvios padrão entre as configurações de topo avaliadas (desvio padrão de *F1 macro* de 1,18 p.p.). O SVM completou cada *fold* em 0,61 s, sendo mais de 83 vezes mais rápido que a CNN-Base e aproximadamente 165 vezes mais rápido que a CNN-SE, sem perda de desempenho estatisticamente detectável em relação às configurações representativas comparadas.

5. **Complexidade arquitetural sem retorno proporcional no espaço experimental avaliado:** as variantes EffNetV2-B0, apesar de serem as mais pesadas (185–198 s por *fold*) e incorporarem mecanismos sofisticados de transferência e atenção, não superaram as CNNs customizadas nem os classificadores leves nas configurações avaliadas. Isso sugere que o problema binário, na resolução do Sentinel-2, pode ser governado por assinaturas espectrais compactas que não requerem representações hierárquicas profundas, embora essa interpretação esteja restrita às configurações testadas e não deva ser generalizada para *pipelines* de aprendizado profundo completamente otimizados.
6. **Compacidade do sinal discriminativo:** a análise de sensibilidade do número de componentes principais revelou que apenas 13 a 15 componentes são suficientes para atingir o desempenho ótimo: *F1 macro* de 89,04% com $k = 13$ e melhor Kappa e *F1* da lama com $k = 14$. Acima de $k \approx 15$, os ganhos são marginais ou ligeiramente revertidos. Esse achado demonstra que o problema é governado por um conjunto compacto de padrões radiométricos, e não pela variância espectral total disponível.
7. **Proxy batimétrico implícito codificado pela PCA e sua limitação preditiva:** a análise de explicabilidade revelou que o PC3, dominado pelas bandas SWIR e responsável por 13,90% da variância, exibe correlação moderada a forte com a batimetria ($r \approx 0,51$, estável entre *folds*), mostrando que a representação espectral comprimida já codifica implicitamente um gradiente de profundidade pelo comportamento óptico do SWIR. Esse mecanismo físico explica por que a batimetria explícita oferece ganho marginal ou nulo para a maioria dos modelos. No entanto, a existência desse proxy implícito não implica que o classificador opere predominantemente por atalhos batimétricos: os modelos apenas-profundidade demonstram que a batimetria por si só é claramente insuficiente (60,90% vs. 89,04%), e a instabilidade inter-*fold* do PC2 indica que a decisão do modelo é sustentada pela estrutura espectral de amplo espectro, e não exclusivamente pela covariância profundidade–sedimento codificada no PC3. Ainda assim, a presença desse componente implícito relacionado à profundidade significa que efeitos residuais de aprendizado de proxies podem influenciar a fronteira de decisão aprendida, e essa possibilidade deve ser considerada na interpretação do desempenho reportado, particularmente no setor da MEB sob influência amazônica, onde profundidade e composição sedimentar tendem a ser espacialmente associadas.

Esses achados convergem para a adoção do *pipeline* MLP+PCA+SMOTE com $k = 13$ como configuração recomendada. Os valores reportados neste capítulo e no resumo correspondem à versão final otimizada do *pipeline* MLP+PCA+SMOTE após a análise de sensibilidade do número de componentes principais. As tabelas de comparação global

apresentadas anteriormente resumem a etapa de triagem de arquiteturas e conjuntos espectrais utilizada para identificar a família de *pipeline* mais competitiva antes dessa otimização final. Na configuração otimizada, o modelo recomendado alcançou *F1 macro* de 89,04%, acurácia de 92,64% e Kappa de 0,781, com desvio entre *folds* de 2,40 p.p. e custo aproximadamente 6,6 vezes menor que o da CNN-Base. Para o mapeamento regional com inferência repetida em grandes áreas costeiras, estabilidade e eficiência pesam tanto quanto o desempenho nominal. Nesse balanço, a MLP+SMOTE se destaca.

4.11 Consistência espacial e interpretação geológica


A Figura 24 apresenta o mapa exploratório regional de dominância sedimentar obtido pela inferência direta do modelo MLP+PCA+SMOTE sem batimetria explícita, com $k = 13$, treinado no conjunto completo de 2.199 amostras, aplicado a uma grade independente de 606 nós e representado por tesselação de Voronoi dissolvida e suavizada, restrita à isóbata de -30 m. As Figuras 25 e 26 detalham, respectivamente, os domínios de areia e lama.

A análise visual revela padrão regional coerente ao longo da MEB, delineando domínios sedimentares compatíveis com os padrões descritos na literatura geológica para essa faixa batimétrica. Os domínios de lama concentram-se predominantemente no setor sob influência direta da foz do Rio Amazonas, compatível com a dinâmica deposicional da plataforma interna amazônica, onde a elevada carga de sedimentos finos em suspensão e a acumulação no Delta Submarino do Amazonas são processos dominantes (FILHO et al., 2025a). Santos Filho et al. (FILHO et al., 2025a), com base em 5.515 amostras físicas e integração de atributos sísmicos, identificaram coberturas lamosas concentradas próximas às desembocaduras dos rios Amazonas e Pará, padrão espacialmente compatível com os domínios de lama mapeados pelo modelo óptico supervisionado no intervalo de 0 a -30 m. A convergência entre os dois conjuntos de evidências, independentes em metodologia e período de aquisição, é consistente com a plausibilidade dos domínios identificados em escala cartográfica.

Em contraste, a areia organiza-se como faixa costeira contínua e persistente, especialmente no setor leste, abrangendo as bacias do Ceará e Potiguar. Essa distribuição reflete condições de alta energia hidrodinâmica na plataforma interna semiárida, onde a ação intensa da Corrente Sul Equatorial e dos ventos alísios dificulta a deposição de finos e favorece sedimentos siliciclásticos arenosos (VITAL et al., 2010). No escopo binário Areia vs. Lama adotado neste estudo, depósitos bioclásticos rasos compostos por algas calcárias, briozoários e fragmentos biosqueléticos tendem a ser absorvidos na classe areia, uma limitação interpretativa inerente ao escopo preditivo que não contradiz, mas complementa, o mapeamento granulométrico de referência.


Para quantificar a concordância cartográfica com o mapeamento independente

Figura 24 – Mapa regional exploratório de dominância sedimentar Areia vs. Lama obtido por inferência direta do modelo MLP+PCA+SMOTE sobre uma grade independente de 606 nós, restrita à isóbata de -30 m e representada por tesselação de Voronoi dissolvida por classe dominante e suavizada. (a) Mapa integrado Areia vs. Lama.




Fonte: Elaborado pelo autor.

Figura 25 – Domínios de areia: polígonos correspondentes aos nós da grade com predição dominante de areia.



Fonte: Elaborado pelo autor.

Figura 26 – Domínios de lama: polígonos correspondentes aos nós da grade com predição dominante de lama.



Fonte: Elaborado pelo autor.

de Santos Filho et al. (FILHO et al., 2025a), a classe granulométrica dominante desse produto foi extraída nos 606 nós de inferência da grade regular e comparada às predições do modelo óptico supervisionado. Dos 606 nós, 53 estavam localizados fora da cobertura espacial do mapeamento de referência e 23 coincidiam com polígonos classificados como cascalho, classe não prevista pelo modelo binário, totalizando 76 nós excluídos da comparação. A análise de concordância cartográfica foi conduzida sobre os 530 nós comparáveis restantes.

Tabela 9 – Métricas de concordância cartográfica entre o modelo óptico (MLP+PCA+SMOTE, $k = 13$) e o mapeamento sedimentológico independente de Santos Filho et al. (FILHO et al., 2025a), nos 530 nós comparáveis da grade regular.[†]

Classe	Nós (ref.)	Concordâncias	Concordância (%)	Precisão (%)	F1 (%)
Areia	259	220	84,9	84,3	84,6
Lama	271	230	84,9	85,5	85,2
Geral	530	450	84,9	84,9	84,9

Fonte: Elaborado pelo autor.

A taxa de concordância geral foi de 84,9%, com concordância idêntica para areia e lama. A precisão foi de 84,3% para areia e 85,5% para lama, enquanto o *F1 macro* alcançou 84,9%, refletindo desempenho equilibrado entre as duas classes, sem viés sistemático em favor de nenhuma delas. Essa comparação deve ser interpretada como análise de consistência cartográfica regional entre produtos independentes, e não como validação pontual contemporânea do estado atual do fundo marinho, uma vez que nenhum conjunto de dados *in situ* independente e contemporâneo está disponível para validação direta no intervalo de 0 a 30 m da MEB.


A coerência dos domínios obtidos é adicionalmente corroborada por Santos Filho et al. (FILHO et al., 2025b), que mapearam bioclásticos e cascalhos carbonáticos na zona mesofótica da margem brasileira (30–200 m). Esses autores identificaram maiores concentrações carbonáticas próximas a 50 m nos setores da Costa Semiárida, especialmente nas bacias do Ceará e Potiguar, enquanto as margens da Foz do Amazonas e Pará-Maranhão apresentaram menores proporções carbonáticas nessa faixa. Esse padrão é diretamente coerente com a dominância de areia no setor leste e de lama no setor noroeste identificada pelo modelo óptico no intervalo de 0 a –30 m. O presente trabalho preenche, portanto, a lacuna batimétrica entre os mapeamentos de Santos Filho et al. (FILHO et al., 2025a; FILHO et al., 2025b), cobrindo sistematicamente a plataforma interna rasa com uma metodologia viável exclusivamente nessa faixa óptica, e estabelecendo uma cadeia de produtos complementares que abrange desde a superfície até 200 m de profundidade ao longo da MEB.

A análise visual dos painéis individuais também revela zonas de transição complexas entre os domínios de areia e lama, caracterizadas por mosaico mais fragmentado.

Essas zonas são consistentes com a variabilidade de turbidez em águas rasas e com as interfaces entre as áreas sob influência da pluma amazônica e os setores de alta energia da plataforma, reforçando a capacidade do modelo de capturar gradientes regionais em ambientes opticamente complexos.

A Figura 27 apresenta o Índice de Equilíbrio Binário nos 606 nós de inferência. Observa-se que 76,6% dos nós apresentam valores abaixo de 0,05, indicando clara dominância de uma das classes na maior parte da área de estudo. Os 95 nós com índice maior ou igual a 0,2 concentram-se principalmente nas zonas de transição entre domínios sedimentares, especialmente nas interfaces areia-lama sob influência da pluma amazônica e próximas a setores com ocorrência de bioclásticos descritos por Santos Filho et al. (FILHO et al., 2025a; FILHO et al., 2025b), onde a classificação binária é naturalmente mais ambígua. Em contraste, os menores valores predominam em áreas com dominância mais estável de uma das classes, corroborando o uso do índice como descritor complementar e descritivo da organização espacial do mapa de dominância.

Figura 27 – Índice de equilíbrio binário heurístico nos 606 nós da grade de inferência. (a) Distribuição dos nós por faixa de índice: 76,6% apresentam valores abaixo de 0,05, indicando clara dominância de uma classe. (b) Localização espacial dos 95 nós com índice $\geq 0,2$ (ambiguidade local), sobrepostos aos demais 511 nós em cinza (dominância clara); a escala de cores indica a intensidade do equilíbrio entre as classes Areia e Lama. O índice é apresentado apenas como descritor heurístico de ambiguidade local, e não como medida calibrada de incerteza preditiva.



Fonte: Elaborado pelo autor.

4.12 Limitações e validade temporal dos dados

A compatibilidade entre o acervo sedimentológico histórico (1956–2004) e as imagens Sentinel-2 (2017–2024) foi tratada como hipótese operacional plausível em escala cartográfica. Na plataforma interna da MEB, forçantes hidrodinâmicas de larga escala e herança estratigráfica favorecem a persistência de fácies dominantes em escala decadal (KUEHL; DEMASTER; NITTROUER, 1986; APRILE et al., 2019), embora mudanças

locais não possam ser descartadas. O intervalo temporal pode introduzir ruído nos rótulos e limitar inferências em nível pontual, mas não invalida o uso do *pipeline* para mapeamento em escala regional. No conjunto de dados analisado, esse efeito parece ser parcialmente mitigado pelo volume amostral, pela curadoria conservadora e pela validação espacial por blocos, o que é compatível com a convergência qualitativa observada em relação aos mapeamentos independentes de Santos Filho et al. (FILHO et al., 2025a; FILHO et al., 2025b).

A principal limitação do estudo é a ausência de dados *in situ* contemporâneos independentes para validação pontual no intervalo de 0 a 30 m da MEB no período de aquisição das imagens (2017–2024). Assim, a concordância com mapeamentos sedimentológicos prévios deve ser entendida exclusivamente como consistência cartográfica regional, e não como validação indireta do estado atual do fundo marinho. Os testes estatísticos com cinco *folds* também devem ser interpretados com cautela em razão do poder estatístico limitado dessa configuração.

Em regiões de alta turbidez, como a foz do Rio Amazonas, a classificação pode ser parcialmente influenciada por correlações indiretas entre o material em suspensão na coluna d’água e o tipo de fundo, fenômeno relacionado à resuspensão de sedimentos. Embora os experimentos de batimetria exclusiva e de embaralhamento indiquem que a discriminação sedimentar não é conduzida exclusivamente pela profundidade, efeitos indiretos de aprendizado de proxies relacionados a gradientes batimétricos — particularmente por meio de componentes espectrais correlacionados com a profundidade, como o PC3, não podem ser completamente excluídos e devem ser considerados na interpretação do desempenho do modelo.

Outra limitação relevante é a restrição ao cenário binário Areia vs. Lama. Essa restrição foi imposta pela insuficiência amostral da classe cascalho, que permaneceu com apenas 134 amostras concentradas em poucos blocos após a curadoria conservadora e a seleção espacial. A exclusão do cascalho no escopo final é, portanto, consequência direta do protocolo rigoroso de independência geográfica e não uma simplificação arbitrária.

Apesar dessas limitações, os resultados demonstram que abordagens leves, reprodutíveis, acompanhadas de curadoria conservadora e validação espacial adequada podem complementar levantamentos acústicos tradicionais e contribuir para o monitoramento sedimentar em larga escala em regiões costeiras opticamente complexas.

5 CONSIDERAÇÕES FINAIS

Esta tese apresentou um *pipeline* de aprendizado de máquina para classificação de sedimentos do fundo marinho usando imagens multiespectrais Sentinel-2, com aplicação à plataforma rasa da Margem Equatorial Brasileira. Em função da limitação amostral e da concentração espacial da classe cascalho após a curadoria, o escopo final de modelagem foi definido no cenário binário Areia vs Lama. A abordagem combinou curadoria conservadora de rótulos históricos, validação espacial por blocos de 25 km, redução de dimensionalidade por PCA, classificação por MLP e tratamento do desbalanceamento por SMOTE.

Os resultados sob validação espacial indicaram que classificadores leves baseados em PCA podem alcançar desempenho competitivo em relação às arquiteturas profundas avaliadas. Não foi detectada superioridade estatística entre as principais famílias de modelos em F1 macro, acurácia ou Kappa. Dentro desse conjunto experimental, o *pipeline* MLP+PCA+SMOTE apresentou o melhor equilíbrio entre estabilidade, eficiência computacional e desempenho para discriminação entre areia e lama. A configuração otimizada com $k = 13$ componentes principais alcançou acurácia de 92,64%, F1 macro de 89,04% e Kappa de 0,781, com custo aproximadamente 6,6 vezes menor que o da CNN-Base.

A análise de sensibilidade demonstrou que poucos componentes principais são suficientes para capturar o sinal discriminativo dominante. A faixa entre $k = 13$ e $k = 15$ concentrou o melhor desempenho, indicando que a classificação é governada por padrões radiométricos compactos, e não pela necessidade de explorar toda a dimensionalidade original dos recortes. A análise de explicabilidade mostrou ainda que parte do gradiente batimétrico é implicitamente codificada em componentes espectrais, especialmente no PC3, dominado por bandas SWIR. No entanto, os experimentos com batimetria isolada e batimetria embaralhada demonstraram que a profundidade, por si só, é insuficiente para sustentar o desempenho observado.

A comparação cartográfica com mapeamento sedimentológico independente revelou concordância regional de 84,9%, com equilíbrio entre as classes areia e lama. Os domínios mapeados são coerentes com o conhecimento geológico da região: lama predominando no setor sob influência amazônica e areia formando faixa persistente, especialmente nos setores do Ceará e Potiguar. Essa convergência indica consistência cartográfica em escala regional, mas não deve ser interpretada como validação contemporânea *in situ* do estado atual do fundo marinho.

As principais limitações do estudo estão associadas à defasagem temporal entre os dados sedimentológicos históricos (1956–2004) e as imagens Sentinel-2 (2017–2024), à ausência de observações de campo contemporâneas no intervalo de 0 a 30 m e à restrição do escopo final ao cenário binário Areia vs Lama. Essas limitações são particularmente

importantes para interpretações pontuais e para extrapolações fora da área e do acervo avaliados.

Como trabalhos futuros, recomenda-se incorporar campanhas sedimentológicas recentes e padronizadas, explorar fusão com dados acústicos e multissensores, investigar estratégias formais de quantificação de incerteza, como calibração probabilística, *ensembles* ou abordagens bayesianas, e reavaliar a classe cascalho a partir de novos dados capazes de sustentar validação espacial independente.

Em síntese, os resultados demonstram que abordagens leves, reprodutíveis e computacionalmente eficientes podem constituir uma alternativa viável para o mapeamento regional de sedimentos em ambientes costeiros opticamente complexos, desde que acompanhadas por curadoria rigorosa, validação espacial adequada e interpretação cautelosa das limitações temporais e geológicas do problema.

REFERÊNCIAS

- ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. In: IEEE. *2017 international conference on engineering and technology (ICET)*. [S.l.], 2017. p. 1–6. Citado na página 36.
- APRILE, F. et al. Sedimentary transport influences on diagenetic processes at the amazon continental shelf, brazil. *Journal of Geography, Environment and Earth Science International*, Sciencedomain International, p. 1–16, abr. 2019. ISSN 2454-7352. Disponível em: <<http://dx.doi.org/10.9734/JGEESI/2019/v20i430113>>. Citado 2 vezes nas páginas 47 e 82.
- ARAÚJO, L. S. et al. Growing industrialization and poor conservation planning challenge natural resources' management in the amazon shelf off brazil. *Marine Policy*, Elsevier BV, v. 128, p. 104465, jun. 2021. ISSN 0308-597X. Disponível em: <<http://dx.doi.org/10.1016/j.marpol.2021.104465>>. Citado 2 vezes nas páginas 26 e 44.
- ASSAD, L. P. de F. et al. Ocean climatology at brazilian equatorial margin: A numerical approach. *Journal of Computational Science*, Elsevier BV, v. 44, p. 101159, jul. 2020. ISSN 1877-7503. Disponível em: <<http://dx.doi.org/10.1016/j.jocs.2020.101159>>. Citado na página 44.
- AZEVEDO, L. P. de. Aplicação de redes neurais artificiais no processo de classificação de orquídeas do gênero cattleya. *Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) - Instituto Federal de Minas Gerais*, 2016. Citado 3 vezes nas páginas 31, 32 e 35.
- BA, J. L.; KIROS, J. R.; HINTON, G. E. *Layer Normalization*. arXiv, 2016. Disponível em: <<https://arxiv.org/abs/1607.06450>>. Citado na página 40.
- BAKER, E.; PUGLISE, K.; HARRIS, P. *Mesophotic coral ecosystems: A lifeboat for coral reefs?* [S.l.: s.n.], 2016. ISBN 978-82-7701-150-9. Citado na página 16.
- BAKER, E. K.; HARRIS, P. T. Habitat mapping and marine management. In: _____. *Seafloor Geomorphology as Benthic Habitat*. Elsevier, 2020. p. 17–33. ISBN 9780128149607. Disponível em: <<http://dx.doi.org/10.1016/b978-0-12-814960-7.00002-6>>. Citado na página 17.
- BIOUCAS-DIAS, J. M. et al. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Institute of Electrical and Electronics Engineers (IEEE), v. 5, n. 2, p. 354–379, abr. 2012. ISSN 2151-1535. Disponível em: <<http://dx.doi.org/10.1109/JSTARS.2012.2194696>>. Citado na página 27.
- BLOTT, S. J.; PYE, K. GRADISTAT: a grain size distribution and statistics package for the analysis of unconsolidated sediments. *Earth Surface Processes and Landforms*, v. 26, n. 11, p. 1237–1248, 2001. Citado na página 18.
- BOSENCE, D. Carbonate shorelines and shelves. In: _____. *Encyclopedia of Geology*. Elsevier, 2021. p. 942–954. ISBN 9780081029091. Disponível em:

<<http://dx.doi.org/10.1016/B978-0-12-409548-9.11848-2>>. Citado 2 vezes nas páginas 16 e 17.

BOSWARVA, K. et al. Improving marine habitat mapping using high-resolution acoustic data; a predictive habitat map for the firth of lorn, scotland. *Continental Shelf Research*, Elsevier BV, v. 168, p. 39–47, set. 2018. ISSN 0278-4343. Disponível em: <<http://dx.doi.org/10.1016/j.csr.2018.09.005>>. Citado na página 16.

BOTHA, E. J. et al. Increased spectral resolution enhances coral detection under varying water conditions. *Remote Sensing of Environment*, Elsevier BV, v. 131, p. 247–261, abr. 2013. ISSN 0034-4257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2012.12.021>>. Citado na página 27.

BRENAN, C. et al. Seafloor sediment characterization to improve estimate of organic carbon standing stocks in continental shelves. Copernicus GmbH, jan. 2024. Disponível em: <<http://dx.doi.org/10.5194/egusphere-2024-5>>. Citado na página 21.

BRISSET, M. et al. Hindcast and near real-time monitoring of green macroalgae blooms in shallow coral reef lagoons using sentinel-2: A new-caledonia case study. *Remote Sensing*, MDPI AG, v. 13, n. 2, p. 211, jan. 2021. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs13020211>>. Citado 2 vezes nas páginas 27 e 28.

BULGARELLI, B.; KISELEV, V.; ZIBORDI, G. Adjacency effects in satellite radiometric products from coastal waters: a theoretical analysis for the northern adriatic sea. *Applied Optics*, Optica Publishing Group, v. 56, n. 4, p. 854, jan. 2017. ISSN 1539-4522. Disponível em: <<http://dx.doi.org/10.1364/AO.56.000854>>. Citado na página 27.

CABALLERO, I.; STUMPF, R. P. Confronting turbidity, the major challenge for satellite-derived coastal bathymetry. *Science of The Total Environment*, Elsevier BV, v. 870, p. 161898, abr. 2023. ISSN 0048-9697. Disponível em: <<http://dx.doi.org/10.1016/j.scitotenv.2023.161898>>. Citado 3 vezes nas páginas 19, 31 e 47.

CAPIZZANO, C. W. et al. Mapping seafloor sediment distributions using public geospatial data and machine learning to support regional offshore renewable energy development. *Geosciences*, MDPI AG, v. 14, n. 7, p. 186, jul. 2024. ISSN 2076-3263. Disponível em: <<http://dx.doi.org/10.3390/geosciences14070186>>. Citado na página 21.

CHAMI, M. et al. Analysis and quantification of seabed adjacency effects in the subsurface upward radiance in shallow waters. *Optics Express*, Optica Publishing Group, v. 27, n. 8, p. A319, mar. 2019. ISSN 1094-4087. Disponível em: <<http://dx.doi.org/10.1364/OE.27.00A319>>. Citado na página 27.

CHAVES, E. de L. Detecção de câncer de mama por meio de imagens infravermelhas utilizando redes neurais convolucionais. *Trabalho de Conclusão de Curso (Graduação em Ciência da Computação)* - Universidade Federal de Uberlândia, 2019. Citado 2 vezes nas páginas 35 e 36.

CHAWLA, N. V. et al. Smote: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, AI Access Foundation, v. 16, p. 321–357, jun. 2002. ISSN 1076-9757. Disponível em: <<http://dx.doi.org/10.1613/jair.953>>. Citado 2 vezes nas páginas 21 e 56.

- CHEN, B. et al. *Graph-based Active Learning for Surface Water and Sediment Detection in Multispectral Images*. arXiv, 2023. Disponível em: <<https://arxiv.org/abs/2306.10440>>. Citado na página 20.
- CLARKE, J. E. H.; MAYER, L. A.; WELLS, D. E. Shallow-water imaging multibeam sonars: A new tool for investigating seafloor processes in the coastal zone and on the continental shelf. *Marine Geophysical Researches*, Springer Science and Business Media LLC, v. 18, n. 6, p. 607–629, dez. 1996. ISSN 1573-0581. Disponível em: <<http://dx.doi.org/10.1007/BF00313877>>. Citado 2 vezes nas páginas 16 e 17.
- COHEN, J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, SAGE Publications, v. 20, n. 1, p. 37–46, abr. 1960. ISSN 1552-3888. Disponível em: <<http://dx.doi.org/10.1177/001316446002000104>>. Citado na página 58.
- COLLIN, A. et al. Mapping sub-metre 3d land-sea coral reefs using superspectral worldview-3 satellite stereoisimagery. *Oceans*, MDPI AG, v. 2, n. 2, p. 315–329, abr. 2021. ISSN 2673-1924. Disponível em: <<http://dx.doi.org/10.3390/oceans2020018>>. Citado na página 27.
- COLLIN, A.; ARCHAMBAULT, P.; PLANES, S. Bridging ridge-to-reef patches: Seamless classification of the coast using very high resolution satellite. *Remote Sensing*, MDPI AG, v. 5, n. 7, p. 3583–3610, jul. 2013. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs5073583>>. Citado na página 27.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, Elsevier BV, v. 37, n. 1, p. 35–46, jul. 1991. ISSN 0034-4257. Disponível em: <[http://dx.doi.org/10.1016/0034-4257\(91\)90048-B](http://dx.doi.org/10.1016/0034-4257(91)90048-B)>. Citado na página 58.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, Springer Science and Business Media LLC, v. 20, n. 3, p. 273–297, set. 1995. ISSN 1573-0565. Disponível em: <<http://dx.doi.org/10.1007/BF00994018>>. Citado na página 55.
- DEGRAER, S. et al. Habitat suitability modelling as a mapping tool for macrobenthic communities: An example from the belgian part of the north sea. *Continental Shelf Research*, Elsevier BV, v. 28, n. 3, p. 369–379, fev. 2008. ISSN 0278-4343. Disponível em: <<http://dx.doi.org/10.1016/j.csr.2007.09.001>>. Citado 2 vezes nas páginas 16 e 17.
- DSA. *Deep Learning Book*. 2022. Disponível em: <<https://www.deeplearningbook.com.br/>>. Citado na página 36.
- EBEL, P. et al. Multisensor data fusion for cloud removal in global and all-season sentinel-2 imagery. *IEEE Transactions on Geoscience and Remote Sensing*, Institute of Electrical and Electronics Engineers (IEEE), v. 59, n. 7, p. 5866–5878, jul. 2021. ISSN 1558-0644. Disponível em: <<http://dx.doi.org/10.1109/TGRS.2020.3024744>>. Citado 2 vezes nas páginas 28 e 29.
- ESA, E. S. A. *Sentinel-2 ESA Bulletin*. 2015. <https://esamultimedia.esa.int/docs/EarthObservation/Sentinel-2_ESA_Bulletin161.pdf>. [Accessed 11-02-2025]. Citado na página 28.

- EUGENIO, F.; MARCELLO, J.; MARTIN, J. High-resolution maps of bathymetry and benthic habitats in shallow-water environments using multispectral remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, Institute of Electrical and Electronics Engineers (IEEE), v. 53, n. 7, p. 3539–3549, jul. 2015. ISSN 1558-0644. Disponível em: <<http://dx.doi.org/10.1109/TGRS.2014.2377300>>. Citado na página 29.
- FIGUEIREDO, A. G. et al. Continental shelf geomorphology and sedimentology. In: _____. *Geology and Geomorphology*. Elsevier, 2016. p. 13–31. ISBN 9788535284447. Disponível em: <<http://dx.doi.org/10.1016/b978-85-352-8444-7.50009-3>>. Citado na página 17.
- FILHO, J. R. d. S. *Geomorfologia e sedimentologia da plataforma continental brasileira com base na estruturação de um banco de dados como subsídio ao estudo de ambientes carbonáticos mesofóticos e da evolução sedimentar*. Tese (Tese de doutorado) — Universidade Federal Fluminense, Niterói, 2022. Citado 2 vezes nas páginas 25 e 26.
- FILHO, J. R. d. S. et al. Mesophotic encrusting biotas and bioclastic deposits on the western south atlantic equatorial margin: Geomorphological insights from the amazon and semi-arid coast systems. *Marine Geology*, Elsevier BV, v. 484, p. 107544, jun. 2025. ISSN 0025-3227. Disponível em: <<http://dx.doi.org/10.1016/j.margeo.2025.107544>>. Citado 10 vezes nas páginas 11, 17, 19, 25, 27, 44, 79, 81, 82 e 83.
- FILHO, J. R. d. S. et al. Unveiling the mesophotic south atlantic reef system (sars): Mapping, evolution, and implications for marine spatial planning (msp) in the western south atlantic. *Journal of Marine Systems*, Elsevier BV, v. 251, p. 104119, out. 2025. ISSN 0924-7963. Disponível em: <<http://dx.doi.org/10.1016/j.jmarsys.2025.104119>>. Citado 7 vezes nas páginas 17, 19, 25, 61, 81, 82 e 83.
- FILHO, J. R. d. S. et al. Mesophotic bioclastics and bioconstructions at the continental shelf of santos basin, brazil. *Sedimentary Geology*, Elsevier BV, v. 442, p. 106294, dez. 2022. ISSN 0037-0738. Disponível em: <<http://dx.doi.org/10.1016/j.sedgeo.2022.106294>>. Citado na página 17.
- GALVEZ, D. et al. Ensemble mapping and change analysis of the seafloor sediment distribution in the sylt outer reef, german north sea from 2016 to 2018. *Water*, MDPI AG, v. 13, n. 16, p. 2254, ago. 2021. ISSN 2073-4441. Disponível em: <<http://dx.doi.org/10.3390/w13162254>>. Citado na página 19.
- GHOLAMALINEZHAD, H.; KHOSRAVI, H. *Pooling Methods in Deep Neural Networks, a Review*. arXiv, 2020. Disponível em: <<https://arxiv.org/abs/2009.07485>>. Citado na página 39.
- GINSBURG, R. N.; JAMES, N. P. Holocene carbonate sediments of continental shelves. In: _____. *The Geology of Continental Margins*. Springer Berlin Heidelberg, 1974. p. 137–155. ISBN 9783662011416. Disponível em: <http://dx.doi.org/10.1007/978-3-662-01141-6_11>. Citado na página 17.
- GONZÁLEZ, M. O. A. et al. Regulation for offshore wind power development in brazil. *Energy Policy*, Elsevier BV, v. 145, p. 111756, out. 2020. ISSN 0301-4215. Disponível em: <<http://dx.doi.org/10.1016/j.enpol.2020.111756>>. Citado na página 16.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>. Citado na página 36.

GORDON, H. R. Removal of atmospheric effects from satellite imagery of the oceans. *Applied Optics*, Optica Publishing Group, v. 17, n. 10, p. 1631, maio 1978. ISSN 1539-4522. Disponível em: <<http://dx.doi.org/10.1364/AO.17.001631>>. Citado na página 30.

GU, J. et al. Recent advances in convolutional neural networks. *Pattern recognition*, Elsevier, v. 77, p. 354–377, 2018. Citado na página 36.

GUILLAUME, M.; MICHELS, Y.; JAY, S. Joint estimation of water column parameters and seabed reflectance combining maximum likelihood and unmixing algorithm. In: *2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. IEEE, 2015. p. 1–4. Disponível em: <<http://dx.doi.org/10.1109/WHISPERS.2015.8075496>>. Citado na página 27.

GUILLAUME, M. et al. Mapping benthic habitats by extending non-negative matrix factorization to address the water column and seabed adjacency effects. *Remote Sensing*, MDPI AG, v. 12, n. 13, p. 2072, jun. 2020. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs12132072>>. Citado na página 27.

HAN, H.; WANG, W.-Y.; MAO, B.-H. Borderline-smote: A new over-sampling method in imbalanced data sets learning. In: _____. *Advances in Intelligent Computing*. Springer Berlin Heidelberg, 2005. p. 878–887. ISBN 9783540319023. Disponível em: <http://dx.doi.org/10.1007/11538059_91>. Citado 2 vezes nas páginas 21 e 56.

HARRIS, P. T. Seafloor geomorphology—coast, shelf, and abyss. In: _____. *Seafloor Geomorphology as Benthic Habitat*. Elsevier, 2020. p. 115–160. ISBN 9780128149607. Disponível em: <<http://dx.doi.org/10.1016/b978-0-12-814960-7.00006-3>>. Citado 2 vezes nas páginas 16 e 17.

HAYKIN, S. *Redes Neurais - Princípios e Prática*. [S.l.]: Bookman, 2007. Citado 5 vezes nas páginas 31, 32, 33, 34 e 35.

HAYKIN, S. *Neural networks and learning machines*. 3rd. ed. [S.l.]: Pearson Education, 2009. Citado na página 55.

HE, H. et al. Adasyn: Adaptive synthetic sampling approach for imbalanced learning. In: *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*. IEEE, 2008. p. 1322–1328. Disponível em: <<http://dx.doi.org/10.1109/IJCNN.2008.4633969>>. Citado 2 vezes nas páginas 21 e 56.

HE, H.; GARCIA, E. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, Institute of Electrical and Electronics Engineers (IEEE), v. 21, n. 9, p. 1263–1284, set. 2009. ISSN 1041-4347. Disponível em: <<http://dx.doi.org/10.1109/TKDE.2008.239>>. Citado 2 vezes nas páginas 21 e 56.

HEDLEY, J. et al. Remote sensing of coral reefs for monitoring and management: A review. *Remote Sensing*, MDPI AG, v. 8, n. 2, p. 118, fev. 2016. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs8020118>>. Citado na página 27.

- HEDLEY, J. D.; HARBORNE, A. R.; MUMBY, P. J. Technical note: Simple and robust removal of sun glint for mapping shallow-water benthos. *International Journal of Remote Sensing*, Informa UK Limited, v. 26, n. 10, p. 2107–2112, maio 2005. ISSN 1366-5901. Disponível em: <<http://dx.doi.org/10.1080/01431160500034086>>. Citado na página 29.
- HEDLEY, J. D. et al. Coral reef applications of sentinel-2: Coverage, characteristics, bathymetry and benthic mapping with comparison to landsat 8. *Remote Sensing of Environment*, Elsevier BV, v. 216, p. 598–614, out. 2018. ISSN 0034-4257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2018.07.014>>. Citado 3 vezes nas páginas 27, 29 e 30.
- HEDLEY, J. D. et al. Coral reef applications of sentinel-2: Coverage, characteristics, bathymetry and benthic mapping with comparison to landsat 8. *Remote Sensing of Environment*, Elsevier BV, v. 216, p. 598–614, out. 2018. ISSN 0034-4257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2018.07.014>>. Citado 4 vezes nas páginas 31, 46, 47 e 75.
- HEDLEY, J. D. et al. Environmental and sensor limitations in optical remote sensing of coral reefs: Implications for monitoring and sensor design. *Remote Sensing*, MDPI AG, v. 4, n. 1, p. 271–302, jan. 2012. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs4010271>>. Citado na página 30.
- HU, J. et al. *Squeeze-and-Excitation Networks*. arXiv, 2017. Disponível em: <<https://arxiv.org/abs/1709.01507>>. Citado na página 55.
- HUGHES, M.; HAYES, D. Automated detection of cloud and cloud shadow in single-date landsat imagery using neural networks and spatial post-processing. *Remote Sensing*, MDPI AG, v. 6, n. 6, p. 4907–4926, maio 2014. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs6064907>>. Citado na página 30.
- INNANGI, S. et al. Continuous, high-resolution mapping of coastal seafloor sediment distribution. *Remote Sensing*, MDPI AG, v. 14, n. 5, p. 1268, mar. 2022. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs14051268>>. Citado na página 19.
- IOFFE, S.; SZEGEDY, C. *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*. arXiv, 2015. Disponível em: <<https://arxiv.org/abs/1502.03167>>. Citado na página 40.
- IOFFE, S.; SZEGEDY, C. *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*. arXiv, 2015. Disponível em: <<https://arxiv.org/abs/1502.03167>>. Citado na página 55.
- JOLLIFFE, I. T. *Principal Component Analysis*. 2nd. ed. New York: Springer, 2002. (Springer Series in Statistics). Citado na página 53.
- KINGMA, D. P.; BA, J. *Adam: A Method for Stochastic Optimization*. arXiv, 2014. Disponível em: <<https://arxiv.org/abs/1412.6980>>. Citado 2 vezes nas páginas 56 e 57.
- KOWSMANN, R. O.; COSTA, M. P. A. *Sedimentação Quaternária da Margem Continental Brasileira e das áreas oceânicas adjacentes*. [S.l.], 1979. 1–56 p. (Projeto REMAC: Reconhecimento global da margem continental brasileira, v. 8). Citado na página 44.

- KUEHL, S. A.; DEMASTER, D. J.; NITTROUER, C. A. Nature of sediment accumulation on the amazon continental shelf. *Continental Shelf Research*, Elsevier BV, v. 6, n. 1–2, p. 209–225, 1986. ISSN 0278-4343. Disponível em: <[http://dx.doi.org/10.1016/0278-4343\(86\)90061-0](http://dx.doi.org/10.1016/0278-4343(86)90061-0)>. Citado 3 vezes nas páginas 26, 47 e 82.
- KUTSER, T. et al. Remote sensing of shallow waters – a 50 year retrospective and future directions. *Remote Sensing of Environment*, Elsevier BV, v. 240, p. 111619, abr. 2020. ISSN 0034-4257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2019.111619>>. Citado 5 vezes nas páginas 19, 31, 46, 47 e 75.
- LARSONNEUR, C. 1977. *La cartographie des dépôts meubles sur le plateau continental français: méthode mis*. 1977. Citado na página 26.
- LAVAGNINO, A. C. et al. Geomorphometric seabed classification and potential megahabitat distribution in the amazon continental margin. *Frontiers in Marine Science*, Frontiers Media SA, v. 7, abr. 2020. ISSN 2296-7745. Disponível em: <<http://dx.doi.org/10.3389/fmars.2020.00190>>. Citado na página 25.
- LE et al. Application of long short-term memory (lstm) neural network for flood forecasting. *Water*, MDPI AG, v. 11, n. 7, p. 1387, Jul 2019. ISSN 2073-4441. Disponível em: <<http://dx.doi.org/10.3390/w11071387>>. Citado na página 35.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado na página 55.
- LI, J. et al. The sensitivity of multi-spectral satellite sensors to benthic habitat change. *Remote Sensing*, MDPI AG, v. 12, n. 3, p. 532, fev. 2020. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs12030532>>. Citado na página 30.
- LI, S. et al. Satellite-derived bathymetry with sediment classification using icesat-2 and multispectral imagery: Case studies in the south china sea and australia. *Remote Sensing*, MDPI AG, v. 15, n. 4, p. 1026, fev. 2023. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs15041026>>. Citado na página 20.
- LIN, C. et al. Effects of atmospheric correction and pansharpening on lulc classification accuracy using worldview-2 imagery. *Information Processing in Agriculture*, Elsevier BV, v. 2, n. 1, p. 25–36, maio 2015. ISSN 2214-3173. Disponível em: <<http://dx.doi.org/10.1016/j.inpa.2015.01.003>>. Citado na página 30.
- LIN, T.-Y. et al. *Focal Loss for Dense Object Detection*. arXiv, 2017. Disponível em: <<https://arxiv.org/abs/1708.02002>>. Citado 2 vezes nas páginas 21 e 56.
- MAGNO, R. et al. Agroshadow: A new sentinel-2 cloud shadow detection tool for precision agriculture. *Remote Sensing*, MDPI AG, v. 13, n. 6, p. 1219, mar. 2021. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs13061219>>. Citado na página 30.
- MARTIMORT, P. et al. Sentinel-2 optical high resolution mission for gmes operational services. In: *2007 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2007. Disponível em: <<http://dx.doi.org/10.1109/IGARSS.2007.4423394>>. Citado na página 27.

- MARTIN, J. et al. Automatic sun glint removal of multispectral high-resolution worldview-2 imagery for retrieving coastal shallow water parameters. *Remote Sensing*, MDPI AG, v. 8, n. 1, p. 37, jan. 2016. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs8010037>>. Citado na página 29.
- MILANI, E. J. et al. Petróleo na margem continental brasileira: geologia, exploração, resultados e perspectivas. *Revista Brasileira de Geofísica*, FapUNIFESP (SciELO), v. 18, n. 3, p. 352–396, 2000. ISSN 0102-261X. Disponível em: <<http://dx.doi.org/10.1590/S0102-261X2000000300012>>. Citado 2 vezes nas páginas 23 e 24.
- MILLIMAN, J. D. Role of calcareous algae in atlantic continental margin sedimentation. In: _____. *Fossil Algae*. Springer Berlin Heidelberg, 1977. p. 232–247. ISBN 9783642665165. Disponível em: <http://dx.doi.org/10.1007/978-3-642-66516-5_26>. Citado na página 16.
- MOGRANE, M. et al. Evaluation of five atmospheric correction algorithms over french optically-complex waters for the sentinel-3a olci ocean color sensor. *Remote Sensing*, MDPI AG, v. 11, n. 6, p. 668, mar. 2019. ISSN 2072-4292. Disponível em: <<http://dx.doi.org/10.3390/rs11060668>>. Citado na página 30.
- MUMBY, P. J. et al. Benefits of water column correction and contextual editing for mapping coral reefs. *International Journal of Remote Sensing*, Informa UK Limited, v. 19, n. 1, p. 203–210, jan. 1998. ISSN 1366-5901. Disponível em: <<http://dx.doi.org/10.1080/014311698216521>>. Citado na página 30.
- MURUGAN, P. Feed forward and backward run in deep convolution neural network. *ArXiv*, abs/1711.03278, 2017. Citado na página 37.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: *Proceedings of the 27th international conference on machine learning (ICML-10)*. [S.l.: s.n.], 2010. p. 807–814. Citado na página 55.
- NETO, J. C. d. *Geodiversidade da plataforma continental de Icapuí, Ceará: uma proposta de identificação de áreas chave em ambientes marinhos*. 125 p. Tese (Ph.D. dissertation (Geology)) — Universidade Federal do Ceará, Fortaleza, CE, Brazil, 2017. Accessed: Oct. 8, 2025. Disponível em: <<http://repositorio.ufc.br/handle/riufc/29898>>. Citado na página 20.
- PAHLEVAN, N. et al. Sentinel-2 MultiSpectral Instrument (MSI) data processing for aquatic science applications: Demonstrations and validations. *Remote Sensing of Environment*, v. 201, p. 47–56, 2017. Citado na página 19.
- PELLEGRINI, B. d. S.; RIBEIRO, H. J. P. S. Exploratory plays of pará-maranhão and barreirinhas basins in deep and ultra-deep waters, brazilian equatorial margin. *Brazilian Journal of Geology*, FapUNIFESP (SciELO), v. 48, n. 3, p. 485–502, jul. 2018. ISSN 2317-4889. Disponível em: <<http://dx.doi.org/10.1590/2317-4889201820180146>>. Citado 2 vezes nas páginas 16 e 17.
- POST, A. L. The application of physical surrogates to predict the distribution of marine benthic organisms. *Ocean amp; Coastal Management*, Elsevier BV, v. 51, n. 2, p. 161–179, jan. 2008. ISSN 0964-5691. Disponível em: <<http://dx.doi.org/10.1016/j.ocecoaman.2007.04.008>>. Citado na página 16.

- POURSANIDIS, D. et al. On the use of sentinel-2 for coastal habitat mapping and satellite-derived bathymetry estimation using a downscaled coastal aerosol band. *Geocarto International*, Taylor & Francis, v. 34, n. 12, p. 1295–1319, 2019. Citado 2 vezes nas páginas 19 e 31.
- QIN, X. et al. Optimizing the sediment classification of small side-scan sonar images based on deep learning. *IEEE Access*, Institute of Electrical and Electronics Engineers (IEEE), v. 9, p. 29416–29428, 2021. ISSN 2169-3536. Disponível em: <<http://dx.doi.org/10.1109/access.2021.3052206>>. Citado na página 20.
- QIU, S.; ZHU, Z.; HE, B. Fmask 4.0: Improved cloud and cloud shadow detection in landsats 4–8 and sentinel-2 imagery. *Remote Sensing of Environment*, Elsevier BV, v. 231, p. 111205, set. 2019. ISSN 0034-4257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2019.05.024>>. Citado na página 30.
- RAMESH, R. et al. Land–ocean interactions in the coastal zone: Past, present amp; future. *Anthropocene*, Elsevier BV, v. 12, p. 85–98, dez. 2015. ISSN 2213-3054. Disponível em: <<http://dx.doi.org/10.1016/j.ancene.2016.01.005>>. Citado na página 16.
- RUSSAKOVSKY, O. et al. ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, v. 115, n. 3, p. 211–252, 2015. Citado na página 55.
- SHEPARD, F. P. Nomenclature based on sand-silt-clay ratios. *SEPM Journal of Sedimentary Research*, Society for Sedimentary Geology, Vol. 24, 1954. ISSN 1527-1404. Disponível em: <<http://dx.doi.org/10.1306/d4269774-2b26-11d7-8648000102c1865d>>. Citado 2 vezes nas páginas 25 e 45.
- SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas*. [S.l.]: Artliber, 2016. Citado 4 vezes nas páginas 32, 33, 34 e 35.
- SINGH, P.; KOMODAKIS, N. Cloud-gan: Cloud removal for sentinel-2 imagery using a cyclic consistent generative adversarial networks. In: *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2018. p. 1772–1775. Disponível em: <<http://dx.doi.org/10.1109/IGARSS.2018.8519033>>. Citado na página 28.
- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing amp; Management*, Elsevier BV, v. 45, n. 4, p. 427–437, jul. 2009. ISSN 0306-4573. Disponível em: <<http://dx.doi.org/10.1016/j.ipm.2009.03.002>>. Citado na página 58.
- TAN, M.; LE, Q. V. Efficientnetv2: Smaller models and faster training. arXiv, 2021. Disponível em: <<https://arxiv.org/abs/2104.00298>>. Citado na página 55.
- VALE, N. F. et al. Structure and composition of rhodoliths from the amazon river mouth, brazil. *Journal of South American Earth Sciences*, Elsevier BV, v. 84, p. 149–159, jul. 2018. ISSN 0895-9811. Disponível em: <<http://dx.doi.org/10.1016/j.jsames.2018.03.014>>. Citado na página 17.

VITAL, H. et al. Characterization of the brazilian continental shelf adjacent to rio grande do norte state, ne brazil. *Brazilian Journal of Oceanography*, FapUNIFESP (SciELO), v. 58, n. spe1, p. 43–54, 2010. ISSN 1679-8759. Disponível em: <<http://dx.doi.org/10.1590/S1679-87592010000500005>>. Citado 2 vezes nas páginas 27 e 79.

WERBOS, P. Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*, Institute of Electrical and Electronics Engineers (IEEE), v. 78, n. 10, p. 1550–1560, 1990. ISSN 0018-9219. Disponível em: <<http://dx.doi.org/10.1109/5.58337>>. Citado na página 41.

WICAKSONO, P.; ARYAGUNA, P. A. Analyses of inter-class spectral separability and classification accuracy of benthic habitat mapping using multispectral image. *Remote Sensing Applications: Society and Environment*, Elsevier BV, v. 19, p. 100335, ago. 2020. ISSN 2352-9385. Disponível em: <<http://dx.doi.org/10.1016/j.rsase.2020.100335>>. Citado na página 30.

WOUTHUYZEN, S. et al. The potency of sentinel-2 satellite for monitoring during and after coral bleaching events of 2016 in the some islands of marine recreation park (twp) of pieh, west sumatra. *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, v. 284, n. 1, p. 012028, maio 2019. ISSN 1755-1315. Disponível em: <<http://dx.doi.org/10.1088/1755-1315/284/1/012028>>. Citado 2 vezes nas páginas 27 e 28.

XU, J. et al. *Understanding and Improving Layer Normalization*. arXiv, 2019. Disponível em: <<https://arxiv.org/abs/1911.07013>>. Citado na página 40.

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in landsat imagery. *Remote Sensing of Environment*, Elsevier BV, v. 118, p. 83–94, mar. 2012. ISSN 0034-4257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.10.028>>. Citado na página 30.

ZOFFOLI, M.; FROUIN, R.; KAMPEL, M. Water column correction for coral reef studies by remote sensing. *Sensors*, MDPI AG, v. 14, n. 9, p. 16881–16931, set. 2014. ISSN 1424-8220. Disponível em: <<http://dx.doi.org/10.3390/s140916881>>. Citado 2 vezes nas páginas 29 e 30.