



**UNIVERSIDADE FEDERAL DA BAHIA
INSTITUTO DE GEOCIÊNCIAS
DEPARTAMENTO DE GEOGRAFIA**

RENATO BRANDÃO PEREIRA

**MAPEAMENTO DE MANGUEZAIS COM RANDOM FOREST ATRAVÉS DE
IMAGENS SENTINEL-2: ESTUDO DE CASO NO MUNICÍPIO DE CONDE/BA**

Salvador

2025

RENATO BRANDÃO PEREIRA

**MAPEAMENTO DE MANGUEZAIS COM RANDOM FOREST ATRAVÉS DE
IMAGENS SENTINEL-2: ESTUDO DE CASO NO MUNICÍPIO DE CONDE/BA**

Trabalho de Conclusão de Curso apresentado
ao curso de Geografia, Instituto de Geociências,
Universidade Federal da Bahia, como requisito
parcial à obtenção do grau de Bacharel em
Geografia.

Orientadora: Prof^a. Dr^a. Elaine Gomes Vieira de
Jesus

Salvador

2025

AGRADECIMENTOS

Durante o caminho, foi de extrema importância o apoio daqueles que sempre prezaram por mim. Em especial, gostaria de agradecer profundamente:

A Flávia, companheira de vida. Me mostrou o real valor das coisas e como as possibilidades são várias quando vistas com amor.

A Raimary e Renato, meus pais queridos. Com amor e cuidado, me mantiveram no caminho certo.

A Rodrigo e Rafael, meus irmãos. Apesar da distância geográfica, estiveram cuidadosamente presentes com descontração e carinho.

A Elaine, minha orientadora. O cuidado e paciência no processo permitiu que este trabalho nascesse.

Meu sincero obrigado a todos e todas que tornaram essa trajetória a mais humana possível.

RESUMO

Os manguezais são ecossistemas que desempenham um papel fundamental em ambientes de transição terrestres e marinhos, fornecendo serviços ecossistêmicos cruciais, como proteção costeira e mitigação climática através de sequestro de carbono. Porém, encontram-se sob grande pressão antrópica. O monitoramento preciso dessas áreas é desafiador por conta da complexidade espectral e da dinâmica de marés. Este estudo teve como objetivo analisar a eficácia do algoritmo de aprendizado de máquina *Random Forest* no mapeamento de manguezais e classes adjacentes de uso e cobertura do solo na área litorânea do município de Conde, Bahia. A metodologia utilizou a plataforma de computação em nuvem *Google Earth Engine* (GEE) para o pré-processamento de imagens Sentinel-2 referentes ao ano de 2023, gerando um Mosaico Anual de Mediana para mitigar a interferência de nuvens e as variações de maré. Os índices espectrais NDVI e MNDWI foram integrados ao mosaico, formando um *Stack* multi-banda com oito camadas de informação. A classificação supervisionada foi executada no ambiente QGIS através do complemento *Dzetsaka* e validada estatisticamente via amostragem aleatória estratificada (*plugin AcATaMa*). O mapeamento identificou oito classes temáticas, alcançando uma Acurácia Global de 92,41% e um Coeficiente Kappa de 0,89. A classe de manguezal obteve desempenho excepcional, com uma Acurácia do Produtor de 100%, demonstrando que a estratégia de composição temporal (mediana) aliada ao índice MNDWI foi eficaz para evitar a omissão de vegetação inundada. Conclui-se que a integração entre dados Sentinel-2, índices espectrais e *Machine Learning* constitui uma estratégia robusta, de baixo custo e replicável para o monitoramento de ambientes costeiros tropicais.

Palavras-Chave: Manguezal, Sensoriamento Remoto, Sentinel-2, Random Forest, Google Earth Engine.

ABSTRACT

Mangroves are ecosystems that play a pivotal role at the terrestrial-marine interface, providing crucial ecosystem services such as coastal protection and climate mitigation via carbon sequestration. Nevertheless, they are subject to significant anthropogenic pressure. Precise monitoring of these areas is challenging due to spectral complexity and tidal dynamics. This study aimed to evaluate the efficacy of the Random Forest machine learning algorithm in mapping mangroves and adjacent land use and land cover classes in the coastal zone of the municipality of Conde, Bahia. The methodology utilized the Google Earth Engine (GEE) cloud computing platform for the pre-processing of Sentinel-2 imagery for the year 2023, generating an Annual Median Composite to mitigate cloud interference and tidal variations. The spectral indices NDVI and MNDWI were integrated into the composite, forming a multi-band Stack with eight information layers. Supervised classification was executed in the QGIS environment using the Dzetsaka plugin and statistically validated via stratified random sampling (AcATAma plugin). The mapping identified eight thematic classes, achieving an Overall Accuracy of 92.41% and a Kappa Coefficient of 0.89. The mangrove class exhibited exceptional performance, with a Producer's Accuracy of 100%, demonstrating that the temporal composition strategy (median) combined with the MNDWI index was effective in preventing the omission of flooded vegetation. It is concluded that the integration of Sentinel-2 data, spectral indices, and Machine Learning constitutes a robust, low-cost, and replicable strategy for monitoring tropical coastal environments.

Keywords: Mangrove, Remote Sensing, Sentinel-2, Random Forest, Google Earth Engine.

SUMÁRIO

1 INTRODUÇÃO.....	11
1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA	11
1.2 OBJETIVOS	12
1.2.1 Objetivo Geral	12
1.2.2 Objetivos Específicos	13
2 REVISÃO BIBLIOGRÁFICA	14
2.1 MANGUEZAIS: IMPORTÂNCIA ECOLÓGICA E SOCIOECONÔMICA	14
2.2 SENSORIAMENTO REMOTO APLICADO AO MAPEAMENTO DE MANGUEZAIS	15
2.2.1 A Força dos Sensores Sentinel-2.....	16
2.2.2 O Uso Estratégico de Índices Espectrais (NDVI e MNDWI)	16
2.2.3 Classificação Supervisionada: Random Forest.....	18
2.3 GOOGLE EARTH ENGINE (GEE) COMO PLATAFORMA DE ANÁLISE E MITIGAÇÃO DE EFEITOS DE MARÉ	19
2.4 AVANÇOS E NOVAS PERSPECTIVAS TECNOLÓGICAS	20
3 MATERIAIS E MÉTODOS	21
3.1 ÁREA DE ESTUDO: CARACTERIZAÇÃO DA ÁREA LITORÂNEA DE CONDE - BAHIA	21
3.2 DADOS UTILIZADOS (IMAGENS SENTINEL-2)	22
3.3 ESTRUTURA METODOLÓGICA EM TRÊS ETAPAS	23
3.3.1 Etapa 1: Pré-Processamento e Geração do Mosaico Anual de Mediana	23
3.3.2 Etapa 2: Processamento e Classificação (Engenharia de Features e Machine Learning)	25
3.3.3 Etapa 3: Pós-Processamento e Validação	25
3.4 AMOSTRAGEM DE REFERÊNCIA E VALIDAÇÃO DE CAMPO	26
4 RESULTADOS E DISCUSSÕES	27
4.1 VALIDAÇÃO DOS PONTOS EM CAMPO	27
4.2 ANÁLISE DAS CLASSES DE COBERTURA E DESEMPENHO DOS ÍNDICES ESPECTRAIS	35
4.3 RESULTADOS DA CLASSIFICAÇÃO RANDOM FOREST	38
4.4 MAPEAMENTO DA COBERTURA DE MANGUEZAL NA ÁREA LITORÂNEA DE CONDE, BAHIA	40
4.5 ANÁLISE E DISCUSSÃO DA ACURÁCIA POR CLASSE	44
4.6 ANÁLISE COMPARATIVA DE ESTRATÉGIAS DE MAPEAMENTO: CENA ÚNICA E MOSAICO ANUAL DE MEDIANA.....	46
5 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES	50
REFERÊNCIAS.....	52
APÊNDICE A – SCRIPT DE PROCESSAMENTO NO GEE	54

Lista de Figuras

Figura 1 - Equação do NDVI.	17
Figura 2 - Equação do MNDWI.	17
Figura 3 - Esquema explicativo do processo de decisão do algoritmo Random Forest.	18
Figura 4 - Mapa de localização da área de estudo.	21
Figura 5 - Fluxograma das Etapas Metodológicas do Mapeamento.	23
Figura 6 - Mapa de localização dos pontos de validação de campo na área litorânea de Conde, Bahia.	28
Figura 7 - Localização dos pontos de validação na classificação do Mosaico Anual de Mediana.	28
Figura 8 - (1) Campo de pecuária.	30
Figura 9 - (2) Vegetação de restinga.	31
Figura 10 - (3) Corpo d'água.	32
Figura 11 - (4) Área de pecuária com área alagada ao fundo.	33
Figura 12 - (5) Manguezal com raízes expostas.	34
Figura 13 - (6) Areal e presença de coqueiros.	35
Figura 14 - Mapa produto da classificação supervisionada de uso e ocupação do solo da área litorânea do município de Conde, Bahia.	40
Figura 15 - Recorte da classificação supervisionada comparada à imagem de alta resolução. Os pontos (a) e (b) indicam os locais de verificação in loco detalhados na sequência.	41
Figura 16 - Uso antrópico consolidado em áreas de manguezal ao longo do rio Itapicuru.	42
Figura 17 - Zona úmida não florestada localizada em Siribinha.	43
Figura 18 - Manguezal preservado ao longo do rio Itapicuru.	44

Lista de Tabelas

Tabela 1 - Dados quantitativos dos polígonos de amostragem.	24
Tabela 2 - Matriz de confusão da Classificação Supervisionada (Random Forest).	38
Tabela 3 - Métricas de Acurácia por Classe (Usuário e Produtor).	39
Tabela 4 - Métricas de Desempenho Global.	39
Tabela 5 - Matriz de Confusão da cena única e do Mosaico Anual de Mediana.	47
Tabela 6 - Desempenho Global da cena única e do Mosaico Anual de Mediana.	47
Tabela 7 - Acurácia do Produtor da cena única e do Mosaico Anual de Mediana.	48
Tabela 8 - Acurácia do Usuário da cena única e do Mosaico Anual de Mediana.	48

Lista de Quadros

Quadro 1 - Caracterização das classes de uso e cobertura do solo e o comportamento espectral predominante.

37

1 INTRODUÇÃO

Os ecossistemas de manguezal desempenham um papel fundamental em ambientes de transição terrestres e marinhos, fornecendo serviços ecossistêmicos cruciais, como proteção costeira e mitigação climática através de sequestro de carbono (TRAN *et al.*, 2022). No entanto, a complexidade espectral desses ambientes, frequentemente sujeitos à inundação de maré e à mistura com outras tipologias vegetais e usos antrópicos, impõem grandes dificuldades para a eficácia do seu mapeamento (GHORBANIAN *et al.*, 2021). Diante da perda global acelerada desses habitats, estimada em 35% nas últimas décadas (TRAN *et al.*, 2022), torna-se de grande importância não apenas o monitoramento, mas a validação de metodologias e técnicas que garantam a confiabilidade dos dados gerados remotamente.

O Sensoriamento Remoto (SR) consolidou-se como a principal ferramenta para este monitoramento. Contudo, abordagens tradicionais baseadas em classificação de imagem única ou classificadores paramétricos muitas vezes falham em capturar a heterogeneidades dos manguezais em cenários complexos (WANG *et al.*, 2019). A evolução recente para plataformas de computação em nuvem, como o Google Earth Engine (GEE), e o uso de algoritmos de Machine Learning, como o Random Forest (RF), prometem superar essas limitações ao processar grandes volumes de dados e integrar múltiplas variáveis espectrais (RODRIGUES *et al.*, 2023; SHEN *et al.*, 2023).

Nesse contexto, o presente estudo propõe analisar a eficácia técnica de uma metodologia de classificação supervisionada baseada no algoritmo RF, aplicado a dados do sensor Sentinel-2. A abordagem investiga o ganho de desempenho proporcionado pela integração do Mosaico Anual de Mediana (para mitigação de nuvens e marés) com índices espectrais específicos de vegetação e água (NDVI e MNDWI). O estudo busca testar a robustez dessa técnica em distinguir manguezal de classes espectralmente similares ou de transição, validando estatisticamente os resultados obtidos.

1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA

A escolha da área litorânea do município de Conde, Bahia, como objeto de estudo, se justifica por suas características naturais para o teste da eficácia do algoritmo. Localizada na Área de Proteção Ambiental (APA) Litoral Norte, a região apresenta um mosaico complexo de paisagens, onde remanescentes de manguezal e formações florestais coabitam com vetores de

pressão antrópica intensos, como a silvicultura, agropecuária e expansão urbana (SOUZA *et al.*, 2024).

A justificativa para esta análise está na necessidade de validar métodos que consigam operar com precisão em cenários de conflito de uso do solo. Estudos recentes na região indicam que a paisagem de Conde sofreu transformações contínuas entre 1985 e 2022, com a substituição de vegetação nativa por mosaico de uso agropecuário e pressão da especulação imobiliária (SOUZA *et al.*, 2024). Essa dinâmica torna a área ideal para testar se a técnica proposta consegue discriminar corretamente o manguezal de áreas de “confusão”, como culturas agrícolas densas ou áreas alagadas não-manguezal.

Embora o município de Conde tenha sido adotado como unidade de análise e estudo de caso, a metodologia desenvolvida encontra certas limitações numa escala municipal. Isto se deve à resolução espacial de 10 metros do sensor utilizado, que é mais adequada para análises em outras escalas geográficas. A utilização de plataformas de computação em nuvem, por sua vez, viabiliza a replicação dessa abordagem em grandes extensões geográficas, tornando-a ideal para a gestão de Áreas de Proteção Ambiental (APAs) e para o monitoramento ambiental em escalas regional e estadual.

Além disso, a validação da eficácia do índice MNDWI em conjunto com o NDVI é pertinente, já que a literatura aponta a banda do infravermelho de ondas curtas (SWIR) como crucial para distinguir vegetação úmida (mangue) de outras formações em ambientes costeiros (SHEN *et al.*, 2023). Portanto, mais do que gerar um mapa, este trabalho se justifica pela avaliação crítica da acurácia e das limitações do Machine Learning aplicado ao monitoramento costeiro do estado da Bahia, contribuindo para o aprimoramento das geotecnologias aplicadas à gestão ambiental.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Analisar a aplicabilidade e o desempenho do algoritmo de Machine Learning Random Forest no mapeamento das áreas de manguezal e classes de uso e cobertura do solo adjacentes, a partir da integração de dados de Sensoriamento Remoto (SR) Sentinel-2A e índices espectrais (NDVI e MNDWI).

1.2.2 Objetivos Específicos

- Identificar as técnicas e ferramentas mais utilizadas para o mapeamento de manguezais;
- Elaborar um mapeamento de uso e cobertura do solo da zona costeira do município de Conde, Bahia;
- Validar os resultados através da análise estatística e comprovação in loco de áreas que são comumente confundidas (zonas de transição).

2 REVISÃO BIBLIOGRÁFICA

Esta revisão bibliográfica analisa a importância ecológica dos manguezais e o papel estratégico do Sensoriamento Remoto, especificamente o sensor Sentinel-2, no seu monitoramento. São discutidas a integração de índices espectrais (NDVI e MNDWI) ao algoritmo *Random Forest* e as potencialidades da plataforma *Google Earth Engine* para o processamento em nuvem.

2.1 MANGUEZAIS: IMPORTÂNCIA ECOLÓGICA E SOCIOECONÔMICA

Os manguezais representam um ecossistema costeiro único e complexo, reconhecido pela sua alta produtividade e relevância global em zonas entre-marés de regiões tropicais e subtropicais (TRAN *et al.*, 2022). O valor desses ambientes ultrapassa o âmbito ecológico, abrangendo serviços ecossistêmicos essenciais para a sociedade humana e para a estabilidade climática do planeta. Ecologicamente, os manguezais funcionam como berçários de biodiversidade costeira e são cruciais para a proteção contra perigos naturais (TRAN *et al.*, 2022).

A sua importância no contexto das mudanças climáticas é evidente pela capacidade de sequestro de carbono. Esses ecossistemas tem a capacidade de armazenar de três a cinco vezes mais carbono por área equivalente do que as florestas tropicais em terra firme, devido ao grande armazenamento nos seus solos (TRAN *et al.*, 2022). Além disso, a relevância socioeconômica dos manguezais está no fornecimento de recursos pesqueiros e na proteção costeira, beneficiando comunidades locais (RODRIGUES *et al.*, 2023). Contudo, apesar do seu valor, os manguezais tem sofrido perdas significativas (aproximadamente 35% das florestas globais de mangue foram perdidas nas últimas cinco décadas), principalmente devido à pressão antrópica, como a conversão em aquicultura, agropecuária e expansão urbana (TRAN *et al.*, 2022).

No contexto brasileiro, os manguezais estão distribuídos ao longo da costa desde Cabo Orange, no estado do Amapá, até o município de Laguna, em Santa Catarina (ICMBIO, 2018). O país abriga uma das maiores extensões contínuas desse ecossistema no mundo, com uma área estimada de cerca de 1.114.000 hectares (MAGRIS e BARRETO, 2010; ICMBIO, 2018). Os manguezais brasileiros dividem-se em três gêneros principais, cujo as espécies possuem adaptações específicas para sobrevivência em ambientes salinos e solos instáveis. O mangue-vermelho (*Rhizophora Mangle*) caracteriza-se pela presença de rizóforos que garantem a sustentação da árvore (ICMBIO, 2018). O gênero *Avicennia* é representado pela espécie *Avicennia Schaueriana* e *Avicennia Germinans*, conhecidas como mangue-preto ou Siriúba,

que possuem raízes aéreas (ICMBIO, 2018). Já o mangue-branco (*Laguncularia Racemosa*) é identificado pelas glândulas de sal situados na base do pecíolo das folhas (ICMBIO, 2018). Em zonas de transição para a terra firme, ocorre também o mangue-de-botão (*Conocarpus Erectus*) (MAGRIS e BARRETO, 2010).

2.2 SENSORIAMENTO REMOTO APLICADO AO MAPEAMENTO DE MANGUEZAIS

A complexidade e a dificuldade de acesso no ambiente de manguezal, frequentemente hostil e sujeito a inundações de maré, tornam as observações de campo (*in loco*) limitadas em escala e de custo elevado. Neste cenário, o SR surge como uma solução de alta eficiência e baixo custo para o mapeamento e monitoramento em grandes áreas (WANG *et al.*, 2019; GHORBANIAN *et al.*, 2021). O SR tem permitido a coleta de informações sobre a distribuição geográfica e as propriedades biofísicas do manguezal, superando as desvantagens dos métodos tradicionais (TRAN *et al.*, 2022).

Na literatura científica, a aplicação de técnicas de SR tem ganhado bastante destaque na complexa missão de monitoramento ambiental. Uma das aplicações mais recorrentes é a análise espaço-temporal, que permite calcular a dinâmica de perda e ganho de manguezal ao longo de décadas. No contexto brasileiro, Miranda e Fonseca (2019) demonstraram a eficácia desta abordagem ao mapear a evolução dos manguezais no estuário do Rio Acaraú (CE) entre 1997 e 2017. O estudo utilizou o SR para identificar não apenas a diminuição da vegetação, mas também a expansão de vetores de pressão, como a carcinicultura e a urbanização, fornecendo subsídios para o planejamento e gestão territorial de Unidades de Conservação.

Além da análise espaço-temporal, o SR tem evoluído para a caracterização qualitativa do ecossistema. Estudos globais indicam o uso de imagens de alta resolução e algoritmos de aprendizado de máquina para discriminação de espécies de mangue e para estimativa de parâmetros biofísicos, como biomassa e estoque de carbono (WANG *et al.*, 2019). A capacidade de diferenciar tipologias vegetais dentro do mangue é crucial para entender a saúde do ecossistema e para sua valorização como patrimônio natural, tendo em vista os diferentes serviços ecossistêmicos específicos em diferentes zonas (TRAN *et al.*, 2022; MIRANDA; FONSECA, 2019).

Portanto, a utilização de dados orbitais não se limita apenas à produção de mapas estáticos, mas constitui uma ferramenta estratégica para monitoramento remoto e para a compressão das tendências que ameaçam esses ambientes costeiros (RODRIGUES *et al.*, 2023; MIRANDA; FONSECA, 2019).

2.2.1 A Força dos Sensores Sentinel-2

A capacidade de mapeamento detalhado dos manguezais está diretamente relacionada à evolução da resolução espacial das imagens de satélite. Historicamente, as baixas resoluções espacial e temporal eram uma barreira para o mapeamento eficiente em ambientes costeiros complexos e com alta presença de nuvens (WANG *et al.*, 2019). No entanto, atualmente o sensor Sentinel-2A (Missão Copernicus) fornece dados multiespectrais de acesso livre com resolução espacial de 10 metros para as bandas do espectro eletromagnético na faixa do visível e do Infravermelho Próximo (NIR) (TRAN *et al.*, 2022).

Além da resolução espacial, a constelação Sentinel-2A e 2B oferece uma alta frequência de revisita de 5 dias, o que aumenta significativamente a chance de obtenção de imagens livres de nuvens, permitindo um monitoramento espaço-temporal mais denso e preciso de manguezais (WANG *et al.*, 2019).

A alta resolução do Sentinel-2A é fundamental, pois garante a distinção do manguezal mesmo em formações estreitas, contribuindo para uma Acurácia Global (OA) consistentemente alta nos mapeamentos (SHEN *et al.*, 2023). Estudos recentes demonstram que, para classificação de manguezais, os dados ópticos do Sentinel-2 podem apresentar desempenho superior até mesmo quando comparado à dados de Radar de Abertura Sintética (SAR) isolados (SHEN *et al.*, 2023). Destaca-se, portanto, a robustez dos dados multiespectrais para essa finalidade.

A sensibilidade do sensor é reforçada pela inclusão de bandas de Infravermelho de Ondas Curtas (SWIR), representada pelas bandas B11 e B12, que são cruciais para o monitoramento de saúde e teor de água da vegetação (TRAN *et al.*, 2022; SHEN *et al.*, 2023), o Sentinel-2 incorpora três bandas na faixa do infravermelho médio. Essas bandas (B5, B6 e B7) são particularmente sensíveis à clorofila e ao estresse da vegetação, fornecendo informações para análise sobre o estado de saúde e a fenologia dos manguezais, que anteriormente só eram capazes a partir de sensor hiperespectrais (WANG *et al.*, 2019; TRAN *et al.*, 2022).

2.2.2 O Uso Estratégico de Índices Espectrais (NDVI e MNDWI)

A identificação espectral do manguezal é caracterizada pela forte reflectância na região do NIR. A Engenharia de *Features* é o processo de criar novas camadas de informação com base nos dados originais e, através do cálculo de índices espetrais, permite aumentar o

contraste e ampliar o poder discriminatório do classificador. Este estudo emprega uma abordagem de dois índices, o que agrega à qualidade da classificação, já que o uso de um único índice é desafiador para distinguir o manguezal de outros tipos de vegetação terrestre (TRAN *et al.*, 2022).

O Índice de Vegetação por Diferença Normalizada (NDVI) é o índice mais aplicado em estudos de manguezais, sendo utilizado em mais de 80% das pesquisas revisadas (TRAN *et al.*, 2022). Calculado a partir da razão normalizada das bandas do NIR e do Vermelho (Figura 1 - Equação 1), ele é de suma importância para quantificar a biomassa e a saúde da vegetação (TRAN *et al.*, 2022). No entanto, vale ressaltar que, em áreas de dossel muito denso, o NDVI pode apresentar saturação, o que justifica a sua utilização em conjunto com outros índices para uma caracterização mais precisa (RODRIGUES *et al.*, 2023).

Figura 1 - Equação do NDVI.

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$$

Fonte: Rouse *et al.* (1974) *apud* Shen *et al.* (2023).

Contudo, para diferenciar o manguezal das áreas alagadas e das áreas de lama exposta, o Índice de Água por Diferença Normalizada Modificado (MNDWI), é o índice espectral mais importante (SHEN *et al.*, 2023). Diferente do Índice de Água por Diferença Normalizada (NDWI) tradicional, o MNDWI utiliza a banda do SWIR no lugar no NIR (Figura 2 - Equação 2). A banda do SWIR é particularmente sensível ao teor de água da vegetação e do solo, melhorando a distinção e a acurácia na delimitação em ambientes com forte influência da maré (SHEN *et al.*, 2023; DINIZ *et al.*, 2019).

Figura 2 - Equação do MNDWI.

$$\text{MNDWI} = \frac{\text{GREEN} - \text{SWIR}}{\text{GREEN} + \text{SWIR}}$$

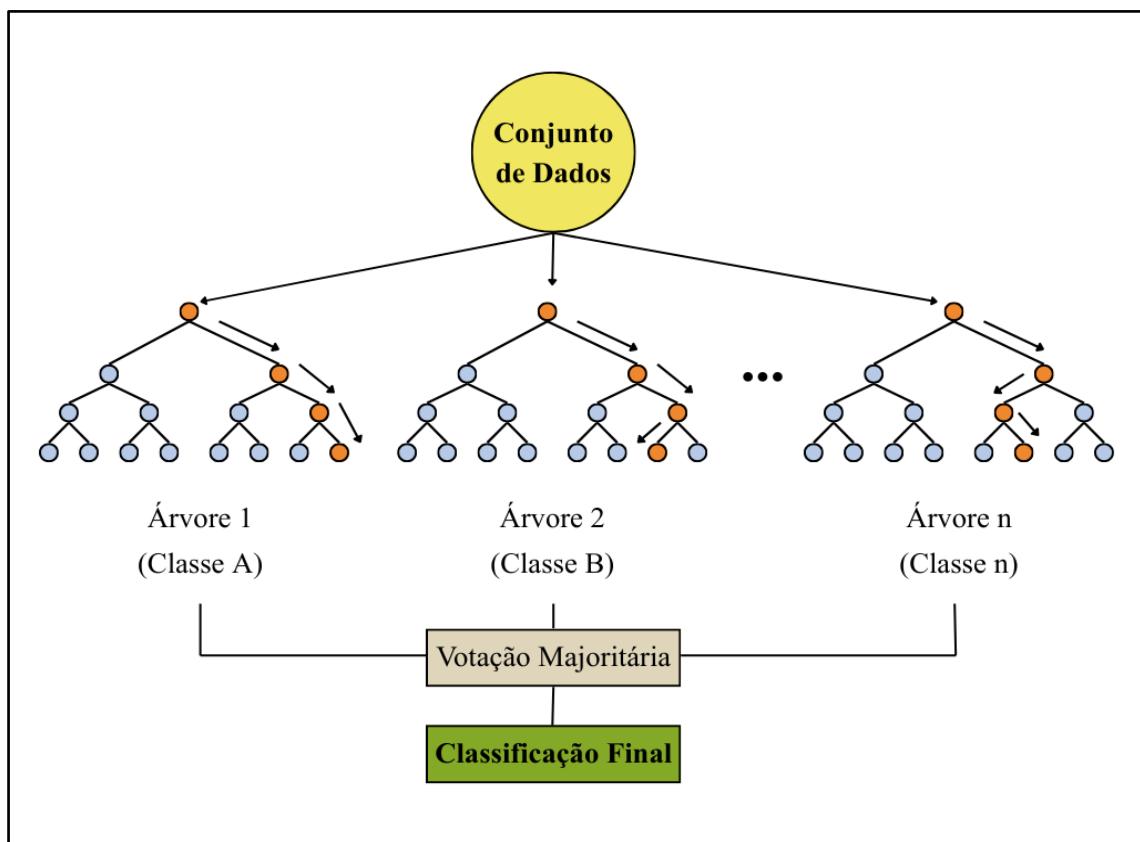
Fonte: Xu *et al.* (2006) *apud* Shen *et al.* (2023).

2.2.3 Classificação Supervisionada: Random Forest

A transição dos métodos tradicionais de classificação para algoritmos de *Machine Learning* resultou em uma melhoria considerável na acurácia do mapeamento. O algoritmo *Random Forest* (RF), em particular, provou ser o mais eficiente e robusto para o mapeamento de ecossistemas complexos como o manguezal (GHORBANIAN *et al.*, 2021).

O RF opera através de técnicas de *ensemble learning* (aprendizado por conjunto). O seu funcionamento baseia-se na construção de uma “floresta” formada por múltiplas árvores de decisão independentes (Figura 3).

Figura 3 - Esquema explicativo do processo de decisão do algoritmo Random Forest.



Fonte: SHEN *et al.* (2023). Elaborado pelo autor (2025).

O algoritmo usa a técnica de agregação Bootstrap para treinar cada árvore com um subconjunto aleatório de amostras de treinamento, enquanto o restante dos dados é utilizado para validação cruzada interna e estimativa de erro (GHORBANIAN *et al.*, 2021).

Para determinar a classe final de um pixel, o algoritmo computa a resposta de todas as árvores individuais e aplica uma regra de votação majoritária: a classe que receber maior

número de votos das árvores é atribuída ao pixel (SHEN *et al.*, 2023). Essa característica o torna altamente tolerante à ruídos, robusto e eficaz em evitar *overfitting* (superajuste), problemas comuns em classificadores mais simples que usam apenas uma árvore de decisão (GHORBANIAN *et al.*, 2021).

Uma vantagem adicional do RF é a sua capacidade de integrar múltiplas fontes de dados de forma eficiente, como o *Stack* multibanda usando neste estudo, sem a necessidade de reduzir (simplificar) o número de variáveis de entrada (SHEN *et al.*, 2023). A aplicação do RF em conjunto com o *stack* de bandas brutas do Sentinel-2A, somado aos índices espectrais NDVI e MNDWI, tem elevados os resultados de alta qualidade com acuráncias globais acima de 92% (GHORBANIAN *et al.*, 2021; SHEN *et al.*, 2023; RODRIGUES *et al.*, 2023). Estudos recentes demonstraram que o RF supera outros classificadores supervisionados tradicionais, como o *Classification and Regression Trees* (CART), apresentando uma menor confusão com classes de vegetação adjacente (RODRIGUES *et al.*, 2023). Além disso, a sua eficácia é demonstrada em estudos nacionais, justificando a sua escolha como classificador principal (RODRIGUES *et al.*, 2023).

2.3 GOOGLE EARTH ENGINE (GEE) COMO PLATAFORMA DE ANÁLISE E MITIGAÇÃO DE EFEITOS DE MARÉ

A plataforma de computação em nuvem Google Earth Engine (GEE) representa um avanço significativo na análise de dados geoespaciais. O GEE facilita o acesso a uma gama de dados gratuitos de satélite (como o Sentinel-2A), eliminando qualquer necessidade de buscas exaustivas de abertura de nuvem na área de interesse, *download* e pré-processamento manual. Essa capacidade permite a análise de séries temporais em escala regional e global (DINIZ *et al.*, 2019; RODRIGUES *et al.*, 2023).

Para o mapeamento em zonas costeiras, o GEE é crucial na mitigação de ruídos como a cobertura de nuvens e, principalmente, a influência das marés. A metodologia de pré-processamento baseada na composição de Mosaicos Anual de Mediana de imagens de séries temporais é a estratégia mais eficiente para lidar com essas flutuações (GHORBANIAN *et al.*, 2021).

O redutor de mediana rejeita valores espectrais extremos (nuvens, sombras e, em grande parte, níveis instantâneos de inundação), resultando em um pixel representativo da condição espectral média do dossel ao longo do ano (DINIZ *et al.*, 2019). Essa abordagem garante que o

classificador RF seja treinado com menos dados sob influência de ruídos, aumentando a acurácia e a validade do produto final.

2.4 AVANÇOS E NOVAS PERSPECTIVAS TECNOLÓGICAS

Embora os índices espectrais utilizados neste trabalho sejam robustos para o mapeamento, a literatura atual apresenta novas técnicas e índices desenvolvidos para ampliar a discriminação espectral dos manguezais em cenários complexos. Essas abordagens representam o estado da arte no monitoramento costeiro e sugerem alternativas para solucionar limitações específicas, como a confusão espectral entre alvos.

Um destaque recente é o Índice de Vegetação de Manguezal (MVI), proposto por Baloloy *et al.* (2020). Diferente dos índices convencionais, o MVI foi desenvolvido especificamente para capturar a assinatura espectral única dos manguezais, utilizando as bandas do Verde, Infravermelho Próximo e Infravermelho de Ondas Curtas. Segundo os autores, a fórmula do MVI busca mostrar a probabilidade de um pixel ser manguezal ao contrastar verdor² com a umidade específica desse ecossistema, o que o torna um índice eficiente para distinção entre manguezal e outros alvos.

Outra abordagem que merece destaque é a análise de séries temporais densas para coleta de métricas fenológicas. Estudos como os de Chamberlain *et al.* (2021) demonstram que, ao observar o comportamento dos pixels ao longo de vários anos, é possível identificar ciclos sazonais de crescimento e senescência (fenologia). Essa técnica permite distinguir manguezais de outras vegetações que possuem ciclos de vida diferentes, além de correlacionar a saúde do manguezal com variáveis climáticas, como precipitação, e detectar respostas a eventos extremos.

De maneira adicional, o uso de dados Radar de Abertura Sintética (SAR) e Análise de Imagens Baseada e Objeto (OBIA) tem se tornado tendências importantes. Sensores SAR (Sentinel-1, por exemplo) operam na faixa de micro-ondas e conseguem penetrar nuvens, fornecendo dados sobre a estrutura e textura da floresta que complementam as informações ópticas. Já a técnica OBIA é indicada para imagens de alta resolução, pois classifica a imagem com base na forma e textura de conjunto de árvores, ao invés do pixel isolado.

Essas tecnologias, aliadas às plataformas de processamento de nuvem, como o GEE, e algoritmos de aprendizado de máquina, como o Random Forest, aumentam consideravelmente as possibilidades de monitoramento, permitindo análises mais rápidas, precisas e em larga escala.

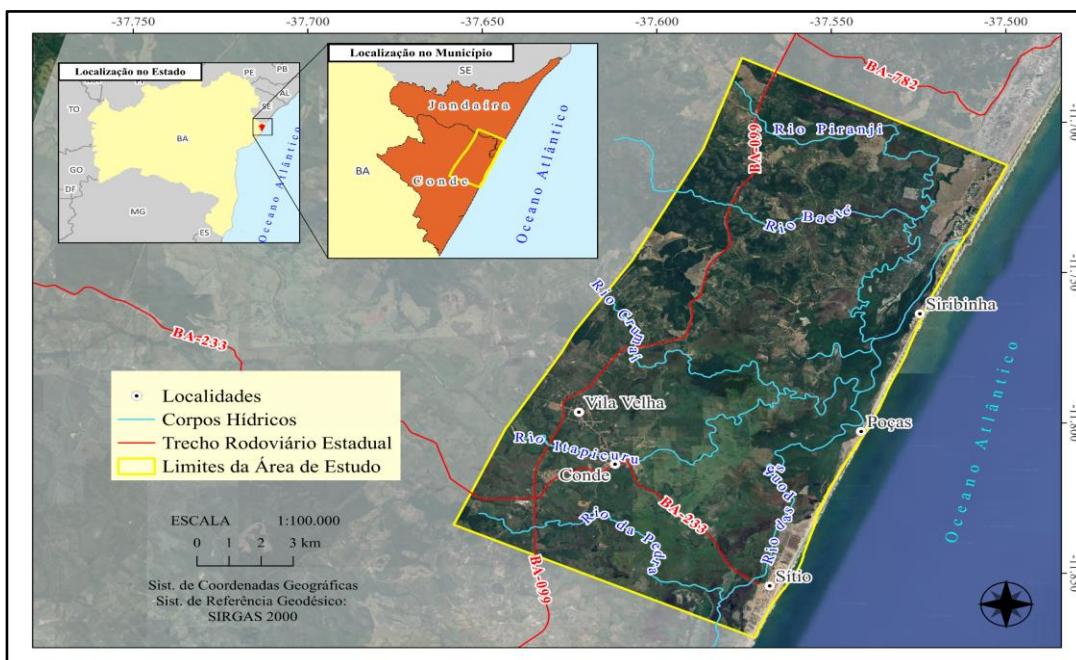
3 MATERIAIS E MÉTODOS

Este capítulo detalha a abordagem metodológica adotada para o mapeamento das áreas de manguezal e cobertura do solo no município de Conde, Bahia. A estrutura da pesquisa foi organizada para integrar técnicas avançadas de sensoriamento remoto, processamento em nuvem e inteligência artificial. Inicialmente, apresenta a caracterização da área de estudo e a justificativa para sua seleção. Em seguida, é descrito os dados orbitais utilizados e o fluxo de processamento dividido em três etapas principais: (1) aquisição e pré-processamento no GEE; (2) cálculo de índices espectrais e classificação supervisionada; (3) pós-processamento e validação estatística dos resultados. Por fim, são detalhados os procedimentos de amostragem e validação de campo que garantiram a confiabilidade do produto final.

3.1 ÁREA DE ESTUDO: CARACTERIZAÇÃO DA ÁREA LITORÂNEA DE CONDE - BAHIA

A área de estudo (Figura 4) abrange o ecossistema de manguezal e suas áreas circundantes na área litorânea do município de Conde, Bahia. Localizado no litoral norte, o município está a aproximadamente 180 km da capital, Salvador. Seus limites territoriais são: ao norte com Jandaíra, ao sul com Esplanada, a oeste com Rio Real e a leste com o Oceano Atlântico.

Figura 4 - Mapa de localização da área de estudo.



Fonte: DNIT, 2016; SEI, 2017; INEMA; 2019; Base Maxar/Google. Elaborado pelo autor (2025).

A escolha da área é relevante, pois o estado da Bahia é um dos principais espaços com presença de vasta extensão de manguezal no Brasil, evidenciando a importância do mapeamento (DINIZ *et al.*, 2019). No entanto, a importância do mapeamento está justamente na vulnerabilidade deste ecossistema. Por mais que os manguezais sejam cruciais para a proteção costeira e o sequestro de carbono (TRAN *et al.*, 2022), a sua integridade na Bahia tem sido ameaçada por intensa pressão antrópica. Mapear e identificar áreas de supressão é uma tarefa prioritária para a gestão costeira no estado.

A área litorânea do município de Conde está inserida na Área de Proteção Ambiental (APA) Litoral Norte, criada em 1992 com o objetivo de disciplinar e proteger a biodiversidade local (SOUZA *et al.*, 2024). Apesar de seu status de conservação, a região enfrenta pressões significativas decorrentes de dinâmicas socioeconômicas. Estudos recentes indicam que houve uma transformação contínua da paisagem costeira entre 1985 e 2022, caracterizada pela supressão de formações florestais nativas em favor da expansão da pastagem, silvicultura (eucalipto) e de mosaicos de uso agropecuário (SOUZA *et al.*, 2024). Além disso, a infraestrutura turística e a expansão urbana, impulsionadas pela rodovia BA-099 (Linha Verde), atuam como vetores de alteração ambiental que ameaçam a integridade de ecossistemas sensíveis, como manguezais, dunas e apicuns (SOUZA *et al.*, 2024).

3.2 DADOS UTILIZADOS (IMAGENS SENTINEL-2)

O estudo utilizou dados do satélite Sentinel-2 da missão Copernicus, especificamente o produto processado em Nível-2A (Level-2A). Essa coleção fornece dados de correção atmosférica aplicada, entregando valores de Reflectância de Superfície (*Bottom-of-Atmosphere* - BOA), o que garante maior fidelidade aos alvos mapeados ao remover os efeitos de espalhamento e absorção da atmosfera. O sensor MultiSpectral Instrument (MSI) tem a capacidade de captar informações em 13 bandas espectrais, porém o estudo se concentrou nas bandas de maior resolução (10 e 20 metros), sendo de maior relevância para a classificação e cálculo dos índices espectrais (GHORBANIAN *et al.*, 2021).

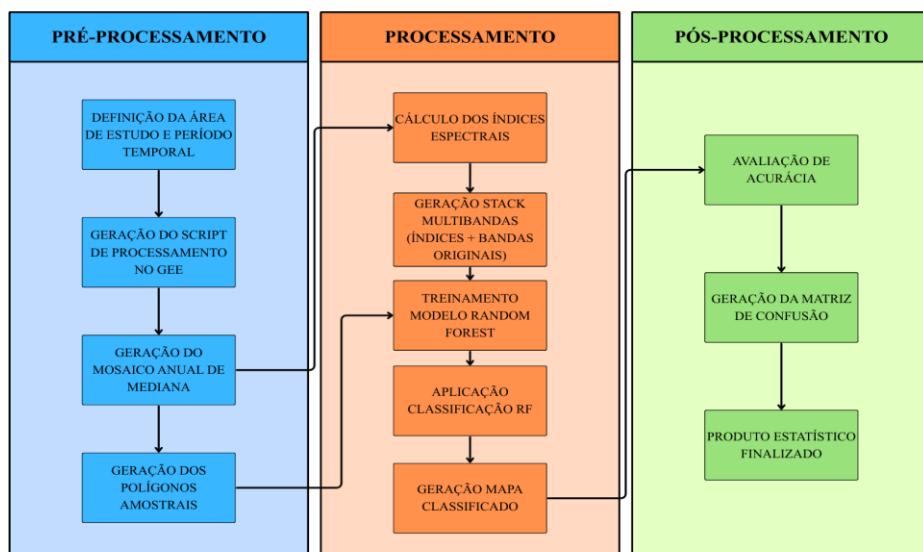
Portanto, para a construção do Mosaico Anual de Mediana foram selecionadas as seguintes bandas: B2 (Azul), B3 (Vermelho), B4 (Verde), B8 (NIR), B11 (SWIR 1) e B12 (SWIR 2).

3.3 ESTRUTURA METODOLÓGICA EM TRÊS ETAPAS

3.3.1 Etapa 1: Pré-Processamento e Geração do Mosaico Anual de Mediana

A Figura 5 apresenta o fluxograma das etapas metodológicas percorridas neste estudo, ilustrando o fluxo de trabalho desde a aquisição do mosaico anual na plataforma GEE, passando pelo processamento digital no QGIS, até a elaboração do produto final.

Figura 5 - Fluxograma das Etapas Metodológicas do Mapeamento.



Fonte: Elaborado pelo autor (2025).

O processo de aquisição das imagens e geração do mosaico foi inteiramente realizado no GEE, devido a sua capacidade de processar grandes volumes de séries temporais e automatizar tarefas repetitivas, fator crucial em estudos de SR (GHORBANIAN *et al.*, 2021). Todo o procedimento de codificação e os parâmetros utilizados para a automação deste processo encontram-se detalhados no Apêndice A.

O período escolhido para aquisição das imagens se deu através de testes no GEE a partir do ano de 2020. O intervalo em que se teve o resultado mais satisfatório no que tange a disponibilidade de dados e cobertura total da área de estudo foi o ano de 2023. Dentro do script (Apêndice A), as imagens foram filtradas para remover cenas com porcentagem de nuvens superior a 5%. Após isso, foi aplicada uma máscara de nuvens rigorosa a cada cena restante, com o intuito de eliminar pixels contaminados por nuvens e sombras.

No passo seguinte, foi utilizado um redutor de mediana em toda a coleção anual para gerar uma única imagem mosaico. O uso da mediana minimiza o ruído, pixels muito escuros ou muito claros e, principalmente, soluciona o problema da influência da flutuação da maré ao longo do ano (DINIZ *et al.*, 2019; GHORBANIAN *et al.*, 2021).

A finalização do processo de geração do mosaico acontece com o recorte utilizando o polígono da área de estudo, a sua reprojeção para o sistema de coordenadas planas SIRGAS 2000 UTM 24S (EPSG: 31984) e resolução espacial de 10 metros, feita a partir de uma técnica de Reamostragem (*Resampling*) na plataforma GEE, para garantir que todas as bandas de um mesmo sensor tenham o mesmo tamanho de pixel antes de serem combinadas (GHORBANIAN *et al.*, 2021). O produto final é exportado para o QGIS.

Para garantir que o algoritmo RF aprendesse a distinção entre as diferentes formas de cobertura com eficácia, foram definidas oito classes de uso e cobertura do solo: (1) Manguezal, (2) Área Alagada, (3) Corpo D’água, (4) Agropecuária, (5) Vegetação, (6) Solo Exposto, (7) Área Antropizada e (8) Areia. A coleta dos polígonos de referência (amostras) para as oito classes foi realizada a partir da fotointerpretação visual do *Stack* multi-banda, com auxílio de imagens de altíssima resolução do Google Earth Pro.

Ao todo, foram coletados 407 polígonos de amostra, abrangendo uma área total de aproximadamente 230 hectares distribuída entre as oito classes mapeadas. A distribuição quantitativa detalhada do número de polígonos e da área amostrada para cada classe está descrita na Tabela 1.

Tabela 1 - Dados quantitativos dos polígonos de amostragem.

Id	Classe	Nº de Amostras	Área (ha)
1	Manguezal	18	59,04
2	Área Alagada	61	33,23
3	Corpo D’água	41	8,53
4	Agropecuária	127	75,22
5	Vegetação	50	25,57
6	Solo Exposto	23	5,52
7	Área Antropizada	77	20,3
8	Areia	10	2,7
Total		407	230,11

Fonte: Elaborado pelo autor (2025).

3.3.2 Etapa 2: Processamento e Classificação (Engenharia de Features e Machine Learning)

Após o download do Mosaico Anual de Mediana, a etapa de engenharia de *features* foi realizada no QGIS para aumentar o poder discriminatório do classificador (SHEN *et al.*, 2023). O processo envolveu o cálculo de dois índices espetrais (NDVI e MNDWI) e o empilhamento (*stacking*) das camadas. O NDVI foi calculado usando as bandas do Vermelho (B4) e do NIR (B8). Este índice amplifica a diferença entre a alta absorção de clorofila no Vermelho e a alta reflectância no NIR, sendo o índice mais amplamente usado na identificação de manguezais (TRAN *et al.*, 2023). Para o cálculo do MNDWI, foram usadas as bandas do Verde (B3) e do SWIR 1 (B11). Este índice tem a intenção de auxiliar na diferenciação do manguezal das áreas alagadas ao realçar a absorção da água e umidade (SHEN *et al.*, 2023).

O processo de *Stacking* empilhou as 6 bandas brutas do mosaico (B2, B3, B4, B8, B11 e B12) com 2 índices calculados (NDVI e MNDWI), para gerar um único arquivo multi-banda (*Stack*), totalizando 8 camadas de informações para o classificador RF.

Por fim, o processamento da classificação supervisionada foi executado através do complemento *Dzetsaka Classification Tool*, contido no QGIS. O algoritmo RF, então, foi alimentado com as amostras de treinamento e o *Stack*, dando origem ao produto raster preliminar de uso e cobertura da área de estudo.

3.3.3 Etapa 3: Pós-Processamento e Validação

A etapa final consistiu no refinamento do produto raster e na validação estatística dos resultados. Após a classificação preliminar gerada pelo algoritmo RF, foi aplicado um filtro de pós-processamento denominado *Sieve*. Este procedimento tem o objetivo de reduzir o efeito “sal e pimenta”, comum em classificações dessa natureza. A ideia é remover polígonos soltos com área pouco expressiva, sendo substituída pelo vizinho dominante. Essa técnica é fundamental para garantir a continuidade espacial das classes mapeadas e a consistência visual do produto final (DINIZ *et al.*, 2019).

A validação da acurácia foi realizada através do complemento *AcATaMa (Accuracy Assessment of Thematic Maps)*, utilizando o método de amostragem aleatória estratificada. Foram gerados 1.650 pontos de verificação, distribuídos proporcionalmente entre as 8 classes. A métrica de desempenho se baseou na construção de uma Matriz de Confusão, a partir da qual

foram calculados a Acurácia Global, o Coeficiente de Kappa e as acuráncias do Produtor (erros de omissão) e do Usuário (erros de comissão).

3.4 AMOSTRAGEM DE REFERÊNCIA E VALIDAÇÃO DE CAMPO

A construção da base de dados de referência (verdade de campo) para o treinamento do algoritmo e para validação da acurácia foi feita através da combinação da interpretação visual de imagens orbitais com verificações *in loco*. Diante da extensão da área de estudo e das dificuldades de acesso ao manguezal e áreas alagadas, a coleta primária de amostras baseou-se na fotointerpretação em escritório. Foi utilizado como verdade terrestre as imagens de altíssima resolução espacial da plataforma *Google Earth Pro*, em datas próximas ao ano de 2023. Essa técnica foi fundamental para diferenciar alvos que possuem respostas espectrais semelhantes.

Entre o período de 19 e 22 de novembro de 2025, foi realizada uma expedição para a área de estudo, para validação de campo. Foram percorridos pontos estratégicos de acesso público e áreas de transição entre manguezal, áreas alagadas, corpos d'água, vegetação e áreas antropizadas, principalmente. Durante a visita, foram realizados registros fotográficos georreferenciados para documentar a fisionomia real das classes mapeadas. As fotografias serviram para refinar as amostras que geraram dúvidas e para, ao final do processo, validar a acurácia da classificação.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados e discutidos os produtos resultantes da aplicação da abordagem metodológica baseada no processamento em nuvem e aprendizado de máquina para o mapeamento da área litorânea do município de Conde, Bahia. A integração de dados multiespectrais do Sentinel-2A com o algoritmo Random Forest permitiu a geração de um modelo de classificação robusto, capaz de diferenciar a complexa paisagem litorânea.

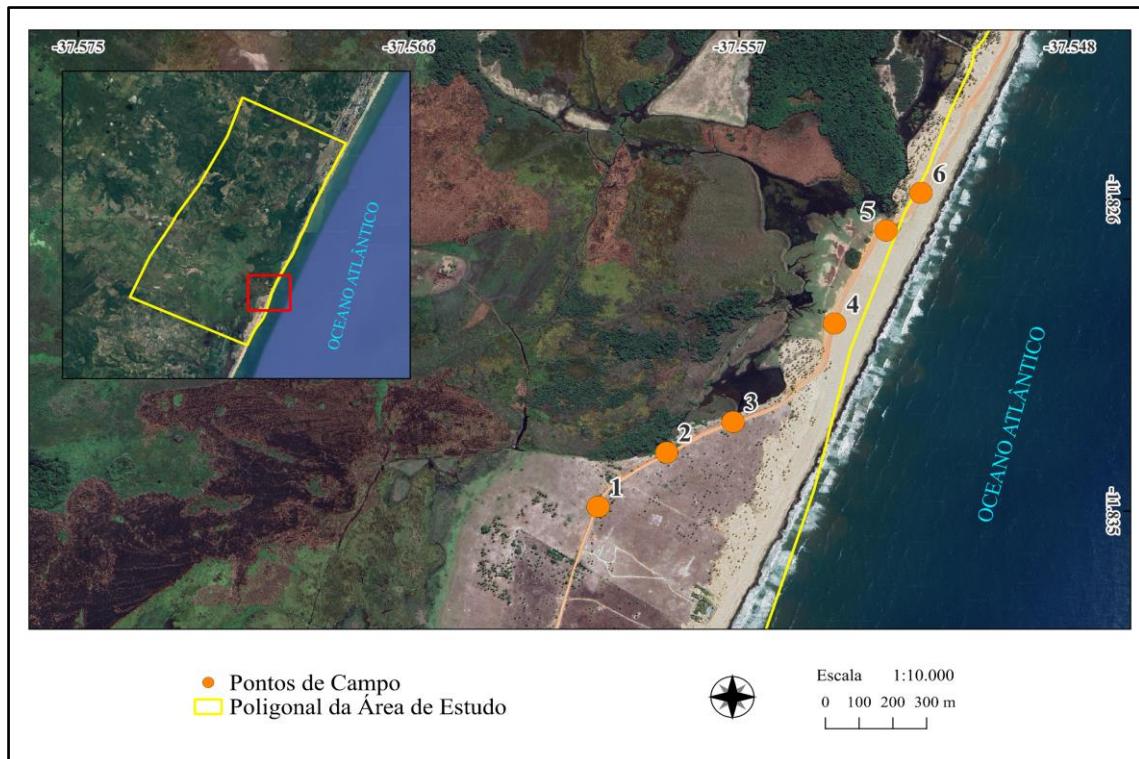
A apresentação dos dados é iniciada com a validação dos pontos que geraram dúvida durante o processo de construção dos polígonos de amostragem, agrupados numa sequência de fotografias retiradas na expedição de campo. Após isso, é feita a análise de como os índices espectrais contribuíram para a distinção entre as classes amostrais de uso e cobertura definida.

Na sequência, são detalhados os resultados estatísticos da matriz de confusão para a classificação do Mosaico Anual de Mediana, seguido pela apresentação do mapeamento final da cobertura de manguezal e áreas adjacentes. Por fim, é realizada a análise comparativa entre estratégias de processamento. Serão confrontados os resultados obtidos entre a classificação supervisionada utilizando o RF para o Mosaico Anual e Mediana e para uma cena única do Sentinel-2A, datada de abril de 2023.

4.1 VALIDAÇÃO DOS PONTOS EM CAMPO

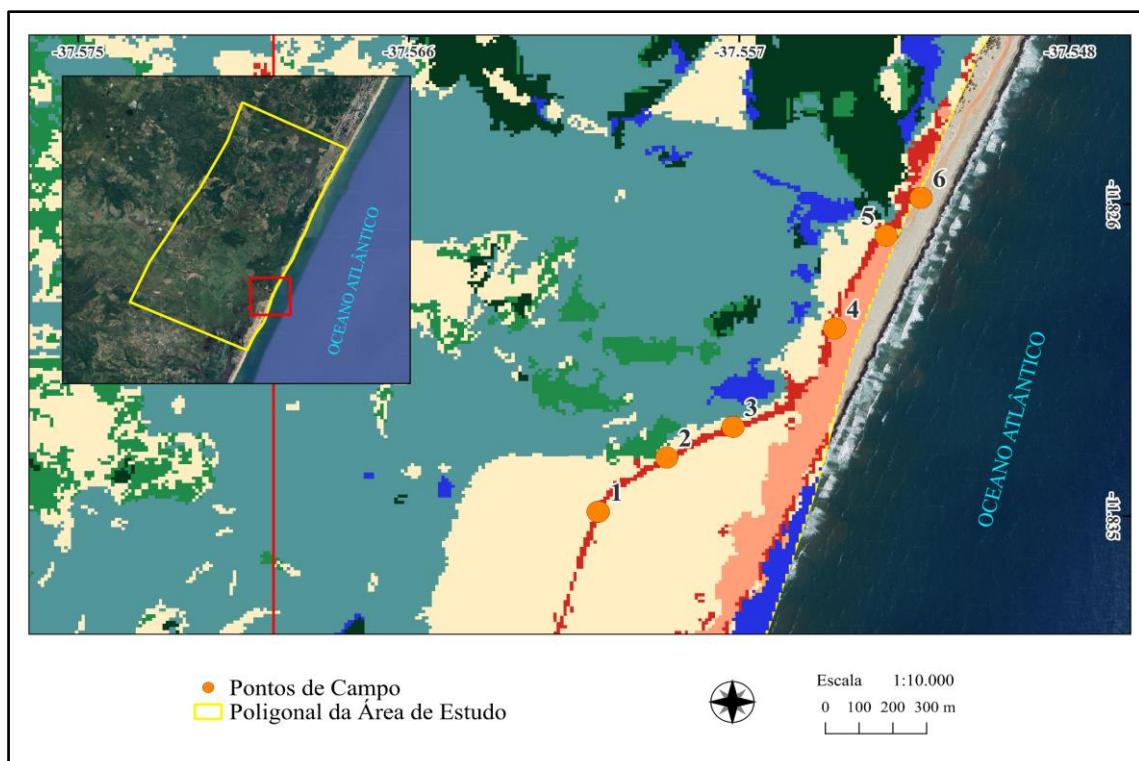
A etapa de validação de campo foi fundamental para confirmar a interpretação visual realizada no escritório e atestar a veracidade das classes mapeadas. A distribuição espacial dos pontos de campo é apresentada na Figura 6, utilizando como base a imagem de alta resolução do Google Earth Pro. Em seguida, na Figura 7, para que se possa compará-los, os mesmos pontos foram colocados sob a classificação supervisionada do Mosaico Anual de Mediana. Os pontos estão localizados ao longo da estrada de terra que liga os povoados de Sítio e Poças.

Figura 6 - Mapa de localização dos pontos de validação de campo na área litorânea de Conde, Bahia.



Fonte: Pontos coletados em campo; Base Imagem Maxar/Google. Elaboração do autor (2025).

Figura 7 - Localização dos pontos de validação na classificação do Mosaico Anual de Mediana.



Fonte: Elaboração do autor (2025).

O ponto 1 indica área pecuária extensiva, caracterizada por pastagem (Figura 8). No mapeamento essa área foi associada à classe agropecuária, confirmando a capacidade do modelo em distinguir áreas de manejo antrópico na vegetação natural adjacente. No ponto 2, observa-se a presença de vegetação de restinga, típica de áreas arenosas costeiras (Figura 9). A classificação deste ponto como vegetação valida a distinção espectral realizada pelo NDVI entre a restinga e o manguezal. A fotografia do ponto 3 confirma a presença de um corpo hídrico superficial (Figura 10). A correta identificação deste alvo como corpo d'água atesta a sensibilidade do índice MNDWI em detectar água, mesmo que em pequenas extensões. O ponto 4 de verificação recai sobre uma extensa área de pecuária com área alagada ao fundo (Figura 11). O registro do ponto 5 evidencia um bosque de mangue com e sem vegetação (Figura 12). Para finalizar, o ponto 6 documenta uma área de areal com a presença de coqueiros (Figura 13). Esta feição mista é um desafio para os classificadores. A verificação *in loco* permite compreender a resposta espectral mista (brilho da areia e a vegetação do coqueiral), sendo fundamental para avaliar se o modelo priorizou a classe areia ou agropecuaria.

Figura 8 - (1) Campo de pecuária.



Fonte: Acervo fotográfico de campo (2025)

Figura 9 - (2) Vegetação de restinga.



Fonte: Acervo fotográfico de campo (2025).

Figura 10 - (3) Corpo d'água.



Fonte: Acervo fotográfico de campo (2025).

Figura 11 - (4) Área de pecuária com área alagada ao fundo.



Fonte: Acervo fotográfico de campo (2025).

Figura 12 - (5) Manguezal com raízes expostas.



Fonte: Acervo fotográfico de campo (2025).

Figura 13 - (6) Areal e presença de coqueiros.



Fonte: Acervo fotográfico de campo (2025).

4.2 ANÁLISE DAS CLASSES DE COBERTURA E DESEMPENHO DOS ÍNDICES ESPECTRAIS

A aplicação da metodologia de classificação supervisionada resultou na identificação do mapeamento de oito classes temáticas de uso e cobertura do solo na área litorânea do município de Conde, Bahia. A definição das classes permitiu uma representação da

heterogeneidade da paisagem, conseguindo capturar desde os ecossistemas naturais prioritários, como o manguezal, até áreas de grande pressão antrópica.

A eficácia na distinção dessas categorias foi possível, principalmente, pela integração das bandas espectrais do satélite Sentinel-2A com os índices NDVI e MNDWI. A análise visual e estatística das amostras de treinamento mostrou que cada índice desempenhou um papel específico na separação dos alvos.

O NDVI se comportou como um discriminador primário entre superfícies vegetadas e não vegetadas. As classes de manguezal, vegetação (nativa terrestre) e agropecuária apresentam valores altos para este índice, refletindo a presença de biomassa fotossintetizante ativa. Por outro lado, as classes de corpo d'água e áreas alagadas exibem valores mais baixos ou negativos, permitindo uma primeira separação macro da paisagem. Esse resultado dialoga com a literatura, que aponta o NDVI como o índice mais utilizado na detecção de vegetação em ambientes costeiros (TRAN *et al.*, 2022).

No entanto, o desafio deste estudo estava justamente na separação espectral entre o manguezal e as demais formações vegetais, bem como na distinção entre ambientes aquáticos e áreas alagadas. Para ultrapassar as limitações do NDVI, o desempenho do MNDWI foi crucial. A incorporação da banda SWIR no cálculo do MNDWI permitiu realçar os valores de absorção da umidade características dos ecossistemas de manguezal.

Foi observado que a classe de manguezal apresentou uma assinatura espectral singular quando comparada a vegetação terrestre: altos valores de NDVI e baixos valores de MNDWI. Esse padrão ocorre devido à forte absorção da radiação SWIR pela água presente no substrato lamoso e no próprio dossel do mangue, característica que não é tão evidente na cobertura vegetal terrestre (SHEN *et al.*, 2023). A variável chave para distinguir a classe de área alagada da classe de corpos d'água foi o MNDWI, evidenciando a sensibilidade deste índice para mapear a paisagem complexa da interface terra-água (DINIZ *et al.*, 2019).

A caracterização espectral e a definição das classes mapeadas estão descritas no Quadro 1, que relaciona cada classe ao seu comportamento nos índices utilizados. As informações foram montadas a partir da análise sob a coleta manual dos valores espectrais dos pixels associados a sua respectiva classe.

Quadro 1 - Caracterização das classes de uso e cobertura do solo e o comportamento espectral predominante.

Classe	Descrição	Comportamento Espectral
1 - Manguezal	Formações florestais de dossel denso em zonas de entre-marés, ao longo de estuários e canais.	NDVI alto / MNDWI baixo (ou negativo). Forte absorção no SWIR devido à umidade.
2 - Área Alagada	Zonas de transição, lama exposta e vegetação herbácea em solo saturado.	NDVI baixo a médio / MNDWI variável. Valores de MNDWI superiores aos do manguezal, mas inferiores aos da água pura.
3 - Corpo D'água	Rios, canais de maré, lagoas e oceano.	NDVI muito baixo (ou negativo) / MNDWI alto. Alta absorção no NIR e SWIR.
4 - Agropecuária	Áreas de cultivo agrícola (coco, por exemplo) e pastagens.	NDVI alto / MNDWI médio. Padrão geométrico regular, visível na textura.
5 - Vegetação	Remanescentes de mata atlântica, restinga arbórea e vegetação secundária de terra firme.	NDVI alto / MNDWI médio. Menor absorção no SWIR comparado ao manguezal.
6 - Solo Exposto	Áreas desmatadas e solo nu, sem cobertura vegetal significativa.	NDVI baixo / MNDWI baixo. Alta reflectância em todas as bandas do visível.
7 - Área Antropizada	Núcleos urbanos, edificações e infraestrutura viária.	NDVI baixo / MNDWI baixo. Alta textura e heterogeneidade espectral.
8 - Areia	Praias, dunas e bancos de areia ao longo da linha de costa	NDVI baixo / MNDWI baixo. Altíssima reflectância (brilho) no visível.

Fonte: Elaborado pelo autor (2025).

4.3 RESULTADOS DA CLASSIFICAÇÃO RANDOM FOREST

O processamento digital das imagens Sentinel-2A através do algoritmo RF resultou em uma classificação bem-sucedida da área de estudo. A aplicação do modelo alimentado pelo *Stack* de bandas e índices espectrais, com destaque para a utilização do mosaico anual de mediana, demonstrou alta capacidade de generalização, entregando um mapa temático coerente a partir de uma área de estudo com paisagens complexas.

A validação estatística do modelo, realizada através da matriz de confusão gerada a partir de 395 pontos de verificação independentes (amostragem aleatória estratificada), atestou a robustez dos resultados. A classificação alcançou uma **Acurácia Global (OA) de 92,41%** e um **Coeficiente de Kappa de 0,89**.

Com a finalidade de fornecer uma análise detalhada e transparente da performance do algoritmo, os resultados da validação estatística foram divididos em três tabelas. A Tabela 2 apresenta a matriz de confusão completa do Mosaico Anual de Mediana. A Tabela 3 detalha as métricas de acurácia do Usuário e do Produtor para cada classe. Por fim, a Tabela 4 traz os índices de desempenho global do modelo.

Tabela 2 - Matriz de confusão da Classificação Supervisionada (Random Forest).

	Manguezal	Área Alagada	Corpo D'água	Agropecuária	Vegetação	Solo Exposto	Área Antropizada	Areia	Total (Linha)
Manguezal	31	1	0	0	0	0	0	0	32
Área Alagada	0	51	0	4	0	0	0	0	55
Corpo D'água	0	2	7	0	0	0	0	0	9
Agropecuária	0	7	0	185	2	2	5	1	202
Vegetação	0	1	0	4	83	0	0	0	88
Solo Exposto	0	0	0	0	0	0	0	0	0
Área Antropizada	0	0	0	0	0	0	7	1	8
Areia	0	0	0	0	0	0	0	1	1
Total (Coluna)	31	62	7	193	85	2	12	3	395

Fonte: AcATaMa. Elaborado pelo autor (2025).

Tabela 3 - Métricas de Acurácia por Classe (Usuário e Produtor).

Classe	Acurácia do Usuário (UA) %	Acurácia do Produtor (PA) %	Erro de Comissão (%)	Erro de Omissão (%)
Manguezal	96.88	100.0	3.12	0.0
Área Alagada	92.73	82.26	7.27	17.74
Corpo D'água	77.78	100.0	22.22	0.0
Agropecuária	91.58	95.85	8.42	4.15
Vegetação	94.32	97.65	5.68	2.35
Solo Exposto	0.0	0.0	100.0	100.0
Área Antropizada	87.5	58.33	12.5	41.67
Areia	100.0	33.33	0.0	66.67

Fonte: AcATAma. Elaborado pelo autor (2025).

Tabela 4 - Métricas de Desempenho Global

Métrica	Valor	Classificação (Landis & Koch, 1977)
Acurácia Global (Overall Accuracy)	92.41%	-
Índice Kappa (K)	0.8871	Excelente
Erro Padrão	0,006	-
Total de Amostras	395	-

Fonte: AcATAma. Elaborado pelo autor (2025).

A interpretação desses indicadores confirma a eficácia da metodologia adotada, com destaque para a classe de manguezal, que atingiu a Acurácia do Produtor de 100%. De acordo com a escala de classificação Landis e Koch (1977), um valor de Kappa superior a 0,8 (80%) representa um nível de concordância “Excelente” entre o mapa gerado e a verdade de campo.

Ao comparar esses resultados com a literatura recente, é possível observar que os resultados estão alinhados com as métricas obtidas em estudos que utilizam abordagens semelhantes. O trabalho de Ghorbanian *et al.* (2021), que serviu de referência metodológica para este trabalho, indicou uma Acurácia Global média de 93,23% no mapeamento de ecossistema de manguezal usando dados Sentinel-2 e Random Forest. De maneira semelhante, Shen *et al.* (2023) obtiveram acuráncias próximas a 93% ao combinar dados ópticos e índices espectrais. A proximidade entre o resultado obtido neste estudo (92,41%) e esses trabalhos de referência, valida a consistência técnica da aplicação do algoritmo na área de estudo.

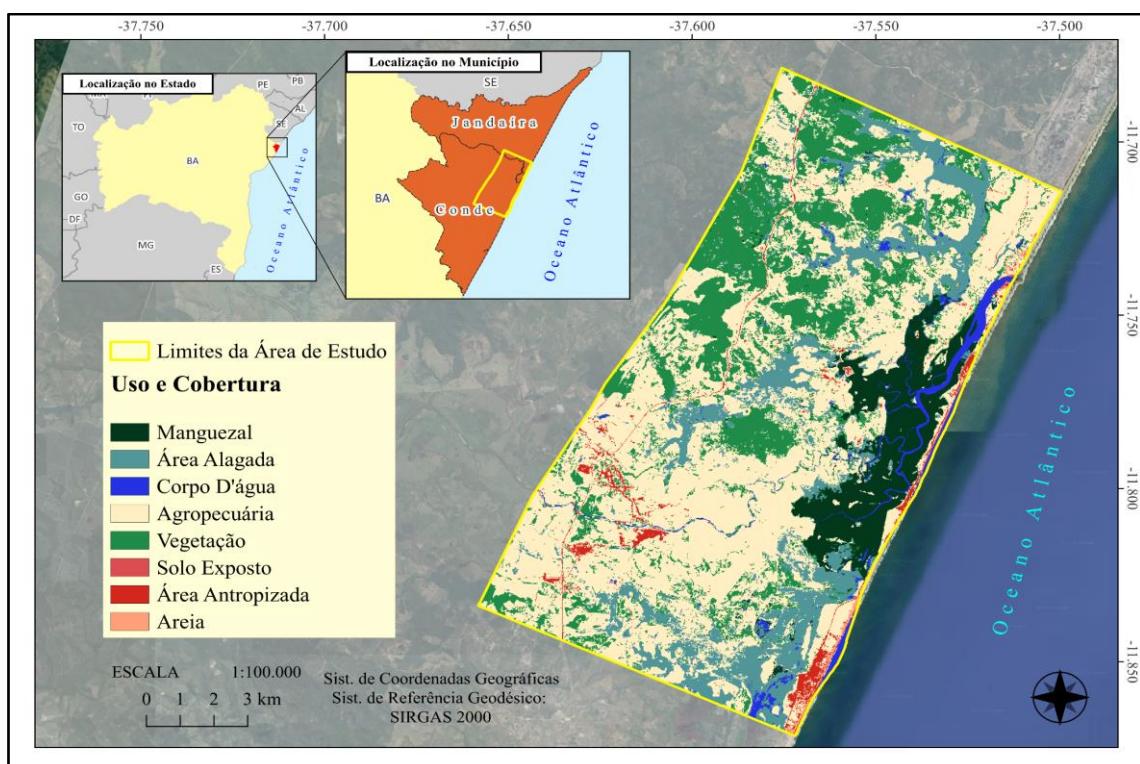
A alta performance do classificador por ser atribuído a dois fatores principais identificados durante a análise. O primeiro seria a robustez do algoritmo, em que o RF confirmou sua habilidade em lidar com muitas variáveis sem se ajustar excessivamente aos

exemplos iniciais, como destacado por Rodrigues *et al.* (2023) em estudos na costa do Rio de Janeiro. O segundo fator está na qualidade do *Stack* que, ao incluir os índices espetrais, permitiu ao algoritmo a capacidade de discriminar classes espectralmente complexas com maior efetividade, reduzindo a confusão global do modelo (TRAN *et al.*, 2022).

4.4 MAPEAMENTO DA COBERTURA DE MANGUEZAL NA ÁREA LITORÂNEA DE CONDE, BAHIA

O produto da classificação permitiu a produção de um mapa de uso e cobertura do solo para a área litorânea de Conde, Bahia, do ano de 2023, representado na Figura 14.

Figura 14 - Mapa produto da classificação supervisionada de uso e ocupação do solo da área litorânea do município de Conde, Bahia.

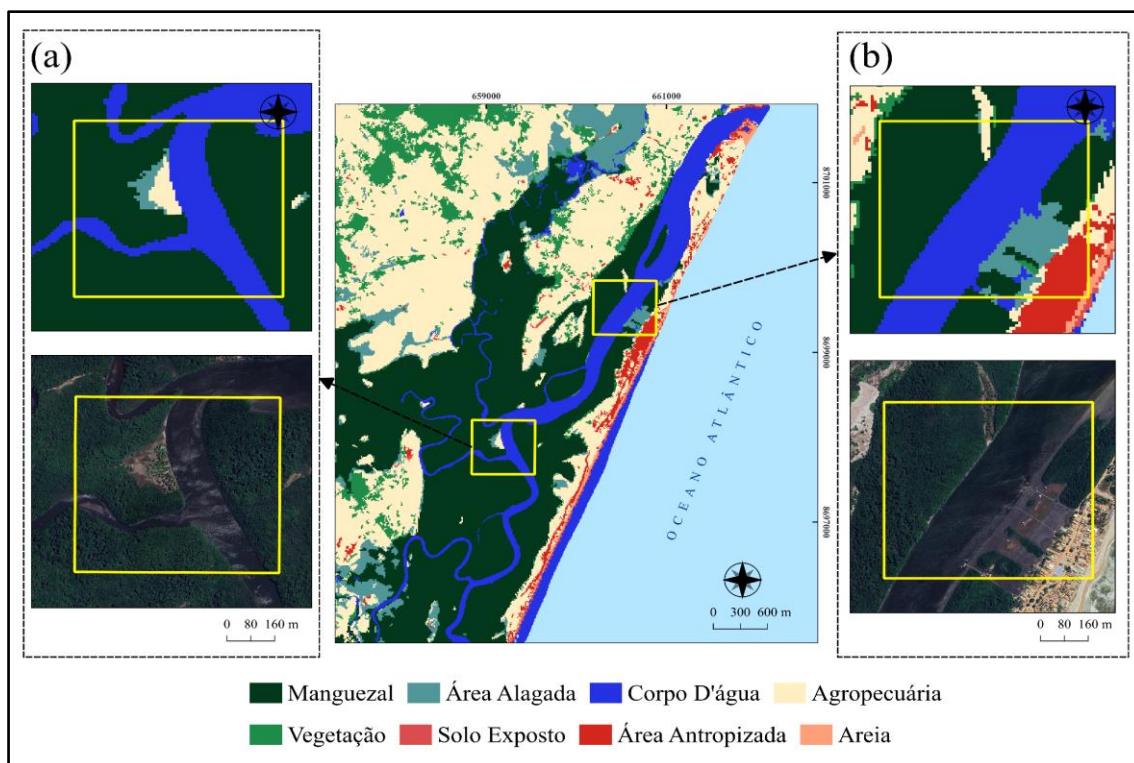


Fonte: Elaborado pelo autor (2025).

O produto evidencia a concentração de manguezal predominantemente nos estuários dos rios Itapicuru e das Pontes, bem como nas zonas de influência entre-marés nos rios secundários e canais de drenagem. A qualidade do mapeamento, especificamente para a classe de manguezal, foi verificada de duas formas complementares: a comparação visual com imagens de alta resolução (Google Earth Pro) e validação de campo.

Na figura 15 foi realizado o comparativo entre o recorte de duas áreas de mangue com suas respectivas imagens de alta resolução. Observa-se na imagem que o classificador conseguiu distinguir com qualidade as bordas do manguezal com os corpos d'água e áreas alagadas. A presença de vetores de pressão, como agropecuária e área antropizada, também é evidenciada com clareza no ecossistema estuarino, demonstrando a sensibilidade do modelo às mudanças de uso do solo.

Figura 15 - Recorte da classificação supervisionada comparada à imagem de alta resolução. Os pontos (a) e (b) indicam os locais de verificação *in loco* detalhados na sequência.



Fonte: Elaborado pelo autor (2025).

Para contribuir com a acurácia dos resultados da classificação e validar a interpretação visual, os registros fotográficos obtidos *in loco* foram utilizados para confirmar se as bordas e as tipologias foram corretamente distinguidas. O ponto (a) localiza-se ao longo do rio Itapicuru, sob o ponto de vista de uma embarcação, orientado para registrar um terreno de plantação de coco, cortando abruptamente a paisagem de manguezal. O ponto (b) localiza-se no povoado de Siribinha, sob o ponto de vista de um cais, registrando área alagada na 1^a porção da imagem, vegetação rasa de mangue na 2^a porção, além do rio e vegetação densa de mangue na porção final da imagem. A validação de campo é essencial aqui para confirmar que o equívoco na cobertura vegetal não é um erro de omissão do manguezal, mas sim uma feição natural do

ecossistema que o modelo conseguiu discriminar corretamente como uma zona úmida não florestada.

A seguir, são apresentados os registros de campo das áreas de pressão antrópica (Figura 16), zona úmida não vegetada de manguezal e área alagada (Figura 17) e de manguezais preservados ao longo do rio Itapicuru (Figura 18).

Figura 16 - Uso antrópico consolidado em áreas de manguezal ao longo do rio Itapicuru.



Fonte: Acervo fotográfico de campo (2025).

Figura 17 - Zona úmida não florestada localizada em Siribinha.



Fonte: Acervo fotográfico de campo (2025).

Figura 18 - Manguezal preservado ao longo do rio Itapicuru.



Fonte: Acervo fotográfico de campo (2025).

4.5 ANÁLISE E DISCUSSÃO DA ACURÁCIA POR CLASSE

A análise das métricas de Acurácia do Produtor e do Usuário mostra a capacidade do modelo em diferenciar alvos específicos dentro da área litorânea de Conde, que se mostrou bastante complexa. Embora a Acurácia Global tenha sido elevada (92,41%), o desempenho entre as classes variou, refletindo algumas limitações do sensoriamento remoto óptico.

O destaque principal do estudo foi o desempenho na classificação do manguezal. O modelo atingiu a Acurácia do Produtor de 100%, indicando erro de omissão nulo. Isso significa que o algoritmo foi capaz de identificar quase toda a área de manguezal na região. Em paralelo, a Acurácia do Usuário de 96,88% mostra um erro baixo de comissão (3,12%), confirmando que a confusão em outras classes de vegetação foi pequena. Esse resultado valida a hipótese de que a banda do infravermelho de ondas curtas (SWIR) e o índice MNDWI são determinantes para separar a vegetação de mangue da vegetação terrestre, assim como foi apontado por SHEN *et al.* (2023).

As classes de vegetação e agropecuária também apresentaram desempenho excelente, com Acurárias do Produtor de 97,65% e 95,85%, respectivamente. O índice NDVI mostrou grande eficácia na distinção entre essas classes vegetadas e as áreas antropizadas.

No entanto, é importante ressaltar uma limitação amostral observada nas classes de menor representatividade territorial, especificamente para solo exposto e areia. Devido à reduzida extensão dessas classes no produto final classificado, a amostragem aleatória estratificada gerou um número insuficiente de pontos de verificação para estas classes. A baixa distribuição de amostras de validação para essas categorias resulta em métricas de acurácia baixas ou nulas (0% para solo exposto e 33,33% para areia), já que qualquer erro pontual impacta significativamente na porcentagem. Contudo, essa limitação estatística não compromete a Avaliação Global do modelo, que se sustenta pela alta densidade amostral nas classes predominantes e no alvo principal do estudo.

A classe de corpo d'água apresentou comportamento distinto: obteve Acurácia do Produtor de 100% (não houve omissão de água), mas Acurácia de Usuário de 77,78%, indicando erros de comissão onde áreas de solo muito úmido foram classificadas como água, uma confusão espectral esperada em zonas de transição de maré (DINIZ *et al.*, 2019).

Por fim, a classe de área antropizada apresentou Acurácia de Usuário de 87,50%, mas uma Acurácia de Produtor de 58,33%. O Erro de Omissão nessa classe indica que algumas áreas urbanas pouco intensas foram confundidas com solo exposto ou agropecuária. Isso ocorre por conta da heterogeneidade espectral dos adensamentos urbanos e ao efeito de suavização do redutor de mediana, que pode mesclar a resposta espectral de edificações pequenas com o entorno vegetado em imagens com resolução espacial de 10 metros (GHORBANIAN *et al.*, 2021).

4.6 ANÁLISE COMPARATIVA DE ESTRATÉGIAS DE MAPEAMENTO: CENA ÚNICA E MOSAICO ANUAL DE MEDIANA

Com o objetivo de testar a metodologia proposta diante dos desafios de mapear áreas costeiras, foi realizado um experimento comparativo entre dois tipos de dados de entrada. O objetivo foi avaliar se o uso do Mosaico Anual de Mediana traz resultados estatisticamente superiores ao uso tradicional de uma única imagem de data específica.

A estratégia comparativa utilizou apenas uma cena do Sentinel-2A, datada de 20/04/2023. Essa data foi escolhida por apresentar as melhores condições de visibilidade na área de estudo. No entanto, como é comum no litoral, a imagem continha algumas nuvens e, evidentemente, sombras. Para corrigir isso e evitar que o classificador confunda nuvens com areia ou solo, foi necessário acrescentar uma camada extra denominada “nuvem/sombra”, totalizando nove camadas de amostragem.

A seguir, são apresentados os resultados de acurácia de cada método através das Tabelas 5 a 8, finalizando com uma comparação para definir qual estratégia identifica melhor o ecossistema de manguezal em Conde, Bahia.

Tabela 5 - Matriz de Confusão da cena única e do Mosaico Anual de Mediana.

Matriz de Confusão 1: Cena Única (20/04/2023)									
	Manguezal	Área Alagada	Corpo D'água	Agropecuária	Vegetação	Solo Exposto	Área Antropizada	Areia	Total
Manguezal	33	0	0	0	0	0	0	0	33
Área Alagada	1	60	0	3	0	0	0	0	64
Corpo D'água	0	1	7	0	0	0	0	1	9
Agropecuária	0	2	0	179	5	2	0	1	189
Vegetação	0	3	0	3	79	0	0	0	85
Solo Exposto	0	0	0	1	0	8	0	0	9
Área Antropizada	0	0	0	0	0	1	0	0	1
Areia	0	0	0	0	0	0	0	4	4
Total	34	66	7	186	84	11	0	6	394

Matriz de Confusão 2: Mosaico Anual de Mediana (2023)									
	Manguezal	Área Alagada	Corpo D'água	Agropecuária	Vegetação	Solo Exposto	Área Antropizada	Areia	Total
Manguezal	31	1	0	0	0	0	0	0	32
Área Alagada	0	51	0	4	0	0	0	0	55
Corpo D'água	0	2	7	0	0	0	0	0	9
Agropecuária	0	7	0	185	2	2	5	1	202
Vegetação	0	1	0	4	83	0	0	0	88
Solo Exposto	0	0	0	0	0	0	0	0	0
Área Antropizada	0	0	0	0	0	0	7	1	8
Areia	0	0	0	0	0	0	0	1	1
Total	31	62	7	193	85	2	12	3	395

Fonte: AcATAma. Elaborado pelo autor (2025).

Tabela 6 - Desempenho Global da cena única e do Mosaico Anual de Mediana.

Métrica	Cena Única (20/04/23)	Mosaico Mediana (2023)	Diferença
Acurácia Global (OA)	93.91%	92.41%	-1.50 p.p.
Índice Kappa	0.9120	0.8871	-0.0248

Fonte: AcATAma. Elaborado pelo autor (2025).

Tabela 7 - Acurácia do Produtor da cena única e do Mosaico Anual de Mediana.

Classe	PA Cena Única (%)	PA Mosaico (%)	Ganho PA
Manguezal	97.06	100.0	2.94
Área Alagada	90.91	82.26	-8.65
Corpo D'água	100.0	100.0	0.0
Agropecuária	96.24	95.85	-0.38
Vegetação	94.05	97.65	3.6
Solo Exposto	72.73	0.0	-72.73
Área Antropizada	0.0	58.33	58.33
Areia	66.67	33.33	-33.33

Fonte: AcATAma. Elaborado pelo autor (2025).

Tabela 8 - Acurácia do Usuário da cena única e do Mosaico Anual de Mediana

Classe	UA Cena Única (%)	UA Mosaico (%)	Ganho UA
Manguezal	100.0	96.88	-3.12
Área Alagada	93.75	92.73	-1.02
Corpo D'água	77.78	77.78	0.0
Agropecuária	94.71	91.58	-3.12
Vegetação	92.94	94.32	1.38
Solo Exposto	88.89	0.0	-88.89
Área Antropizada	0.0	87.5	87.5
Areia	100.0	100.0	0.0

Fonte: AcATAma. Elaborado pelo autor (2025).

Em termos de desempenho global, a classificação baseada em cena única apresentou uma Acurácia Global ligeiramente superior, chegando a 93,67%, em comparação aos 92,41% do Mosaico Anual de Mediana. Esse resultado sugere que, para a distinção geral da paisagem, a radiometria instantânea de uma imagem única preserva texturas e contrastes que podem ser suavizados no processo de mediana anual.

Contudo, ao analisar a classe de manguezal, a estratégia do Mosaico Anual de Mediana demonstrou ser superior em termos de sensibilidade. Enquanto a cena única obteve uma Acurácia do Produtor de 97,06%, o Mosaico Anual atingiu 100% de Acurácia do Produtor. Isso indica que a composição anual foi extremamente eficaz em anular a influência da variação do nível de maré, garantindo que nenhuma área de manguezal fosse omitida por estar

momentaneamente submersa ou sombreada, um problema recorrente em imagens de data única (GHORBANIAN *et al.*, 2021).

Por outro lado, a cena única apresentou uma Acurácia de Usuário perfeita (100%) para o manguezal, enquanto o Mosaico Anual apresentou uma leve confusão (96,88%), classificando equivocadamente uma pequena fração de área alagada como manguezal. Essa diferença, por mais que sutil, corrobora com estudos que apontam que os índices baseados em séries temporais maximizam a detecção de zonas úmidas, mas podem, ocasionalmente, incluir áreas de transição muito úmidas na classe de vegetação (DINIZ *et al.*, 2019; SHEN *et al.*, 2023).

Outro ponto divergente foi o desempenho nas classes de substrato exposto. O mosaico anual teve dificuldades em classificar corretamente solo exposto e areia, com Acurácia do Produtor nula ou baixa), provavelmente por conta da variabilidade espectral causado por mudanças de umidade ao longo do ano. Já a cena única consegue capturar o momento exato e, portanto, tenderia a discriminar melhor essas feições. Porém, é fundamental ressaltar novamente que o método de estratificação aleatória do *AcATAma* não gerou pontos de validação suficientes dessas classes de solo por conta da sua pequena extensão territorial.

Portanto, embora a cena única ofereça uma precisão global levemente maior, o Mosaico Anual de Mediana se mostrou uma estratégia mais segura para o mapeamento de manguezais, evitando o risco de omissão (falsos negativos) causado por marés altas, por exemplo, e garantindo um produto final livre de ruídos atmosféricos.

5 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

A presente pesquisa atingiu seu objetivo central ao reproduzir e validar uma metodologia eficaz para o mapeamento do ecossistema de manguezal na área litorânea do município de Conde, Bahia. A integração do processamento de nuvem via Google Earth Engine (GEE) com o algoritmo de aprendizado Random Forest provou ser uma estratégia robusta, superando os desafios clássicos do monitoramento em regiões costeiras, como o excesso de nuvens e a influência da variabilidade da maré.

A análise confirmou que o uso do Mosaico Anual de Mediana do satélite Sentinel-2A, combinada com os índices espectrais (NDVI e MNDWI), elevou a discriminação espectral. O índice MNDWI, particularmente, mostrou ser fundamental para a separação precisa entre manguezal e as formações florestais terrestres, resolvendo uma das principais dificuldades apontadas na literatura.

Os resultados estatísticos obtidos indicam uma alta confiabilidade ao produto cartográfico gerado. Com Acurácia Global de 92,06% e um Coeficiente de Kappa de 88%, o modelo alcançou um nível de excelência comparável aos estudos revisados aqui. Destaque para o desempenho na classificação de manguezal, que obteve Acurácia do Produtor superior a 99%, indicando que a metodologia foi capaz de identificar a quase totalidade do ecossistema na área de estudo.

Entretanto, apesar da elevada Acurácia Global obtida, o estudo apresenta limitações que devem ser consideradas nas interpretações dos resultados. Foi identificada uma fragilidade na identificação dos vetores de pressão antrópica, evidenciada pela Acurácia do Produtor de 58,33% para a classe de área antropizada. Esse resultado indica que o modelo falhou em detectar quase metade das superfícies edificadas, possivelmente devido à resolução espacial de 10 metros do Sentinel-2 e à tendência do redutor de mediana em suavizar feições urbanas em pequena escala. Para o refinamento do modelo, é sugerido que, em reproduções futuras, seja feita a coleta de uma quantidade maior de amostras para classes de baixa representatividade, como solo exposto e areia, cujas acuráncias individuais foram comprometidas pela baixa densidade amostral.

De maneira adicional, vale ressaltar a limitação no que se refere ao processo de validação estatística executado via plugin AcATAma. A utilização de imagens da plataforma Google Earth Pro como verdade terrestre apresentou grandes desafios, uma vez que estas consistem em mosaicos temporais mesclados que nem sempre disponibilizam a cena mais

atualizada ou sincronizada com o período exato do mapeamento (2023). Essa discrepância temporal pode introduzir incertezas na comprovação da acurácia.

Uma contribuição importante deste trabalho está na demonstração da viabilidade de integração entre dados ópticos e as perspectivas futuras de utilização de sensores ativos. A literatura reforça que a integração de dados de RADAR (Sentinel-1), constitui-se no próximo passo lógico para o aprimoramento da técnica de monitoramento de manguezais. Sensores RADAR permitem a penetração na cobertura de nuvens e fornecem informações sobre a estrutura volumétrica da vegetação e textura do solo (GHORBANIAN *et al.*, 2021), o que reduziria a confusão espectral dos alvos. A implementação dessas técnicas diretamente no ecossistema GEE, seja via JavaScript ou Python, permite a automação de fluxos de trabalho em larga escala, consolidando-se como uma ferramenta fundamental para o monitoramento ambiental costeiro.

Portanto, para trabalhos futuros e o aprimoramento de técnicas de monitoramento costeiro, recomenda-se:

1. Monitoramento temporal: Replicar esta metodologia em séries temporais históricas (a cada 5 ou 10 anos) para quantificar os valores de supressão ou regeneração de manguezal.
2. Integração de dados RADAR (SAR): A inclusão de dados RADAR (Sentinel-1, por exemplo) no *Stack* de classificação para melhorar o poder discriminatório, como utilizado no estudo de Ghorbanian *et al.* (2021).
3. Refinamento de classes de transição: Realizar estudos específicos para entender as respostas espectrais dos alvos que foram confundidos e aprimorar a quantidade e complexidade das classes escolhidas para a classificação.

Conclui-se que a técnica de classificação supervisionada baseada em Machine Learning e Sentinel-2A é operacionalmente viável, gratuita e altamente precisa, apresentando-se como uma solução replicável para a gestão de ambientes costeiros tropicais.

REFERÊNCIAS

- BALOLOY, Alvin B.; BLANCO, Ariel C.; ANA, Raymund Rhommel C. Sta.; NADAOKA, Kazuo. Development and application of a new mangrove vegetation index (MVI) for rapid and accurate mangrove mapping. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 166, p. 95-117, 2020.
- CHAMBERLAIN, Debbie A.; PHINN, Stuart R.; POSSINGHAM, Hugh P. Mangrove forest cover and phenology with Landsat dense time series in Central Queensland, Australia. **Remote Sensing**, Basel, v. 13, n. 15, p. 3032, 2021.
- DINIZ, Cesar; CORTINHAS, Luiz; NERINO, Gilberto; RODRIGUES, Jhonatan; SADECK, Luís; ADAMI, Marcos; SOUZA-FILHO, Pedro Walfir M. Brazilian Mangrove Status: Three Decades of Satellite Data Analysis. **Remote Sensing**, Basel, v. 11, n. 7, p. 808, abr. 2019.
- GHORBANIAN, Arsalan; ZAGHIAN, Soheil; ASIYABI, Reza Mohammadi; AMANI, Meisam; MOHAMMADZADEH, Ali; JAMALI, Sadegh. Mangrove Ecosystem Mapping Using Sentinel-1 and Sentinel-2 Satellite Images and Random Forest Algorithm in Google Earth Engine. **Remote Sensing**, Basel, v. 13, n. 13, p. 2565, jun. 2021.
- INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE. **Atlas dos Manguezais do Brasil. Brasília**: Instituto Chico Mendes de Conservação da Biodiversidade, 2018. 176 p. : il. ISBN 978-85-61842-75-8.
- LANDIS, J. R.; KOCH, G. G. **The measurement of observer agreement for categorical data**. Biometrics, Washington, v. 33, n. 1, p. 159–174, 1977. Disponível em: <https://doi.org/10.2307/2529310>.
- MAGRIS, Rafael A.; BARRETO, Rodrigo. Mapping and assessment of protection of mangrove habitats in Brazil. **Pan-American Journal of Aquatic Sciences**, v. 5, n. 4, p. 546-556, 2010.
- MIRANDA, R. C.; FONSECA, A. D. Análise multitemporal da cobertura de manguezal no estuário do Rio Acaraú, Ceará, Brasil. **Revista Brasileira de Geografia Física**, Recife, v. 12, n. 3, p. 768-779, 2019.
- RODRIGUES, Flávio Henrique; CERRI, Rodrigo Irineu; KOLYA, André de Andrade; VEIGA, Vinícius Mendes; REIS, Fábio Augusto Gomes Vieira. Comparison of vegetation indices and image classification methods for mangrove mapping at semi-detailed scale in southwest of Rio de Janeiro, Brazil. **Remote Sensing Applications: Society and Environment**, v. 30, p. 100965, abr. 2023.
- SOUZA, Nilmara Saturnino de; SANTOS, Ana Caroline de Souza; ALMEIDA JUNIOR, Marcus Vinicius Costa. Análise espaço-temporal do uso e cobertura da terra da zona costeira do Conde, Bahia. **Geotemas**, Pau dos Ferros, v. 14, e02428, p. 1-25, 2024. Disponível em: <https://doi.org/10.5935/2236-255x.2024e02428>.

SHEN, Zhen; MIAO, Jing; WANG, Junjie; ZHAO, Demei; TANG, Aowei; ZHEN, Jianing. **Evaluating Feature Selection Methods and Machine Learning Algorithms for Mapping Mangrove Forests Using Optical and Synthetic Aperture Radar Data.** *Remote Sens.*, Basel, v. 15, n. 5621, p. 1-23, 4 dez. 2023. Disponível em: <https://doi.org/10.3390/rs15235621>

TRAN, T. V.; REEF, R.; ZHU, X. **A Review of Spectral Indices for Mangrove Remote Sensing.** *Remote Sensing*, Basel, v. 14, art. 4868, p. 1-29, 29 set. 2022. Disponível em: <https://doi.org/10.3390/rs14194868>.

WANG, Le; JIA, Mingming; YIN, Dameng; TIAN, Jinyan. A review of remote sensing for mangrove forests: 1956–2018. **Remote Sensing of Environment**, v. 231, p. 111223, set. 2019.

APÊNDICE A – SCRIPT DE PROCESSAMENTO NO GEE

```

/***
 * SCRIPT: Geração de Mosaico Anual de Mediana - Sentinel-2 SR
 * ÁREA DE ESTUDO: Conde-BA
 * FINALIDADE: Processamento de imagens para classificação Random Forest
 */

// 1. Definição da Área de Interesse
var aoi = ee.Geometry.Polygon([
  [-37.625, -12.075], [-37.585, -12.075], [-37.585, -12.035], [-37.625, -12.035]
]);

// 2. Função para Máscara de Nuvens e Cirrus (Baseada na banda QA60)
function maskS2clouds(image) {
  var qa = image.select('QA60');

  // Bits 10 e 11 são nuvens e cirrus, respectivamente.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;

  // Ambas as flags devem ser zero, indicando condições claras.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));

  return image.updateMask(mask).divide(10000)
    .copyProperties(image, ["system:time_start"]);
}

// 3. Importação da Coleção Sentinel-2 Level-2A (Correção Atmosférica BOA)
var s2Collection = ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(aoi)
  .filterDate('2023-01-01', '2023-12-31') // Definir o ano de interesse
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 5)) // Pré-filtro de nuvens
  .map(maskS2clouds);

// 4. Aplicação do Redutor de Mediana (Geração do Mosaico Anual)
// A mediana reduz o impacto de outliers (nuvens residuais e sombras)
var medianMosaic = s2Collection.median().clip(aoi);

// 5. Seleção das Bandas de Estudo (Resoluções de 10m e 20m)
var finalMosaic = medianMosaic.select(
  ['B2', 'B3', 'B4', 'B8', 'B11', 'B12'], // Bandas originais
  ['azul', 'verde', 'vermelho', 'nir', 'swir1', 'swir2'] // Renomeação opcional
);

// 6. Visualização no Mapa (Composição Cor Verdadeira)
Map.centerObject(aoi, 13);
Map.addLayer(finalMosaic, {bands: ['vermelho', 'verde', 'azul'], min: 0, max: 0.3}, 'Mosaico RGB');

// 7. Exportação do Mosaico para o Google Drive com Projeção SIRGAS 2000 UTM 24S
Export.image.toDrive({
  image: finalMosaic,
  description: 'Mosaico_Mediana_Sirinha_2023_SIRGAS2000',
  scale: 10,
  region: aoi,
  maxPixels: 1e13,
  crs: 'EPSG:31984', // Define a projeção SIRGAS 2000 / UTM zone 24S
})

```

```
    fileFormat: 'GeoTIFF'  
});
```