

Trabalho de Formatura

Curso de Graduação em Engenharia Ambiental

**“AVALIAÇÃO DO DESEMPENHO DO CLASSIFICADOR SVM PARA O
MAPEAMENTO DE MANGUEZAIS NA BAIXADA SANTISTA/SP”**

Julya Paes de Souza

Prof(a). Dr(a). Lucília do Carmo Giordano

Rio Claro (SP)

2025

UNIVERSIDADE ESTADUAL PAULISTA

Instituto de Geociências e Ciências Exatas

Câmpus de Rio Claro

JULYA PAES DE SOUZA

**“AVALIAÇÃO DO DESEMPENHO DO CLASSIFICADOR
SVM PARA O MAPEAMENTO DE MANGUEZAIS NA
BAIXADA SANTISTA/SP”**

Trabalho de Formatura apresentado ao Instituto de Geociências e Ciências Exatas - Câmpus de Rio Claro, da Universidade Estadual Paulista Júlio de Mesquita Filho, para obtenção do grau de Engenheiro Ambiental.

Rio Claro - SP

2025

S729a

Souza, Julya Paes de

Avaliação do desempenho do classificador SVM para o mapeamento de manguezais na Baixada Santista/SP / Julya Paes de Souza. -- Rio Claro, 2025

61 p. : tabs., fotos, mapas

Trabalho de conclusão de curso (Bacharelado - Engenharia Ambiental) - Universidade Estadual Paulista (UNESP), Instituto de Geociências e Ciências Exatas, Rio Claro

Orientadora: Lucília do Carmo Giordano

1. Engenharia ambiental. 2. Sensoriamento remoto. 3. Ecologia costeira. I. Título.

JULYA PAES DE SOUZA

“AVALIAÇÃO DO DESEMPENHO DO CLASSIFICADOR
SVM PARA O MAPEAMENTO DE MANGUEZAIS NA
BAIXADA SANTISTA/SP”

Trabalho de Formatura apresentado ao Instituto
de Geociências e Ciências Exatas - Câmpus de
Rio Claro, da Universidade Estadual Paulista
Júlio de Mesquita Filho, para obtenção do grau
de Engenheiro Ambiental.

Comissão Examinadora

Lucilia Do Carmo Giordano (orientadora)

Daiana Marques Costa

Flávio Henrique Rodrigues

Rio Claro, 27 de novembro de 2025.

Assinatura do(a) aluno(a)

assinatura do(a) orientador(a)

À minha mãe, que me ensinou o verdadeiro significado de ser uma mulher forte e batalhadora. Ao meu pai, meu melhor amigo e conselheiro, cuja presença sempre me guiou com amor e sabedoria. Ao meu irmão, que me mostrou o que é o amor puro, aquele que se expressa mesmo no silêncio.

A todos que me amaram e acreditaram em mim durante a caminhada. Se hoje não tenho medo de ser quem sou, é porque primeiro, eu fui amada em voz alta.

Aos familiares e amigos que compreenderam minhas ausências e, ainda assim, permaneceram por perto, oferecendo apoio e carinho. Tudo o que há de melhor em mim carrega um pouco do amor de vocês.

AGRADECIMENTOS

Agradeço, primeiramente, à Universidade Estadual Paulista (Unesp), pelo ambiente de aprendizado, crescimento e descobertas que tornou possível a realização deste trabalho.

À minha orientadora, Prof. Dra. Lucilia do Carmo Giordano, pela paciência, pelos ensinamentos e por acreditar em meu potencial. Seu apoio e confiança foram fundamentais para que este estudo ganhasse forma. Ao Laboratório de Sensibilidade ao Óleo (LabSAO), por ter me acolhido e apresentado à área de estudo que hoje ocupa um lugar de grande carinho em minha trajetória acadêmica.

Ao Prof. Dr. Danilo Marques Magalhães, orientador de pesquisas, congressos e extensão, cuja generosidade e simpatia inabalável tornaram o aprendizado em SIG uma experiência leve e inspiradora.

Aos amigos e colegas do Meca Cereja, por tornarem a caminhada universitária mais leve e divertida. Em especial, ao grupo Rivotrio (Vitória Lima e Pedro Secco), meus companheiros mais próximos na universidade, que me mantiveram firme e me lembraram, nos dias difíceis, que a amizade também é uma forma de resistência. Vocês me fizeram ficar mesmo quando o cansaço me pedia desistência.

À Ana Carolina, carinhosamente apelidada de pirulito, por ser abrigo desde a minha chegada em Rio Claro. Dividir o mesmo teto com você foi um privilégio, e a existência da finada República Sinta Liga guardará para sempre a certeza de que alguns lares não têm endereço, têm alma.

A tantos amigos que foram como presentes durante essa caminhada: Lucas Candiani, Felipe Felício, Sophia Zambello, Ana Paula Paulucci e tantos outros que compartilharam anos de felicidade e exaustão ao meu lado.

Às minhas amigas Flávia Frazão e Maria Luiza, que, mesmo distantes, sempre foram meu porto seguro, onde pude voltar, chorar e sorrir sem precisar explicar.

Agradeço também e sobretudo, à minha família, base de tudo o que sou. Aos meus pais, pelo amor incondicional e pela força que sempre me sustentou. À minha avó Maria Lúcia, que aprendeu a escrever junto comigo apenas para caminhar ao meu lado nas primeiras letras da vida. E ao meu avô Felício, por cada doce que transformava tristeza em consolo e carinho em

abrigo. À minha madrinha Vânia, pelas orações e por sua presença constante; aos meus tios André e Juliano, e aos meus primos, pelos momentos compartilhados e pela alegria que tornaram a jornada mais leve.

Aos meus sogros, que me acolheram com carinho e afeto, e ao meu namorado, companheiro de tantos anos de graduação e, agora, de vida. Seu amor e serenidade foram fundamentais, assim como sua presença silenciosa e constante nos dias e noites de escrita desta monografia.

A todos que, de alguma forma, fizeram parte desta trajetória, deixo meu mais sincero e eterno agradecimento.

“... refletir sobre o mito da sustentabilidade, inventado pelas corporações para justificar o assalto que fazem à nossa ideia de natureza. Fomos, durante muito tempo, embalados com a história de que somos a humanidade. Enquanto isso - enquanto seu lobo não vem -, fomos nos alienando desse organismo de que somos parte, a Terra, e passamos a pensar que ele é uma coisa e nós, outra: a Terra e a humanidade. Eu não percebo onde tem alguma coisa que não seja natureza. Tudo é natureza. O cosmos é natureza. Tudo em que eu consigo pensar é natureza.”

-Ailton Krenak (2019, p. 16)

RESUMO

O trabalho apresentado teve como foco principal o mapeamento dos manguezais na Baixada Santista (SP) e a avaliação da eficácia do algoritmo Support Vector Machine (SVM) usando imagens multiespectrais do satélite Sentinel-2. A região é marcada por um ecossistema costeiro importante, porém vulnerável à pressão urbana, industrial e portuária. Para identificar as configurações que garantem maior precisão, o estudo comparou o comportamento do classificador SVM diante de diferentes parametrizações, testadas a partir de quatro segmentações orientadas a objeto (GEOBIA), elaboradas com distintas combinações das bandas espectrais do Sentinel-2. A metodologia consistiu no pré-processamento das imagens, definição de classes espectrais, coleta de amostras para treinamento do classificador e validação dos resultados por meio da matriz de confusão. Os resultados mostraram que as composições que incorporam bandas do infravermelho e da borda vermelha apresentaram melhor desempenho na diferenciação entre vegetação de mangue e outras coberturas do solo. As análises indicaram boa coerência espacial e consistência nos padrões ambientais mapeados, demonstrando o potencial do SVM aliado a dados do Sentinel-2 para representar de forma detalhada ambientes costeiros complexos.

Palavras-chave: Manguezal; Support Vector Machine; Sensoriamento Remoto; Sentinel-2; Baixada Santista.

ABSTRACT

This study focuses on mapping mangrove ecosystems in the Baixada Santista region (São Paulo, Brazil) and evaluating the effectiveness of the Support Vector Machine (SVM) algorithm using multispectral imagery from the Sentinel-2 satellite. The study area represents an ecologically relevant coastal environment that remains vulnerable to urban, industrial, and port-related pressures. To identify the parameter configurations that yield higher classification accuracy, the research compared the performance of SVM under different settings, tested across four object-oriented segmentations (GEOBIA) generated with distinct combinations of Sentinel-2 spectral bands. The methodological workflow included image preprocessing, definition of spectral classes, collection of training samples, and accuracy assessment using a confusion matrix. The results indicate that compositions incorporating infrared and red-edge bands achieved superior performance in distinguishing mangrove vegetation from other land-cover types. The analyses also revealed strong spatial coherence and consistent environmental patterns, demonstrating the potential of SVM combined with Sentinel-2 data to provide detailed representations of complex coastal environments.

Keywords: Mangrove; Support Vector Machine; Remote Sensing; Sentinel-2; Baixada Santista.

Title: Spatial Analysis of Mangrove Distribution in the Baixada Santista (SP) Using Machine Learning Algorithms.

LISTA DE FIGURAS

Figura 1- Estrutura geral do algoritmo máquina de vetor de suporte (Support Vector Machine)	21
Figura 2 – Localização da Baixada Santista (SP).....	23
Figura 3 – Localização da área de estudo na Baixada Santista (SP).....	24
Figura 4 – Perfil esquemático dos depósitos sedimentares da planície costeira da Baixada Santista	25
Figura 5- Área de manguezais localizada na área de estudo	26
Figura 6- Duplicação da área do porto de Santos	26
Figura 7 – Perfil espectral de classes previamente definidas por meio de gráfico de linhas....	35
Figura 8 – Perfil espectral de classes previamente definidas por meio de gráfico de box-plot.....	35
Figura 9- Segmentação R3G2B1 (RGB Natural).....	38
Figura 10- Classificação SVM R3G2B1 (RGB Natural)	39
Figura 11- Erro SVM R3G2B1 (RGB Natural)	40
Figura 12- Segmentação R10G9B1	41
Figura 13- Classificação SVM R10G9B1	42
Figura 14- Erro SVM R10G9B1	43
Figura 15- Segmentação R9G4B3	44
Figura 16- Classific SVM R9G4B3	45
Figura 17- Segmentação R4G5B8.....	46
Figura 18- Classificação R4G5B8.....	47
Figura 19- Identificação de classes de ecossistemas de manguezais por classificação (%).....	48
Figura 20- Desempenho geral por classificação.....	49
Figura 21- Estabilidade estatística entre classes por segmentação/classificação	51

SUMÁRIO

1 INTRODUÇÃO	10
2 OBJETIVOS	13
3 REFERENCIAL TEÓRICO	14
3.1 Caracterização dos manguezais	14
3.2 Ameaças, pressões e serviços ecossistêmicos	15
3.3 Monitoramento e sensoriamento remoto	17
3.4 Classificação por aprendizado de máquina e avaliação de acurácia	19
4 MATERIAIS E MÉTODOS	23
4.1 Área de estudo	23
4.2 Obtenção e pré-processamento dos dados	27
4.3 Definição de classes e análise espectral preliminar	29
4.4 Segmentação orientada a objeto	31
4.4.1 Funcionamento do algoritmo e limitações no <i>Segment Mean Shift</i>	32
4.5 Classificação por Support Vector Machine (SVM).....	33
4.6 Análise estatística	34
5 RESULTADOS E DISCUSSÃO	35
6 CONSIDERAÇÕES FINAIS.....	52
7 REFERÊNCIAS	54

1 INTRODUÇÃO

Os manguezais têm um papel essencial na conservação da biodiversidade nas zonas costeiras tropicais em todos os níveis de escala, sejam regionais ou globais. Entre as várias funções desses ecossistemas estão principalmente a proteção contra a erosão, o sequestro de carbono e a manutenção da biodiversidade. Isso faz com que sejam considerados áreas de grande importância ecológica, já que abrigam processos biológicos e geoquímicos intensos e fundamentais para todo o globo terrestre (Costa, 2023).

Além da importância ambiental, os manguezais também são extremamente relevantes do ponto de vista social. Muitas comunidades ribeirinhas dependem diretamente dos recursos naturais oferecidos por esses ambientes (como pescadores e marisqueiros) que têm nesses ecossistemas uma fonte essencial de sustento e renda. Os benefícios não se limitam à pesca, embora esse seja um dos principais aspectos econômicos associados aos manguezais (Ferraz, 2017). Esses ambientes também exercem influência sobre a dinâmica física do litoral e mantêm relações com ecossistemas vizinhos, reforçando ainda mais sua importância (Albuquerque; Do Nascimento Farias; Maia, 2015; Da Silva *et al.*, 2016; Carvalho *et al.*, 2016; Souza *et al.*, 2018).

Presentes em regiões tropicais e subtropicais, os manguezais abrigam espécies vegetais que se adaptaram às condições salinas, como o mangue-vermelho (*Rhizophora mangle* L.) e a siriúba (*Avicennia schaueriana* Stapf ; Leechn. ex Moldenke). Eles também funcionam como berçários para muitas espécies da fauna marinha (Correia; Sovierzoski, 2005; Souza *et al.*, 2018). No Brasil, estão distribuídos ao longo de praticamente toda a costa atlântica, do Amapá até Santa Catarina. A Baixada Santista, em São Paulo, é uma dessas áreas e uma das mais pressionadas pela urbanização acelerada, pela poluição e pelas atividades industriais/portuárias (Diegues, 2008; Nanni; Segnini, 2005).

De acordo com Cheliz e Oliveira (2020), a Baixada Santista representa um caso emblemático dos conflitos ambientais resultantes da mundialização e da intensificação dos fluxos econômicos globais. Inserida em uma região metropolitana que concentra cerca de dois milhões de habitantes sobre uma área fisicamente frágil e limitada, a Baixada se destaca pela sobreposição de interesses locais e externos, evidenciando a dificuldade de políticas municipais e regionais em lidar com processos e agentes de magnitude global. O avanço de grandes projetos industriais, portuários e, mais recentemente, petrolíferos, tem ampliado a dualidade entre a importância nacional dessa área estratégica e as necessidades de sua população local. Essa

dinâmica complexa reforça as vulnerabilidades físicas e sociais da região e aprofunda os riscos e impactos ambientais sobre ecossistemas sensíveis, como os manguezais.

Santos, São Vicente e Cubatão (municípios centrais da Baixada) abrigam um dos maiores complexos portuários e industriais do país, cuja presença tem gerado impactos ambientais expressivos. A poluição atmosférica e hídrica, o desmatamento de manguezais e a ocupação irregular em áreas alagáveis compõem um cenário de degradação que, embora parcialmente mitigado nas últimas décadas, ainda persiste como desafio ambiental (Medeiros *et al.*, 2019; Cheliz; Oliveira, 2020).

Nesse contexto, o monitoramento dos manguezais torna-se fundamental para subsidiar ações de gestão ambiental e de ordenamento territorial. Contudo, para regiões altamente antropizadas como a Baixada Santista, ainda se observa limitação na disponibilidade de mapeamentos recentes, detalhados e metodologicamente robustos. A heterogeneidade da paisagem costeira, marcada pela presença simultânea de mangues, marismas, vegetação arbórea, áreas úmidas interiores e extensos usos antrópicos, dificulta a aplicação de técnicas convencionais de classificação, que por vezes não capturam adequadamente nuances espectrais e estruturais desses ambientes. Essa dificuldade configura explicitamente o problema de pesquisa, pois evidencia a necessidade de aprimorar metodologias de discriminação entre ecossistemas costeiros em ambientes de elevada complexidade ambiental.

A lacuna científica reside, portanto, na ausência de estudos que avaliem de forma sistemática o desempenho de algoritmos de aprendizado de máquina, como o *Support Vector Machine*, aplicados a diferentes segmentações derivadas de composições espectrais do Sentinel-2 na Baixada Santista. Embora classificadores supervisionados tenham se mostrado eficientes em ambientes complexos (Mountrakis *et al.*, 2011), ainda são escassos os trabalhos que exploram comparações entre configurações espectrais segmentadas, sobretudo combinando técnicas de classificação com metodologias orientadas a objeto, como a abordagem GEOBIA, reconhecida por representar unidades espaciais completas e reduzir ruídos de classificação (Blaschke, 2010).

A escolha metodológica pelo sensoriamento remoto e por algoritmos de machine learning é amplamente justificada pela capacidade dessas ferramentas de superar limitações observadas em métodos tradicionais de mapeamento. As imagens multiespectrais do Sentinel-2 permitem analisar estruturas biofísicas relevantes, como a umidade do solo, o vigor vegetativo

e a densidade das copas, graças às bandas específicas no Red Edge e no SWIR, que são extremamente úteis para diferenciar ambientes inundáveis e vegetação costeira (Da Silva Júnior; Da Penha Pacheco, 2023). O uso do SVM, por sua vez, destaca-se pela precisão em separar classes espectralmente semelhantes, mesmo com conjuntos de treinamento relativamente reduzidos (Mountrakis et al., 2011). A integração dessas técnicas com segmentações orientadas a objeto potencializa a coerência espacial dos resultados e aprimora a representação da paisagem em regiões altamente heterogêneas.

Diante desse cenário, o presente trabalho tem como objetivo mapear a distribuição dos manguezais na Baixada Santista utilizando imagens Sentinel-2 combinadas com o classificador SVM a partir de diferentes imagens segmentadas. A proposta é produzir informações acuradas que contribuam para o monitoramento contínuo desses ambientes e que possam subsidiar políticas públicas voltadas à conservação e ao uso sustentável dos ecossistemas costeiros. A metodologia integra pré-processamento das imagens, aplicações de segmentações com diferentes combinações espectrais, coleta de amostras para treinamento, classificação supervisionada e validação estatística dos resultados por meio da matriz de confusão, acurácia global e índice Kappa, conforme Cohen (1960), assegurando maior rigor às análises.

2 OBJETIVOS

Este trabalho tem como principal objetivo avaliar a eficácia do algoritmo *Support Vector Machine* (SVM) no mapeamento de áreas de manguezal na Baixada Santista (SP), utilizando imagens multiespectrais do satélite Sentinel-2. Além disso, o estudo busca compreender o comportamento do classificador diante de diferentes parametrizações, testadas a partir de quatro segmentações elaboradas com distintas combinações das doze bandas espectrais disponíveis, a fim de identificar quais configurações permitem maior precisão na detecção e delimitação dos manguezais.

3 REFERENCIAL TEÓRICO

3.1 Caracterização dos manguezais

Os manguezais são ecossistemas costeiros tropicais e desempenham um papel vital na proteção das zonas costeiras e na manutenção da biodiversidade. O termo "mangue" foi aplicado em meados do século XVI, quando os navegadores portugueses, como o padre Gaspar Afonso, já mencionavam esses ambientes em suas cartas, associando o local como habitats de animais como caranguejos e peixe-boi (ICMBio, 2018). Os manguezais são ecossistemas localizados em terrenos de transição entre terra e mar, principalmente em fozes de rios e estuários. São caracterizados por solos inundados pelas marés e sujeitos a variações de salinidade (Schaeffer-Novelli, 1995). A vegetação é composta por espécies halófitas, como o mangue-vermelho (*Rhizophora mangle*), com raízes-escora adaptadas a solos pouco compactos; a siriúba (*Avicenia schaueriana*), que possui pneumatóforos para respiração; e o mangue-branco (*Laguncularia racemosa*), adaptado às áreas alcançadas pelas marés altas. Outros vegetais incluem o mangue-de-botão (*Conocarpus sp.*) e outras espécies menos frequentes (Correia; Sovierzoski, 2005).

O substrato dos manguezais é rico em silte, argila e matéria orgânica em decomposição, resultando em baixos níveis de oxigênio. Esses ecossistemas são encontrados em regiões tropicais e subtropicais, com maior desenvolvimento próximo ao Equador. No Brasil, estendem-se do Amapá, onde há grandes áreas contínuas, até Santa Catarina, onde a vegetação é de menor porte (Correia; Sovierzoski, 2005). Na região Sudeste do Brasil, os manguezais estão presentes principalmente ao longo da costa dos estados do Rio de Janeiro, São Paulo e Espírito Santo, com destaque para áreas como a Baixada Santista, o litoral norte paulista, a Baía de Guanabara e a Baía de Sepetiba (Cunha-lignon, 2001).

As condições ideais incluem temperaturas médias anuais acima de 20°C, chuvas superiores a 1.500 mm/ano e influência de marés que garantem variação de salinidade, transporte de nutrientes e dispersão de espécies. A salinidade da água é um fator predominante na formação e distribuição dos manguezais (Fruehauf, 2005). Esses ecossistemas se estabelecem em zonas de transição entre águas doces e salgadas, onde as espécies vegetais apresentam adaptações fisiológicas para sobreviver em ambientes salinos. Por exemplo, o mangue-vermelho possui mecanismos que excretam o sal acumulado pelas folhas, enquanto a siriúba apresenta maior eficiência na absorção de água salina sem prejuízo para seu metabolismo (Correia; Sovierzoski, 2005; Souza *et al.*, 2018).

O regime de marés também é crucial para a distribuição dos manguezais. Eles se desenvolvem em regiões onde as variações de nível do mar expõem o solo periodicamente. Esse ciclo contribui para a distribuição de nutrientes, a aeração do solo e a dispersão dos propágulos e sementes que flutuam com a correnteza até se estabelecerem em locais adequados (Vannucci, 2003). Além disso, os manguezais prosperam em áreas de baixa energia, onde ocorre a sedimentação de argilas e siltes ricos em matéria orgânica, formando um substrato propício para o crescimento das plantas. A deposição de sedimentos favorece a estabilidade do solo, permitindo o desenvolvimento de estruturas adaptadas ao ambiente anóxico, como os pneumatóforos (Ellis *et al.*, 2004).

Ecologicamente, os manguezais são essenciais para a ciclagem de nutrientes, funcionam como refúgio, alimentação e área de reprodução para diversas espécies marinhas, estuarinas e dulcícolas. Esses ecossistemas desempenham papel fundamental no equilíbrio da cadeia alimentar costeira (Correia; Sovierzoski, 2005). Além disso, os manguezais são altamente eficientes como sequestradores de carbono, armazenando níveis superiores aos de muitos outros biomas. Com taxas de sequestro entre 1,3 e 2,0 Mg C ha⁻¹ ano⁻¹, o carbono é armazenado por longos períodos nos sedimentos, proveniente tanto da produção local quanto de fontes externas (Cuenca-oay, 2019). Suas raízes densas dissipam a energia das ondas, protegendo zonas costeiras contra tempestades e maremotos, enquanto promovem o acúmulo de sedimentos ricos em carbono (Weaver; Stehno, 2024).

3.2 Ameaças, pressões e serviços ecossistêmicos

O valor econômico dos manguezais é frequentemente subestimado, apesar de sua importância para diversas comunidades e países. Antes de abordar seus benefícios diretos, é fundamental compreender que esses ambientes fornecem serviços ecossistêmicos, entendidos como os benefícios que os seres humanos obtêm dos ecossistemas naturais, englobando funções ecológicas, recursos materiais, regulação ambiental e benefícios culturais e sociais (MEA, 2005).

No âmbito ecológico, os serviços ecossistêmicos dos manguezais compreendem processos que sustentam o funcionamento e a estabilidade dos ecossistemas costeiros. Isso inclui a manutenção dos ciclos biogeoquímicos, a proteção natural das zonas costeiras, a sustentação de cadeias alimentares e o favorecimento da biodiversidade. Esses processos garantem a integridade ecológica da região, influenciando diretamente a produtividade dos ambientes marinhos e estuarinos (Kumar, 2012).

Do ponto de vista socioeconômico, os serviços ecossistêmicos incluem benefícios que se refletem na qualidade de vida e na segurança das populações humanas. Envolvem o fornecimento de recursos naturais explorados de forma sustentável, a oferta de alimentos essenciais para comunidades tradicionais, a proteção contra eventos extremos, a mitigação de impactos climáticos e a geração de oportunidades culturais, educacionais e econômicas (Costanza, 1997). Dessa forma, esses serviços possuem papel estratégico para a estabilidade social e para o desenvolvimento regional, conforme sintetizado no quadro 1.

Quadro 1- Serviços ecológicos e econômicos prestados pelo ecossistema

SERVIÇOS ECOLÓGICOS	SERVIÇOS SOCIOECONÔMICOS
“Berçário” da vida marinha (alimento + abrigo + elevada temperatura)	Fornecimento de proteína de origem animal
Manutenção da biodiversidade e dos recursos genéticos	Produtos alimentícios elaborados com recursos da vegetação
Armazenamento e reciclagem da matéria orgânica	Fornecimento de madeira
Exportação de matéria orgânica e nutrientes	Sustento às comunidades costeiras
Regulação biológica dos processos ecossistêmicos	Proteção da linha de costa contra inundações, furacões e maremotos
Manutenção da resiliência biológica	Controle da erosão costeira e ribeirinha
Produção de oxigênio	Biofiltração (matriz biológica para a absorção de poluentes)
Captação de água e recarga de aquíferos	Absorção de dióxido de carbono, diminuindo o efeito estufa
Formação de camada superficial do solo + manutenção da fertilidade	Medicina tradicional-local (poucos estudos)
Influência sobre o clima local, regional e global	Valores patrimoniais, culturais, espirituais e religiosos envolvidos
Suporte biofísico a outros ecossistemas costeiros	Informações educacionais e científicas
	Recreação e turismo

Fonte: Modificado de Souza *et al* (2018)

Esses serviços ecossistêmicos ajudam a reduzir custos com infraestrutura de defesa costeira e recuperação de desastres, proporcionando uma economia significativa para governos e comunidades. Outros produtos naturais extraídos dos manguezais incluem taninos, utilizados na indústria de curtimento de couro, resistência de utensílios de barro e conservação de redes de pesca. A madeira é utilizada na construção de barcos, casas e estacas, enquanto frutos e sementes podem servir de base para alimentos e bebidas, como mel e chás medicinais (Souza *et al.*, 2018).

Apesar de sua importância, os manguezais enfrentam diversas ameaças que comprometem sua conservação e permanência. O desmatamento é uma das principais, causado pela exploração ilegal de madeira e pela conversão de áreas de mangue para atividades agropecuárias. Isso resulta em impactos negativos no equilíbrio ecológico local, uma vez que os manguezais são cruciais para a regulação do clima e a proteção costeira (Nagelkerken *et al.*, 2008). A urbanização descontrolada também contribui para a destruição dos manguezais, com a construção de portos, rodovias, empreendimentos imobiliários e a ocupação irregular de baixa renda, que representa a maior parte do impacto, afetando o regime de marés e aumentando a poluição das águas (Paiva, 2007).

A poluição das águas costeiras, frequentemente associada ao lançamento de esgoto doméstico, resíduos industriais e acúmulo de plásticos, constitui uma ameaça significativa à integridade dos ecossistemas costeiros, como os manguezais. A entrada excessiva de nutrientes nessas áreas pode desencadear processos de eutrofização, promovendo a redução dos níveis de oxigênio dissolvido na água e impactando diretamente a fauna e a flora locais (Carvalho, 2016). Associado a isso, o acúmulo de resíduos sólidos, como metais pesados e fragmentos plásticos, compromete o equilíbrio ecológico desses ambientes, afetando cadeias tróficas e interações biológicas essenciais (Gonçalves, 2010).

3.3 Monitoramento e sensoriamento remoto

A partir disto, a necessidade de monitoramento contínuo desses ecossistemas se torna evidente, sobretudo diante da crescente pressão antrópica e das mudanças ambientais aceleradas já citadas. No entanto, o acompanhamento de áreas extensas e frequentemente inacessíveis, como os manguezais, impõe desafios consideráveis do ponto de vista logístico e metodológico, principalmente quando se depende exclusivamente de levantamentos de campo (Loveland ; Defries, 2004). Nesse contexto, o sensoriamento remoto (SeRe) tem se consolidado como uma

ferramenta eficiente e acessível para a análise ambiental em larga escala, solucionando problemas como os de monitoramento desses ecossistemas.

A utilização de imagens para análise da superfície terrestre remonta ao início do século XX, quando as primeiras fotografias aéreas passaram a ser produzidas a partir de balões e aeronaves. Embora essas imagens ainda não configurassem o sensoriamento remoto no sentido moderno, elas representaram um marco importante no desenvolvimento de técnicas de observação indireta do território (Rabchevsky, 1970). Durante a Primeira Guerra Mundial, houve um avanço expressivo no uso estratégico dessas fotografias para fins de reconhecimento militar, o que impulsionou o aprimoramento de tecnologias ópticas e métodos de captação sistemática (Florenzano, 2002). Foi somente nas décadas seguintes, com o advento dos sensores eletromagnéticos e o lançamento de satélites artificiais, que o sensoriamento remoto passou a se consolidar como uma disciplina científica própria, voltada à aquisição e interpretação de dados da superfície terrestre por meio de sensores embarcados em plataformas orbitais e suborbitais (Fu *et al.*, 2020).

O sensoriamento remoto permite a aquisição de informações sobre a superfície terrestre sem a necessidade de contato físico direto, o que o torna essencial para o monitoramento ambiental em áreas de difícil acesso. Sua capacidade de oferecer dados em diferentes escalas espaciais, espectrais e temporais torna essa tecnologia uma ferramenta robusta para análises ecológicas complexas (Fitz, 2018). O avanço paralelo dos Sistemas de Informação Geográfica (SIG) também contribuiu significativamente para a integração, interpretação e modelagem de dados ambientais, ampliando as possibilidades de análise (Leite, 2013).

A base do sensoriamento remoto reside nos sensores responsáveis por coletar as informações espectrais da superfície terrestre. Esses sensores são classificados em dois tipos principais: sensores passivos, que captam a radiação solar refletida pela superfície, e sensores ativos, que emitem seu próprio sinal e registram a energia refletida de volta ao sensor, como ocorre nos sistemas de radar (Lira, 2016). No conjunto dos sensores passivos, temos o satélite Sentinel-2, pertencente ao programa europeu Copernicus e gerenciado pela Agência Espacial Europeia (ESA). Esse satélite tem sido amplamente empregado no monitoramento de ambientes naturais, incluindo os ecossistemas costeiros e, especificamente, os manguezais (Jutz *et al.*, 2020).

O Sentinel-2 possui sensores multiespectrais com resolução espacial de até 10 metros, cobrindo 13 bandas espectrais e apresentando uma frequência de revisita de cinco dias. Tais características conferem alta capacidade de detecção e acompanhamento de mudanças em áreas dinâmicas, como zonas estuarinas e litorâneas (Drusch, 2012). A captação em múltiplas faixas

do espectro eletromagnético permite analisar parâmetros biofísicos relevantes, como o vigor da vegetação, a umidade do solo e a dinâmica de inundações, sendo, portanto, uma fonte valiosa de dados para estudos de sensibilidade ambiental (Veiga, 2023; Main-Knorn *et al.*, 2017).

O processamento digital das imagens obtidas por sensores orbitais é etapa fundamental para garantir a precisão e a confiabilidade das análises quantitativas. Essa etapa envolve procedimentos de correção e calibração que visam minimizar os efeitos de distorções atmosféricas, geométricas e topográficas, comuns em dados brutos (Baxes, 1994). As correções radiométricas, por exemplo, são empregadas para ajustar os valores de reflectância observados, levando em conta o espalhamento da radiação, sobretudo nos comprimentos de onda mais curtos, como o azul, fenômeno descrito por Rayleigh (1871).

As correções geométricas, por sua vez, utilizam informações orbitais, efemérides e Modelos Digitais de Elevação (MDE) para corrigir a geometria das imagens, ajustando-as à topografia do terreno e à posição do satélite no momento da aquisição. Tais correções garantem o alinhamento espacial entre diferentes imagens e sua compatibilidade com sistemas de referência geográfica, como o SIRGAS 2000 ou o WGS-84 (Dave *et al.*, 2015).

Além das correções fundamentais, técnicas de fusão de imagens como IHS (*Intensity-Hue-Saturation*) e *pan-sharpening* têm sido empregadas para aprimorar o nível de detalhamento visual, preservando a integridade espectral dos dados. Essas abordagens são especialmente úteis em análises locais, nas quais o reconhecimento de feições específicas exige refinamento espacial elevado (Sankaliya, 2015; Pushparaj; Hegde, 2017).

3.4 Classificação por aprendizado de máquina e avaliação de acurácia

Recentemente, os algoritmos de aprendizado de máquina (*Machine Learning*) têm se destacado no contexto da classificação de uso e cobertura do solo, especialmente em ambientes com elevada complexidade estrutural (Ambarwari; Husni, 2023). Tais técnicas apresentam elevada eficiência na detecção de padrões espectrais e estruturais, contribuindo para a produção de mapas temáticos com altos índices de acurácia (Chollet, 2021).

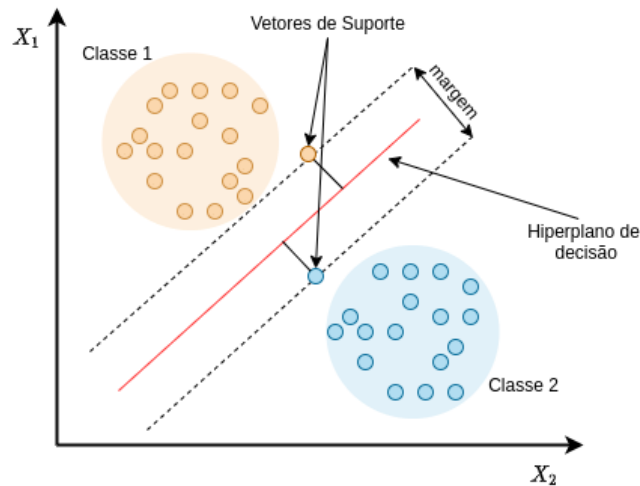
Entre os algoritmos mais empregados, destaca-se o *Support Vector Machine* (SVM), que atua transformando os dados de entrada em um espaço multidimensional, permitindo a separação não linear entre diferentes classes espectrais. O algoritmo busca identificar um hiperplano de decisão que maximize a separação entre as classes, promovendo uma classificação robusta e precisa (Davis, 2014).

Do ponto de vista matemático, o SVM busca determinar o hiperplano ótimo que melhor separa duas classes no espaço de características. Esse hiperplano é definido pela equação $w \cdot x + b = 0$, onde w é o vetor normal e b é o viés (Cortes; Vapnik, 1995). O objetivo do algoritmo é maximizar a margem, que corresponde à distância entre os hiperplanos $w \cdot x + b = +1$ e $w \cdot x + b = -1$; essa maximização torna a classificação mais robusta. A solução envolve resolver um problema de otimização convexa que minimiza $\frac{1}{2} \|w\|^2$, sujeito às restrições de classificação correta das amostras. As amostras que se encontram exatamente sobre as margens são chamados vetores de suporte e são as únicas que influenciam a posição do hiperplano ótimo (Vapnik, 1995). Para lidar com problemas não linearmente separáveis, o SVM utiliza funções Kernel, como o polinomial e o RBF, que calculam o produto interno entre as amostras em um espaço de maior dimensionalidade sem a necessidade de realizar explicitamente a transformação $\phi(x)$. Esse procedimento, conhecido como *truque do Kernel*, permite que o algoritmo encontre separações não lineares com baixo custo computacional (Schölkopf; Smola, 2002).

Os vetores de suporte são as amostras que satisfazem essa condição de igualdade, sendo essenciais para determinar a orientação e a posição do hiperplano ótimo. Em problemas não linearmente separáveis, o SVM utiliza funções Kernel para projetar os dados em um espaço de maior dimensionalidade, onde a separação se torna possível. O Kernel é uma função que permite transformar os dados de entrada para um espaço de maior dimensionalidade, viabilizando a separação não linear entre classes. Assim, o SVM pode construir um hiperplano ótimo mesmo quando as classes não são separáveis no espaço original (Cortes; Vapnik, 1995; Schölkopf; Smola, 2002).

Os vetores de suporte (*Support Vectors*), conforme ilustrado na Figura 1, correspondem às amostras localizadas mais próximas ao hiperplano e são responsáveis por delimitar as margens que separam as classes. Quanto maior a distância entre essas margens, mais confiável tende a ser a classificação resultante.

Figura 1 - Estrutura geral do algoritmo máquina de vetor de suporte (Support Vector Machine)



Fonte: Barbosa *et al.*, 2021.

O algoritmo *Support Vector Machine* (SVM) é uma técnica de classificação supervisionada fundamentada no princípio da minimização do risco estrutural, o que permite otimizar de forma eficaz a taxa de erro durante o processo de aprendizagem (Chang *et al.*, 2020).

Uma de suas principais vantagens consiste na alta performance mesmo quando aplicadas bases de dados com número limitado de amostras. Devido a essa característica, o SVM tem sido amplamente empregado em diferentes contextos, destacando-se em aplicações voltadas à previsão de desastres naturais (como deslizamentos e inundações) e no monitoramento de ecossistemas ambientalmente sensíveis (Pourghasemi, 2013; Dias *et al.*, 2014).

A fim de assegurar a confiabilidade dos resultados obtidos nas classificações supervisionadas de imagens, é imprescindível a utilização de métricas que possibilitem uma avaliação abrangente do desempenho dos algoritmos empregados. Dentre os indicadores mais utilizados destacam-se a acurácia global, a matriz de confusão e o índice Kappa, cada um oferecendo diferentes perspectivas sobre a qualidade da classificação (Congalton, 1991).

A acurácia global expressa a proporção de acertos em relação ao total de amostras avaliadas, fornecendo uma medida geral de desempenho. No entanto, essa métrica pode apresentar limitações em cenários com distribuição desbalanceada entre as classes, uma vez que tende a superestimar a qualidade da classificação ao privilegiar classes majoritárias (Shao *et al.*, 2019). Para contornar essa limitação, a matriz de confusão é frequentemente utilizada de forma complementar, pois permite a visualização detalhada dos acertos e erros em cada

categoria, evidenciando possíveis padrões de confusão entre classes com características espectrais ou estruturais semelhantes (Haghighi *et al.*, 2018).

O índice Kappa constitui uma métrica mais robusta, pois incorpora a possibilidade de acertos por acaso na avaliação da concordância entre os dados classificados e os dados de referência. Isso o torna particularmente adequado em situações com distribuição desigual das amostras entre as classes, oferecendo uma análise mais criteriosa da fidelidade da classificação (Fatourechí *et al.*, 2008).

Em quesito de análise estatística, também é importante compreender os erros de omissão e comissão, frequentemente utilizados em análise de acurácia de classificações supervisionadas como as do presente estudo. De acordo com Chuvieco (1990), esses erros representam aspectos complementares da avaliação de desempenho de um classificador. O erro de omissão ocorre quando uma classe existente na realidade não é corretamente identificada, sendo, portanto, “omitida” do resultado final. Já o erro de comissão refere-se à atribuição incorreta de uma amostra a uma determinada categoria, quando ela na verdade pertence a outra classe.

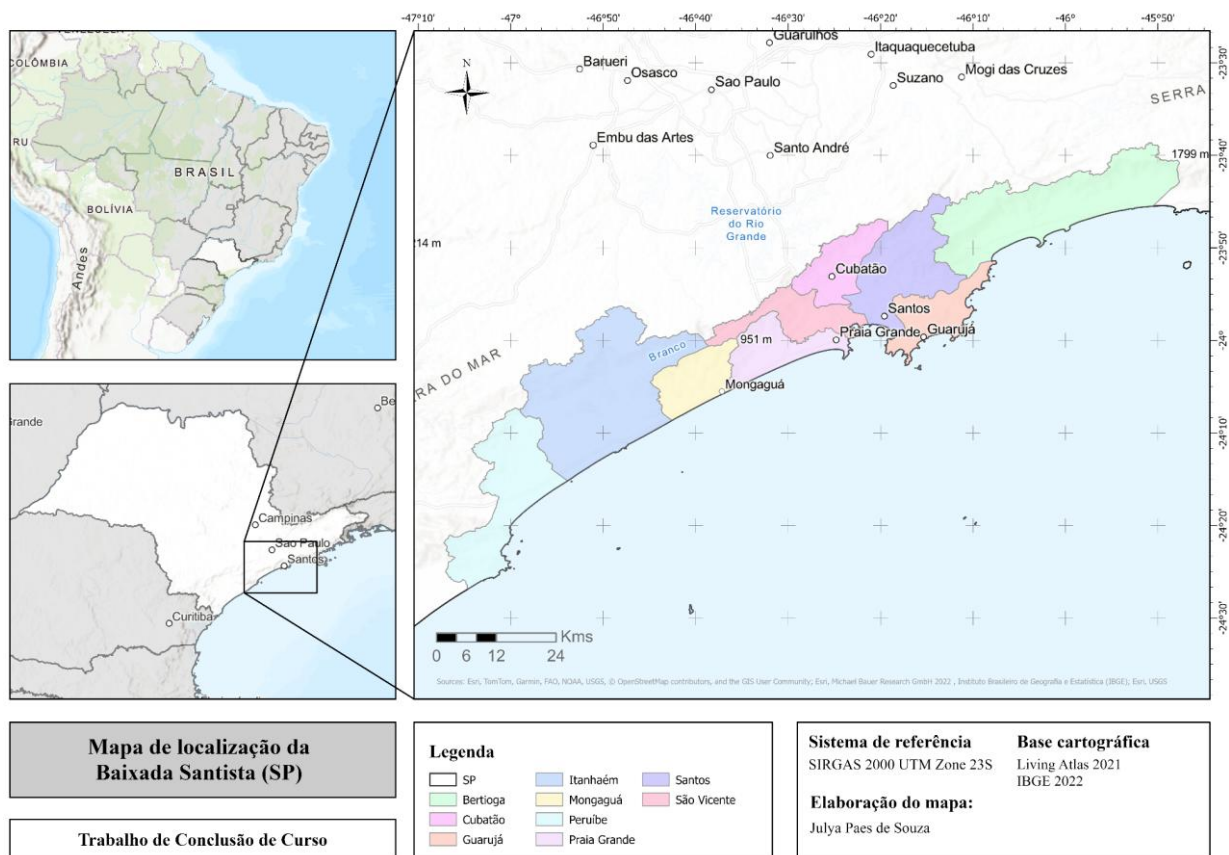
Em termos práticos, o erro de omissão está associado à sub-representação de uma classe, refletindo falhas na sua detecção, enquanto o erro de comissão indica uma super-representação, resultante da inclusão indevida de elementos em uma categoria. Assim, ambos os indicadores são fundamentais para compreender a natureza e a direção dos equívocos cometidos pelo classificador, permitindo uma análise mais detalhada e confiável da qualidade dos resultados obtidos (Chuvieco, 1990).

4 MATERIAIS E MÉTODOS

4.1 Área de estudo

O presente estudo foi conduzido na Região Metropolitana da Baixada Santista, localizada no litoral centro-sul do estado de São Paulo, Brasil (Figura 2). A região é composta por nove municípios: Santos, São Vicente, Guarujá, Praia Grande, Cubatão, Bertioga, Itanhaém, Mongaguá e Peruíbe. Historicamente, o desenvolvimento urbano e econômico da região está intrinsecamente relacionado à sua geografia portuária e às praias oceânicas, fatores determinantes na configuração atual da paisagem e no uso dos recursos naturais (Da Silva; Gomes, 2012).

Figura 2 – Localização da Baixada Santista (SP)

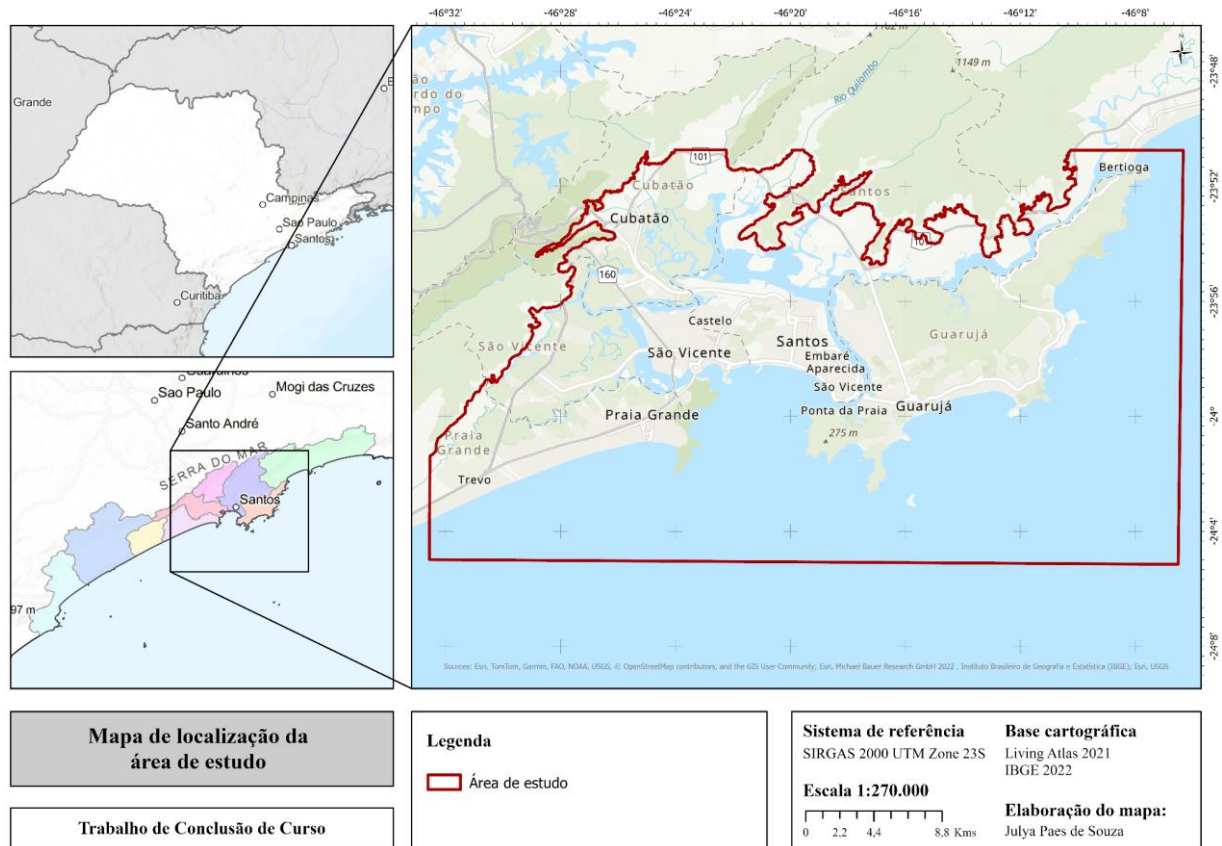


Fonte: Autoria própria, 2025.

Para garantir maior precisão na análise espectral e reduzir ruídos provenientes de áreas irrelevantes para os objetivos do estudo, foi realizado um recorte espacial da cena multiespectral, delimitado pelo polígono vermelho na Figura 3. A seleção do recorte considerou

a curva de nível de cota de 10m, a fim de englobar áreas estuarinas e manguezais e minimizar a inclusão de águas oceânicas abertas, otimizando a extração de informações referentes aos ecossistemas costeiros de interesse.


Figura 3– Localização da área de estudo na Baixada Santista (SP)



Fonte: Autoria própria, 2025.

Geomorfologicamente, a Baixada Santista configura-se como uma planície costeira de baixa altitude, predominantemente plana, com elevações raramente superiores a 10 metros acima do nível do mar (Suguio; Martin, 1978). Esta planície resultou de processos contínuos de sedimentação fluvial e marinha durante o quaternário, culminando no depósito de sedimentos arenosos e argilosos, como ilustrado no perfil esquemático da Figura 4 (Souza *et al.*, 2005).

Figura 4– Perfil esquemático dos depósitos sedimentares da planície costeira da Baixada Santista



Fonte: Modificado de Afonso (2006).

Os solos da região apresentam caráter hidromórfico, com a grande maioria sendo gleissolos e organossolos, de drenagem deficiente e elevada concentração de matéria orgânica, enquanto neossolos quartzarênicos predominam nas áreas de restinga (Oliveira, 1999; Ross ; Fierz, 2007). Tais condições edáficas são determinantes para a ocorrência de extensas zonas úmidas, como os manguezais, que se constituem em componente central da paisagem estuarina (Schaeffer-Novelli *et al.*, 1990).

Climaticamente, a região apresenta clima tropical úmido (Af), sem estação seca definida, segundo a classificação de Köppen-Geiger (Alvares *et al.*, 2013). Dados meteorológicos locais corroboram esta classificação, indicando temperatura média anual superior a 22 °C e precipitação anual frequentemente superior a 2.000 mm, distribuída uniformemente ao longo do ano, com precipitação mínima mensal acima de 60 mm (CETESB, 2018).

Essa combinação de fatores geomorfológicos e climáticos favorece a formação e manutenção de ecossistemas costeiros altamente produtivos. Os manguezais, localizados na interface terrestre-marinhos (Figura 5), são adaptados a variações de salinidade e à influência das marés, sustentando elevada biodiversidade e oferecendo serviços ecossistêmicos essenciais, como proteção costeira, ciclagem de nutrientes e sequestro de carbono, contribuindo para mitigação das mudanças climáticas (Alongi, 2012; Schaeffer-Novelli *et al.*, 1990).

Figura 5 - Área de manguezais localizada na área de estudo



Fonte: Dados internos Cartas SAO, 2019.

Entretanto, a região enfrenta intensas pressões antrópicas decorrentes do Porto de Santos, do polo industrial de Cubatão e da expansão urbana em municípios como Santos e Praia Grande, resultando em supressão de habitats, poluição de solos e águas e fragmentação de ecossistemas (Da Silva; Gomes, 2012). Além disso, recentemente, em 2022, foi aprovado um projeto para duplicar a área do porto local. Essa alteração, certamente, irá influenciar os ecossistemas que as rodeiam (Autoridade Portuária de Santos, 2022; Figura 6). Essas alterações evidenciam a necessidade de monitoramento ambiental contínuo, especialmente em áreas sensíveis como os manguezais.

Figura 6- Duplicação da área do porto de Santos



Fonte: Autoridade Portuária de Santos, 2022.

4.2 Obtenção e pré-processamento dos dados

A análise baseou-se em uma cena multiespectral do satélite Sentinel-2B, adquirida em 5 de maio de 2025, via USGS Explorer, correspondente ao *tile* T23KLP, no formato MSIL1C (.SAFE). Este nível de processamento fornece reflectância no topo da atmosfera (TOA), já ortorretificada e com correção geométrica, garantindo adequação para análise espectral detalhada e classificação supervisionada. A escolha da cena considerou cobertura de nuvens inferior a 5% e alta qualidade radiométrica, condições essenciais para estudo de ecossistemas costeiros heterogêneos.

O Sentinel-2 disponibiliza 13 bandas espectrais com diferentes resoluções espaciais:

- **10 m:** B2 (azul), B3 (verde), B4 (vermelho), B8 (infravermelho próximo, NIR)
- **20 m:** B5, B6, B7 (Red Edge), B8A, B11, B12 (SWIR)
- **60 m:** B1, B9, B10 (correções atmosféricas e detecção de nuvens)

Para uniformização espacial, as bandas de 20 m foram reamostradas para 10 m utilizando o método de interpolação bilinear, apropriado para dados contínuos, de modo a preservar a coerência espectral entre as diferentes resoluções. Posteriormente, todas as bandas foram integradas em um único raster multiespectral, permitindo o processamento e a análise integrada dos dados.

As composições coloridas RGB, bem como combinações envolvendo NIR e Red Edge, foram geradas para otimizar a interpretação da vegetação e identificar variações na estrutura e vigor das comunidades vegetais. Todas as etapas de pré-processamento e integração foram realizadas no software ArcGIS Pro 3.1 (ESRI, 2023).

Após a integração, o raster multiespectral foi organizado segundo uma sequência espectral crescente, abrangendo desde o espectro visível até o infravermelho de ondas curtas (SWIR), de forma a contemplar toda a resposta eletromagnética relevante para a caracterização ambiental. Essa organização permite que cada banda seja associada de forma consistente a canais de cor (R, G ou B) em diferentes composições, evitando confusões durante a segmentação e classificação.

Embora o Sentinel-2B possua originalmente 13 bandas, conforme apresentado, o raster multiespectral utilizado neste estudo considera 10 bandas para as composições, selecionadas conforme sua relevância para análise ambiental:

- Bandas visíveis (B2, B3, B4) para composições RGB naturais e interpretação de vegetação e áreas urbanas;
- Bandas NIR e Red Edge (B5, B6, B7, B8, B8A) para caracterização de vigor vegetativo, densidade foliar e detecção de transições sutis de vegetação;
- Bandas SWIR (B11, B12) para discriminação de solos úmidos, vegetação densa e diferenciação de áreas urbanas.

Bandas como B1 (pancromática) e B9/B10 (correções atmosféricas) não foram incluídas em composições por não contribuírem diretamente para a análise de classificação de coberturas terrestres. O quadro 2 apresenta a estrutura final das bandas utilizadas, indicando tanto a denominação no raster (Band_1 a Band_10) quanto a designação original do sensor Sentinel-2B (B2, B3, etc.), além da respectiva faixa espectral. Essa organização é fundamental para evitar confusões nas etapas subsequentes do processamento, especialmente durante a construção de composições RGB para segmentação, pois garante que as bandas corretas sejam associadas a cada canal de cor (R, G ou B) de forma consistente. O conhecimento prévio da sequência das bandas permite que análises de segmentação e classificação, como o uso do algoritmo SVM, sejam realizadas com maior precisão, pois cada combinação de bandas reflete de forma confiável o comportamento espectral das coberturas ambientais estudadas, evitando erros de interpretação e maximizando a separabilidade entre diferentes classes, como vegetação, solos e superfícies aquáticas.

Quadro 2 – Organização das bandas no raster multiespectral do Sentinel-2B.

BANDA GERADA	DESIGNAÇÃO ORIGINAL (Sentinel-2B)	COMPRIMENTO DE ONDA CENTRAL (nm)	LARGURA DE BANDA (nm)	DESCRIÇÃO
Band_1	B1	442,2	20	Azul profundo (Deep Blue) – Correção atmosférica e detecção de aerossóis
Band_2	B2	492,3	65	Azul (Blue) – Mapeamento de corpos d'água e vegetação aquática
Band_3	B3	558,9	35	Verde (Green) – Análise de vegetação e fitoplâncton
Band_4	B4	664,9	31	Vermelho (Red) – Detecção de vegetação e análise de uso e cobertura
Band_5	B5	703,8	15	Red Edge 1 – Transição entre o vermelho e o NIR (índices de vegetação)
Band_6	B6	739,1	14	Red Edge 2 – Avaliação de estresse da vegetação
Band_7	B7	779,7	20	Red Edge 3 – Análise detalhada da estrutura da vegetação
Band_8	B8	832,9	115	Infravermelho Próximo (NIR – Near Infrared) – Biomassa e vigor da vegetação
Band_8A	B8A	864	20	NIR estreito / Red Edge adicional – Transição adicional entre NIR e SWIR
Band_9	B9	943,2	20	Vapor d'água – Correção atmosférica
Band_10	B10	1376,9	30	Detecção de cirros – Identificação de nuvens finas
Band_11	B11	1610,4	93	Infravermelho de Ondas Curtas 1 (SWIR 1) – Umidade e solo
Band_12	B12	2185,7	181	Infravermelho de Ondas Curtas 2 (SWIR 2) – Mineralogia e diferenciação de solos

Fonte: Autoria própria, 2025.

4.3 Definição de classes e análise espectral preliminar

Com base em estudos prévios desenvolvidos no âmbito das atividades de pesquisa do Laboratório de Sensibilidade ao Óleo (LabSAO/UNESP), envolvendo análises multiespectrais e procedimentos de mapeamento na Bacia de Santos, foram definidas as classes de uso e

cobertura do solo representativas da área de estudo. Embora esses materiais não estejam todos publicados, integram o acervo técnico consolidado pelo grupo de pesquisa e são utilizados de forma sistemática como referência metodológica interna, especialmente na discriminação de ambientes intertidais e vegetação halófitas. A definição das classes também se fundamentou em obras amplamente reconhecidas, como Schaeffer-Novelli (1995), Vannucci (2003), Ellis et al. (2004) e Souza et al. (2018), garantindo consistência ecológica e aderência aos padrões descritos na literatura.

A etapa de obtenção da verdade terrestre (*ground truth*) foi conduzida de modo a assegurar a replicabilidade e a precisão da classificação supervisionada. Inicialmente, foram identificadas e delimitadas, por interpretação visual detalhada, as áreas correspondentes às classes previamente definidas. Para isso, foram utilizadas imagens de alta resolução disponíveis no Google Earth, ortofotos recentes e registros complementares (como registros de campo do grupo LabSAO) que permitiram verificar características espectrais, texturais, morfológicas e contextuais da paisagem. A seleção das feições observáveis seguiu critérios padronizados, de forma a evitar ambiguidades e garantir a reprodutibilidade do procedimento.

As amostras obtidas foram organizadas em dois conjuntos independentes. O primeiro foi destinado exclusivamente ao treinamento do classificador, assegurando que cada classe fosse representada por polígonos distribuídos espacialmente e capazes de capturar a variabilidade espectral interna dos alvos. O segundo conjunto, composto por amostras não sobrepostas às de treinamento, foi reservado para a etapa de validação, permitindo avaliar o desempenho do algoritmo de forma imparcial e metodologicamente robusta. Esse procedimento garante que o estudo possa ser replicado integralmente, tanto em termos da definição das classes quanto da coleta e organização da verdade terrestre.

Para avaliar a separabilidade espectral entre as classes e subsidiar a etapa de classificação supervisionada, foram extraídos perfis espectrais médios a partir de amostras homogêneas selecionadas sobre a imagem pré-processada. O número de amostras por classe foi de aproximadamente dez regiões homogêneas, distribuídas em áreas com diferentes características espectrais e geográficas, evitando-se sua sobreposição com as amostras utilizadas para o treinamento do classificador. Essa estratégia buscou representar de maneira consistente a variabilidade interna de cada classe, respeitando a heterogeneidade observada tanto em campo quanto nas imagens.

A extração foi realizada em regiões reconhecidas e validadas por inspeção visual e por dados consolidados no banco interno do LabSAO, assegurando a coerência entre o comportamento espectral e as feições observadas. A análise foi conduzida por meio de gráficos de linha representando a tendência média de reflectância das classes ao longo das bandas espectrais e por box-plots que evidenciaram a variação interna, a dispersão dos valores e as possíveis sobreposições espectrais. Esses procedimentos permitiram verificar a coerência dos alvos definidos, identificar ambiguidades e ajustar as classes consideradas, com foco em reduzir problemas de ruído e aprimorar a precisão na identificação dos manguezais. Como resultado dessa etapa, foi obtida uma base sólida para a caracterização espectral dos diferentes tipos de cobertura e uso do solo na região costeira, servindo de referência direta para a fase subsequente de classificação supervisionada.

4.4 Segmentação orientada a objeto

A segmentação orientada a objeto (GEOBIA – *Geographic Object-Based Image Analysis*) foi empregada como etapa preliminar para a classificação supervisionada, visando a representação das feições do terreno a partir da análise combinada de homogeneidade espectral, textura e forma dos objetos (Blaschke *et al.*, 2010). Diferentemente das abordagens baseadas em pixels, a GEOBIA agrupa pixels adjacentes com características semelhantes, formando objetos espaciais que correspondem a unidades da paisagem (Benz *et al.*, 2004).

Para o processo de segmentação, foram testadas quatro combinações de bandas espectrais do Sentinel-2B. Em todas as segmentações, foram aplicados os mesmos parâmetros: detalhe espectral de 20 pixels, detalhe espacial de 5 pixels e tamanho mínimo de segmento de 20 pixels, definidos com base em testes exploratórios e referências bibliográficas (Baatz, 2000; Blaschke, 2010; Hayashi, 2023; Resende *et al.*, 2012).

As combinações de bandas utilizadas foram:

- B4 (Vermelho), B5 (Red Edge 1) e B8 (Infravermelho Próximo - NIR): com a premissa de realce de vegetação e análise de vigor das comunidades vegetais;
- R3G2B1 (RGB natural – Vermelho, Verde e Azul): com a premissa da representação visual fiel da paisagem, utilizada como padrão de referência para interpretação da autora;

- B9 (SWIR 1), B4 (Vermelho) e B3 (Verde): com a premissa de destacar de áreas não fotossinteticamente ativas, contraste entre solos expostos e superfícies urbanizadas;
- B10 (SWIR 2), B9 (SWIR 1) e B1 (Azul): com a premissa de gerar cores falsas para análise de vegetação, solos úmidos e diferenciação de classes complexas.

Cada combinação foi submetida ao processo de segmentação de forma independente, mantendo-se os parâmetros para possibilitar comparações entre os diferentes conjuntos de bandas. As segmentações geradas foram posteriormente utilizadas como base para a classificação supervisionada, permitindo avaliar qual configuração de bandas apresentaria melhor adequação para a delimitação de objetos correspondentes às feições do terreno.

4.4.1 Funcionamento do algoritmo e limitações no Segment Mean Shift

Durante a aplicação da segmentação orientada a objeto no ArcGIS Pro, observou-se um comportamento específico da ferramenta *Segment Mean Shift* que pode inicialmente ser interpretado como uma inconsistência, onde, mesmo quando a imagem de entrada possui múltiplas bandas espectrais (como no caso das dez bandas utilizadas neste estudo) o algoritmo processa exclusivamente três bandas por vez. Essa limitação não decorre de falha do software, mas sim da forma como o *Segment Mean Shift* foi projetado e implementado pela Esri.

A ferramenta *Segment Mean Shift*, integrante do conjunto de operações de segmentação e classificação do *Spatial Analyst* e do *Image Analyst* no ArcGIS Pro, processa imagens por meio da identificação de agrupamentos de pixels que apresentam similaridade espectral e espacial. De acordo com a referência técnica disponibilizada pela Esri, a ferramenta aceita qualquer raster compatível com o software e com profundidade de bits válida. Entretanto, a documentação estabelece que o parâmetro denominado Índice de Banda corresponde a uma lista composta por exatamente três bandas, separadas por espaço. Mesmo quando o raster multiespectral contém um número maior de canais, a segmentação é conduzida apenas com base nas três bandas definidas nesse índice.

Na interface gráfica do ArcGIS Pro, esse parâmetro não é exposto ao usuário. O software utiliza automaticamente as três bandas que compõem a visualização ativa em modo RGB no momento da execução da ferramenta. Quando o raster é apresentado ao usuário com uma composição específica, o *Segment Mean Shift* emprega exatamente os canais associados ao vermelho, verde e azul daquela visualização. As demais bandas presentes no raster são

desconsideradas durante a segmentação, independentemente da quantidade de informações espectrais disponíveis.

Esse comportamento não constitui uma falha de execução, mas reflete a estrutura computacional do algoritmo, que foi implementado para operar em um espaço espectral tridimensional. A abordagem reduz a dimensionalidade espectral de forma controlada, o que favorece a estabilidade do processo iterativo de suavização e agrupamento inerente ao método mean shift. Tal restrição evita aumento significativo do custo computacional e garante compatibilidade com diferentes resoluções e profundidades de bit dentro do ambiente *Spatial Analyst*.

A limitação reforça a necessidade de selecionar composições RGB que representem adequadamente as diferenças espectrais entre as classes de interesse. As bandas escolhidas determinam a estrutura dos segmentos e influenciam diretamente o desempenho de etapas posteriores, como o cálculo de atributos de segmento e a classificação supervisionada. Assim, a seleção criteriosa das bandas utilizadas na composição RGB constitui etapa essencial para assegurar que a segmentação reflita as propriedades espectrais relevantes do ambiente analisado.

4.5 Classificação por *Support Vector Machine* (SVM)

A classificação da imagem multiespectral foi realizada utilizando o algoritmo *Support Vector Machine* (SVM), uma técnica de aprendizado de máquina supervisionado amplamente empregada em sensoriamento remoto devido à sua robustez em cenários com alta dimensionalidade e elevada sobreposição espectral entre classes (Andreola, 2019). A classificação considerou as dez bandas do Sentinel-2, previamente reamostradas para resolução espacial uniforme de 10 metros.

Para cada classe de cobertura do solo, foi definido um número mínimo de 50 amostras (quando possível), valor estabelecido de forma a equilibrar a representatividade estatística e a pureza das amostras, evitando a inclusão de pixels mistos bem como a generalização, caso tenha a falta deles. A coleta das amostras seguiu critérios rigorosos de pureza espectral, garantindo que cada pixel representasse exclusivamente a classe de interesse, evitando interferências de sobreposição espectral. O processo de classificação SVM forneceu quatro mapas temáticos raster (uma vez que foram testados quatro tipos de segmentação).

4.6 Análise estatística

A avaliação da acurácia da classificação foi conduzida no software ArcGIS Pro por meio da geração da matriz de confusão. Para isso, utilizaram-se pontos de controle independentes obtidos no banco de dados das Cartas SAO, que serviram como referência para a validação dos resultados nas áreas de mangues, marismas e outras áreas alagadas.

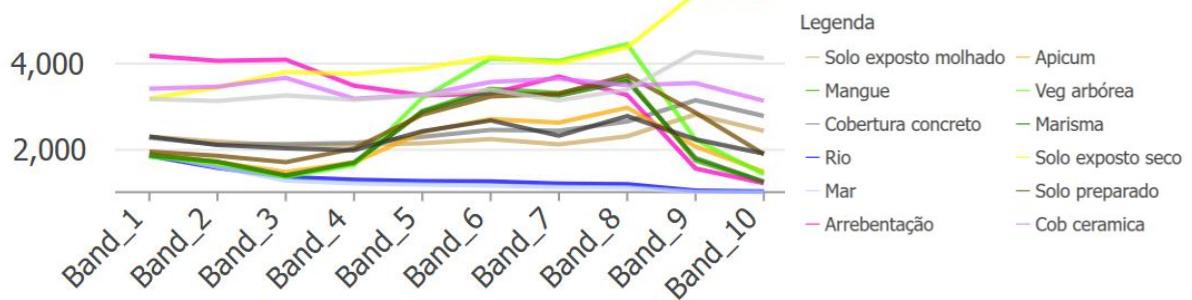
Para o restante das classes foi feita uma coleta acurada de pixels para servir de verdade terrestre para a geração da matriz de confusão. O procedimento consistiu em selecionar a classificação previamente gerada e definir amostras de controle representativas para cada classe mapeada. Foram coletadas aproximadamente 15 amostras por classe, e 25 amostras para as classes de manguezais e marismas, por se tratar de áreas de maior relevância e suscetibilidade a erros de interpretação.

Em seguida, foi executada a validação automática por meio da validação aleatória estratificada, mantendo o número máximo de amostras no valor padrão (500 amostras). A partir dessa etapa, o software correlacionou os pontos de referência com os pixels classificados, resultando na matriz de confusão. Essa matriz forneceu os principais indicadores de desempenho da classificação, entre eles a acurácia global (*Accuracy*) e o coeficiente Kappa, permitindo avaliar quantitativamente a confiabilidade do mapeamento obtido.

5 RESULTADOS E DISCUSSÃO

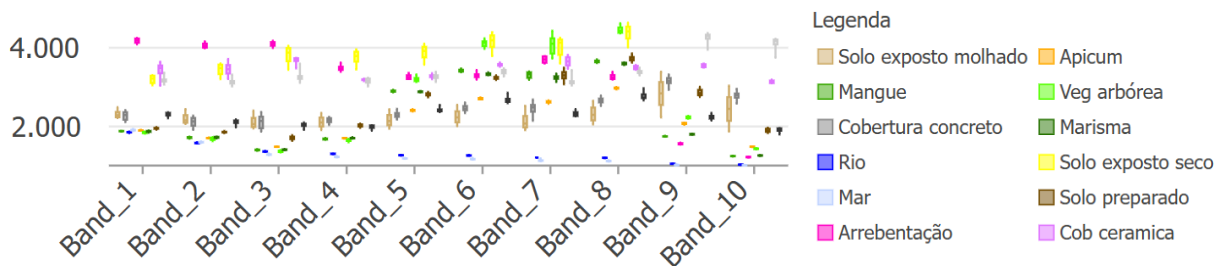
A análise dos perfis espectrais realizada na área de estudo permitiu caracterizar de forma detalhada os ecossistemas de manguezal e os diferentes usos e coberturas do solo. A integração de gráficos de linha que evidenciaram as tendências médias de reflectância por banda (Figura 7) com box-plots, que destacaram dispersão e sobreposição espectral (Figura 8), forneceu subsídios quantitativos e qualitativos essenciais para a definição, unificação ou distinção das classes. Enquanto os gráficos de linha revelaram o comportamento médio de cada alvo, os box-plots permitiram identificar detalhes importantes, como *outliers* e sobreposição entre classes, sendo fundamentais para decisões precisas de classificação.

Figura 7 – Perfil espectral de classes previamente definidas por meio de gráfico de linhas



Fonte: Autoria própria, 2025.

Figura 8 – Perfil espectral de classes previamente definidas por meio de gráfico de box-plot



Fonte: Autoria própria, 2025.

Os resultados mostraram comportamentos espectrais bem definidos para alguns alvos. A cobertura metálica, por exemplo, apresentou alta reflectância (4.000–5.500 valores de número digital (DN)) e curva relativamente plana, sendo configurada como espectralmente distinta e de fácil reconhecimento, principalmente em associação a estruturas portuárias (que

ficaram bem delimitadas). Com isso, optou-se por manter essa classe, uma vez que estruturas como o porto e outras indústrias podem ser relevantes quando trata-se da conservação de manguezais.

As coberturas vegetais (mangue, vegetação arbórea e marisma/apicum) exibiram picos nos comprimentos de onda Red Edge (borda vermelha) e NIR (Near InfraRed, infravermelho próximo), com diferentes amplitudes e dispersões. Com base nesses padrões, decidiu-se unir marisma e apicum em uma única classe denominada “marisma”, além de incluir duas novas classes: áreas de brejos e similares, e áreas de planície lamosa. Essas classes apresentaram características espectrais distinguíveis e relevância ecossistêmica, estando também presentes em grande parte das bibliografias existentes, bem como no banco de dados interno do projeto “Geoprocessamentos e Cartas SAO da Bacia de Santos” – UNESP/Rio Claro (2020).

Nos solos, observou-se que os secos apresentaram tendência de reflectância crescente até o SWIR, enquanto solos úmidos e preparados permaneceram próximos em algumas faixas espectrais. A separação das classes foi mantida, considerando a importância de diferenciar condições de saturação hídrica e usos antrópicos na área costeira. A classe “Solo preparado” foi renomeada para “Solo modificado” para englobar de forma mais ampla possíveis alterações no solo e facilitar a compreensão pelo público geral.

Os corpos hídricos apresentaram baixos valores de reflectância e elevada similaridade espectral, sendo destacados com o apoio do índice NDWI (sigla para Normalized Difference Vegetation Index ou Índice de Vegetação por Diferença Normalizada), que realçou zonas de deságue e interfaces costeiras. Essa distinção (entre rio e mar) é essencial para compreender a dinâmica hídrica, que influencia diretamente o ecossistema de manguezal, marcado, exatamente, pela mistura dos dois tipos de corpos hídricos.

As áreas antrópicas (asfalto, concreto e cerâmica) foram unificadas na classe “área urbanizada”. Apesar das diferenças espectrais entre esses materiais, a separação individual aumentaria a complexidade e o tempo de processamento, além de desviar o foco do estudo, que prioriza os manguezais. A unificação também contribuiu para uma classificação mais didática e acessível.

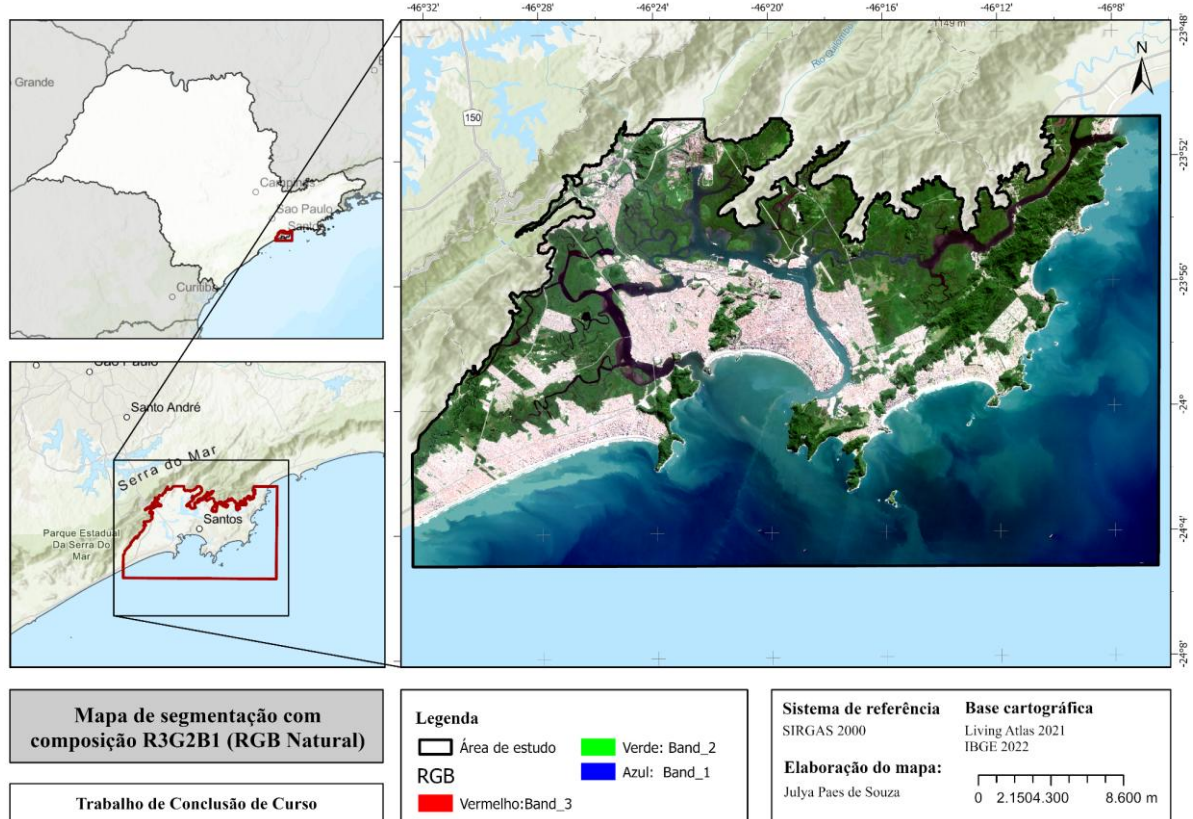
Esses padrões espectrais serviram como base para a escolha das diferentes combinações de bandas nas segmentações e para o treinamento do algoritmo *Support Vector Machine* (SVM). Por exemplo, a semelhança espectral entre manguezais e vegetação arbórea levou a indicações

que composições que incluíssem bandas do Red Edge e SWIR, capazes de capturar diferenças sutis de vigor, densidade foliar e umidade do solo, seriam de melhor acurácia enquanto áreas urbanizadas e solos secos poderiam ser mais bem distinguidas por combinações que explorassem o visível e o NIR.

A partir disso, a primeira segmentação analisada correspondeu à composição RGB natural (R3G2B1 – Band_3/B4, Band_2/B3, Band_1/B2), a qual serviu como um padrão visual de referência, facilitando a seleção inicial das amostras. Essa composição reproduz as cores percebidas pelo olho humano, o que torna a identificação das feições terrestres mais intuitiva e contribui para a calibração da segmentação, além de auxiliar na definição das amostras de treinamento realizadas pela autora. Contudo, apesar dessa vantagem visual, a segmentação apresentou limitações na separabilidade espectral entre áreas de solo exposto e manguezal, resultado coerente com os padrões observados na análise espectral. Ainda assim, o produto obtido se destaca pela clareza na delimitação de grandes estruturas, evidenciando, por exemplo, a mancha urbana consolidada em tons de cinza e branco, em contraste com o verde característico da Serra do Mar e dos manguezais (Figura 9).

Embora a composição RGB natural ofereça uma representação visual fiel da paisagem, seu uso isolado limita o potencial analítico do mapeamento, uma vez que não explora todo o espectro disponível nas imagens multiespectrais. Assim, a segmentação tende a enfatizar contrastes visuais e estruturais, mas não capta diferenças sutis de comportamento espectral entre as coberturas. Essa limitação reforça a importância de testar composições que integrem bandas do infravermelho, capazes de ampliar a resposta espectral da vegetação e melhorar a distinção entre os diferentes ecossistemas costeiros.

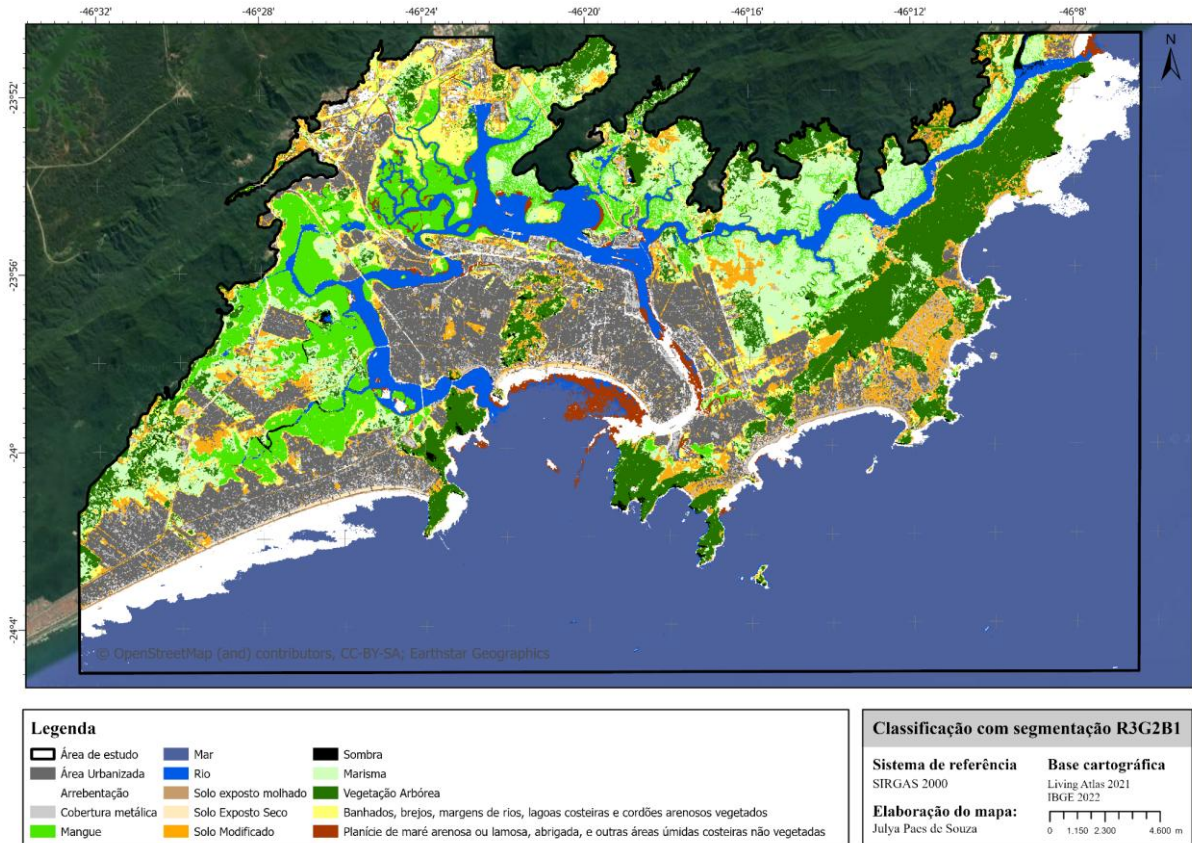
Figura 9 - Segmentação R3G2B1 (RGB Natural)



Fonte: Autoria própria, 2025.

Na classificação com SVM, o desempenho da segmentação R3G2B1 foi inferior em relação às demais composições segundo a análise estatística, que será discutida posteriormente (Figura 20). O algoritmo apresentou dificuldades em separar as áreas de manguezal das planícies lamosas e da vegetação adjacente (Figura 10). Do ponto de vista técnico, essa confusão é coerente com o fato de que bandas do visível possuem baixo contraste espectral em ambientes úmidos (Figueiredo, 2005).

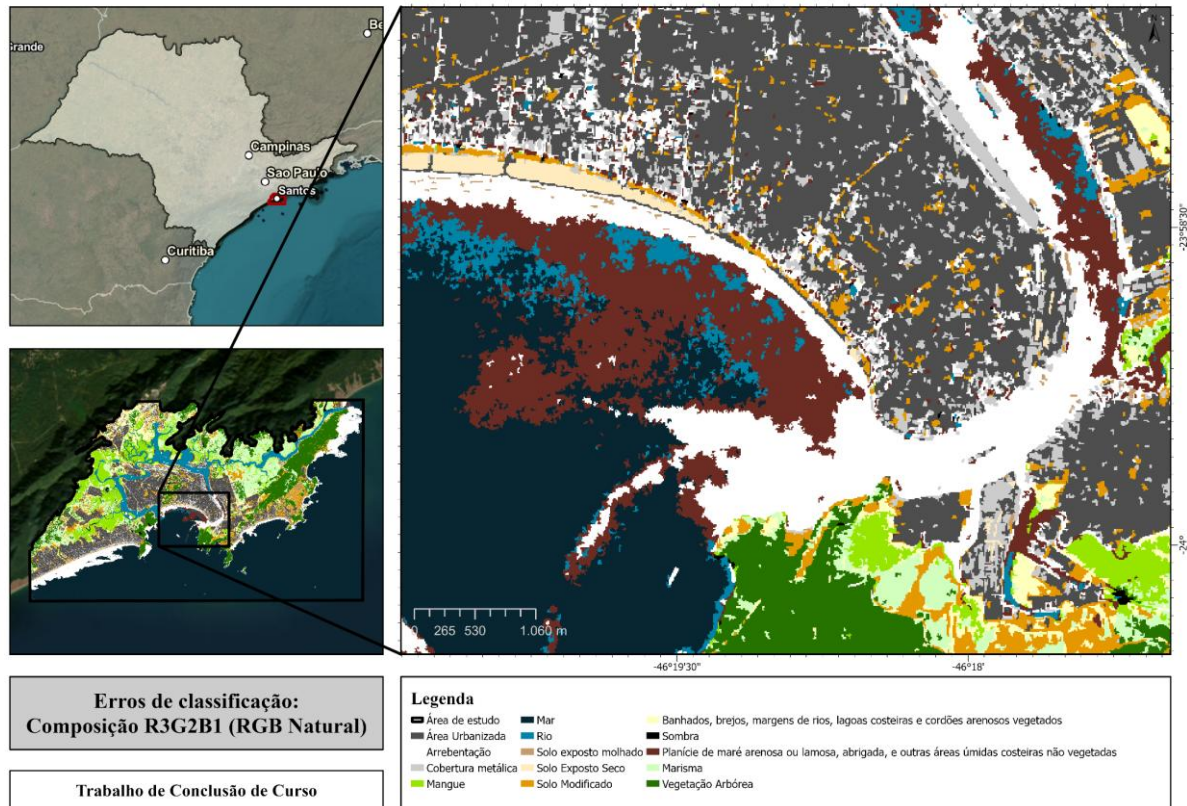
Figura 10 - Classificação SVM R3G2B1 (RGB Natural)



Fonte: Autoria própria, 2025.

Portanto embora o RGB natural seja útil para interpretação visual, ele apresenta limitações para classificação em SVM, pois não captura diferenças estruturais e de umidade essenciais para diferenciar manguezais. Além disso, nessa classificação foi possível identificar um erro perceptível a olho nu, onde, o algoritmo considera áreas de rio-mar como áreas de planície lamosa (Figura 11).

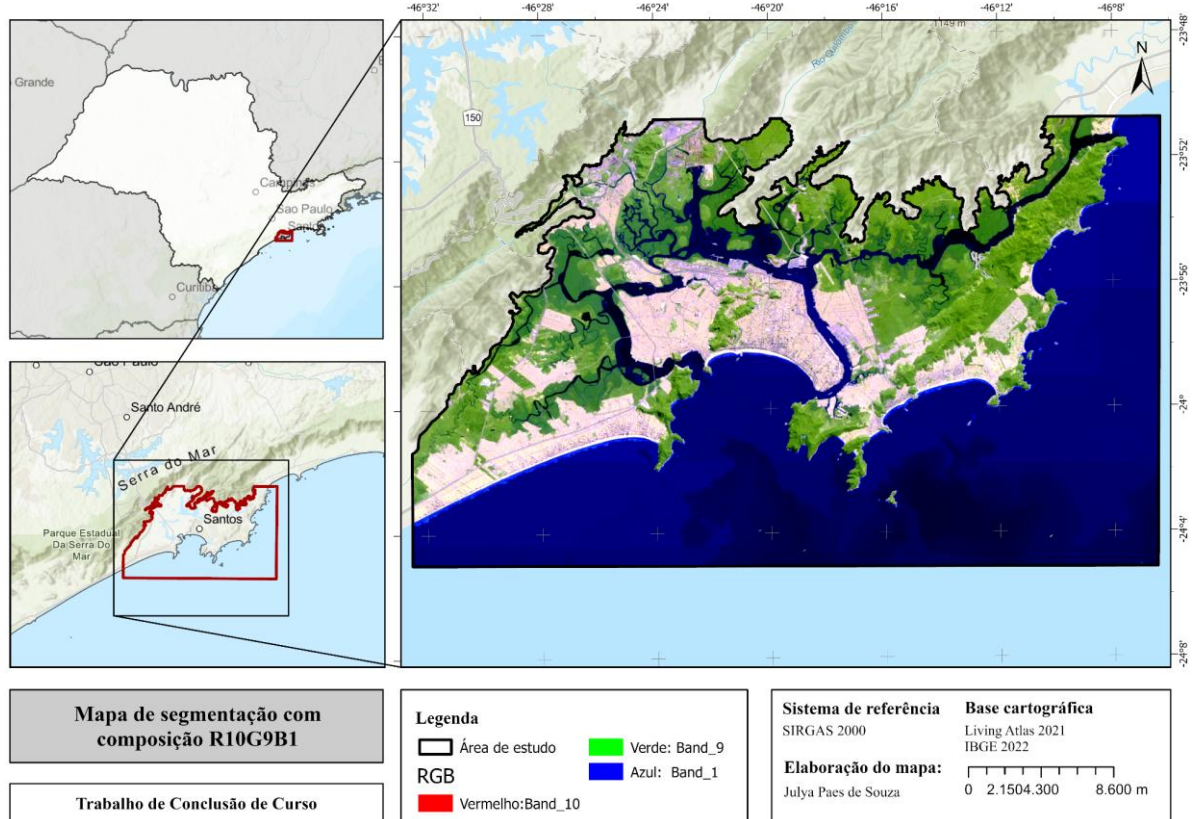
Figura 11 - Erro SVM R3G2B1 (RGB Natural)



Fonte: Autoria própria, 2025.

Para superar essas restrições, foi utilizada a composição R10G9B1 (Band_10/B12, Band_9/B11, Band_1/B2), que combina bandas do SWIR 2, SWIR 1 e Azul, a fim de maximizar a discriminação da cobertura vegetal. Nesta visualização de cores falsas, o resultado da segmentação reflete não apenas a presença de vegetação, mas também as variações da sua preservação e estrutura interna (como a saúde das folhas). As áreas de mata atlântica, manguezal e possível vegetação secundária apresentam tons de verde-escuro com variações de brilho (observa-se diferentes tons de verde, sobretudo, ao aumentar a escala de visualização) e intensidade, que traduzem, como já dito, a saúde e principalmente a densidade da biomassa (Figura 12). Os segmentos gerados a partir desta composição são, portanto, essenciais para uma boa classificação, permitindo ao algoritmo de segmentação a separação robusta de classes de vegetação que se pareceriam homogêneas no RGB natural, como diferenciar áreas de vegetação arbórea e mangues.

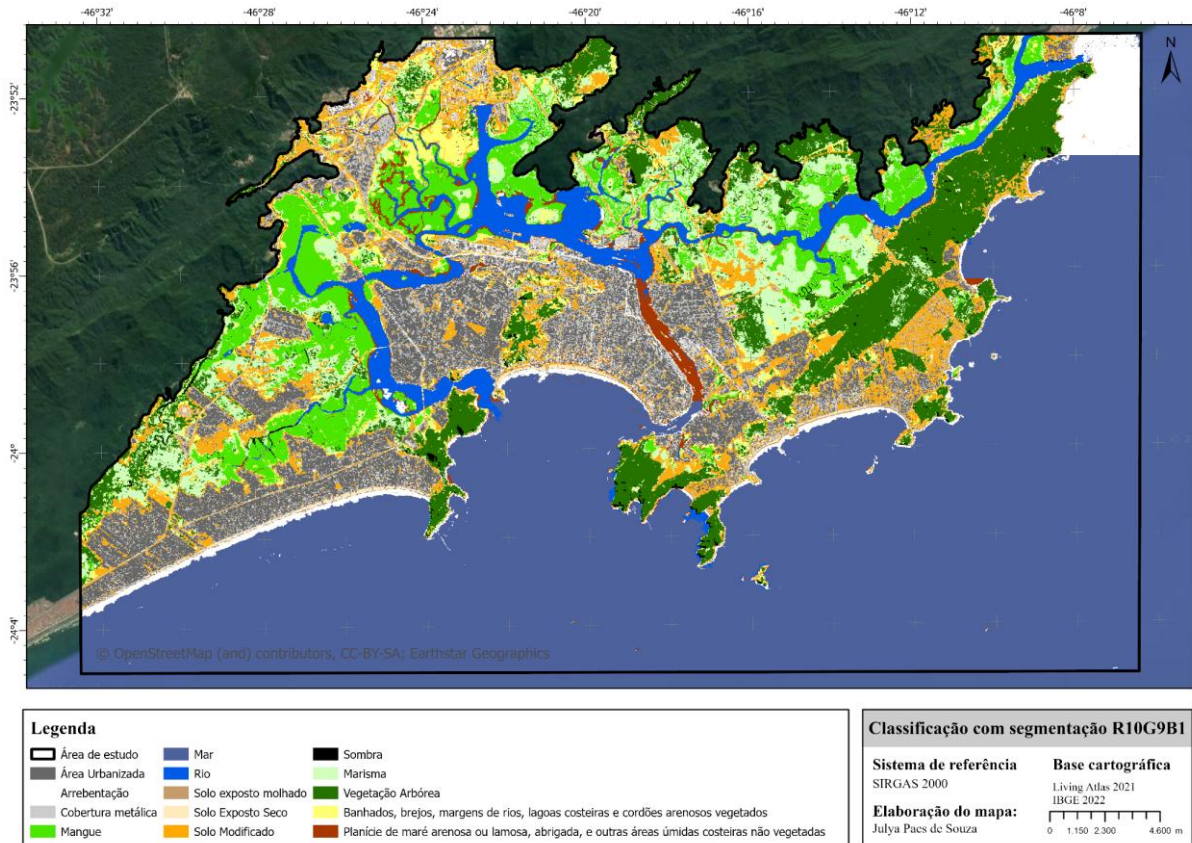
Figura 12 - Segmentação R10G9B1



Fonte: Autoria própria, 2025.

A classificação derivada da segmentação R10G9B1 influencia a qualidade interna das classes com vegetação (Figura 13). O uso combinado do SWIR e NIR permite ao classificador ir além da simples presença/ausência de vegetação. O resultado é um mapeamento que reflete melhor as variações de umidade e vigor dentro da própria mata atlântica e do manguezal. Esta classificação contribui estatisticamente para a melhoria da acurácia global, pois fornece atributos que ajudam a resolver ambiguidades espectrais que persistem em outras composições, como a separação entre diferentes estágios sucessionais da floresta ou áreas de estresse hídrico. A sua principal contribuição é refinar o limite entre a vegetação densa e o manguezal, garantindo que segmentos com alta umidade e biomassa (características do mangue) sejam separados da vegetação de encosta, mesmo que ambas apresentem alta resposta no NIR.

Figura 13 - Classificação SVM R10G9B1

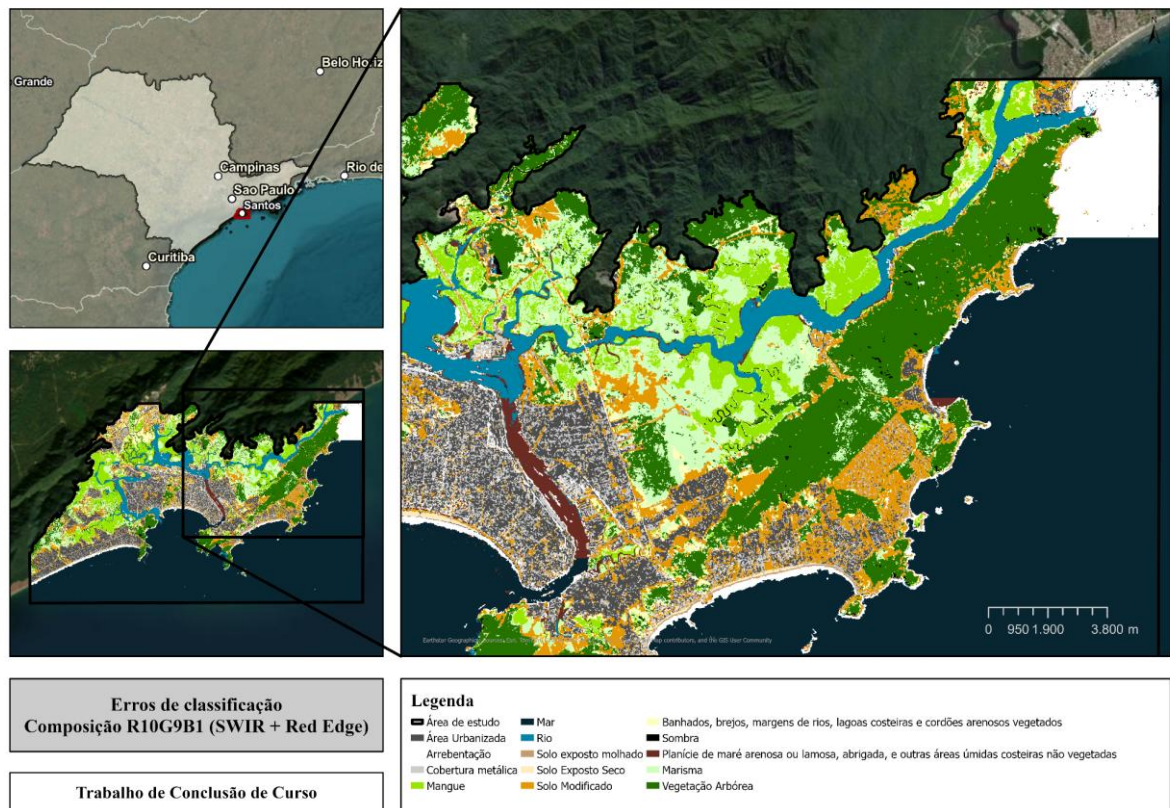


Fonte: Autoria própria, 2025.

Apenas pela análise visual, é possível dizer que, os manguezais em específico foram mais bem identificados nessa composição, uma vez que o SWIR permitiu diferenciar vegetação encharcada e solos saturados de áreas secas ou arenosas. No entanto, persistiram confusões nas transições água-terra, especialmente nas classes arrebentação e marisma, que compartilham respostas intermediárias de reflectância (Figura 8). Ainda assim, o resultado mostrou boa coerência espacial e foi um dos melhores no mapeamento dos manguezais, mas ainda sem resultado satisfatório, uma vez que, marismas e outras áreas alagadas são tão importantes quanto os mangues para o ecossistema em questão.

Também foi notório uma falha durante a classificação com essa segmentação, no canto superior direito, quando o algoritmo entende uma grande área de mar como arrebentação (Figura 14). Durante o processo de análise visual foi percebido que na segmentação esse “recorte” fica mais claro e então o algoritmo generaliza todo o local. Ou seja, apesar da boa identificação, essa segmentação pode gerar erros grotescos, sobretudo para estudos com foco marítimo. Também há confusão entre a área de rio-mar com áreas de planície lamosa.

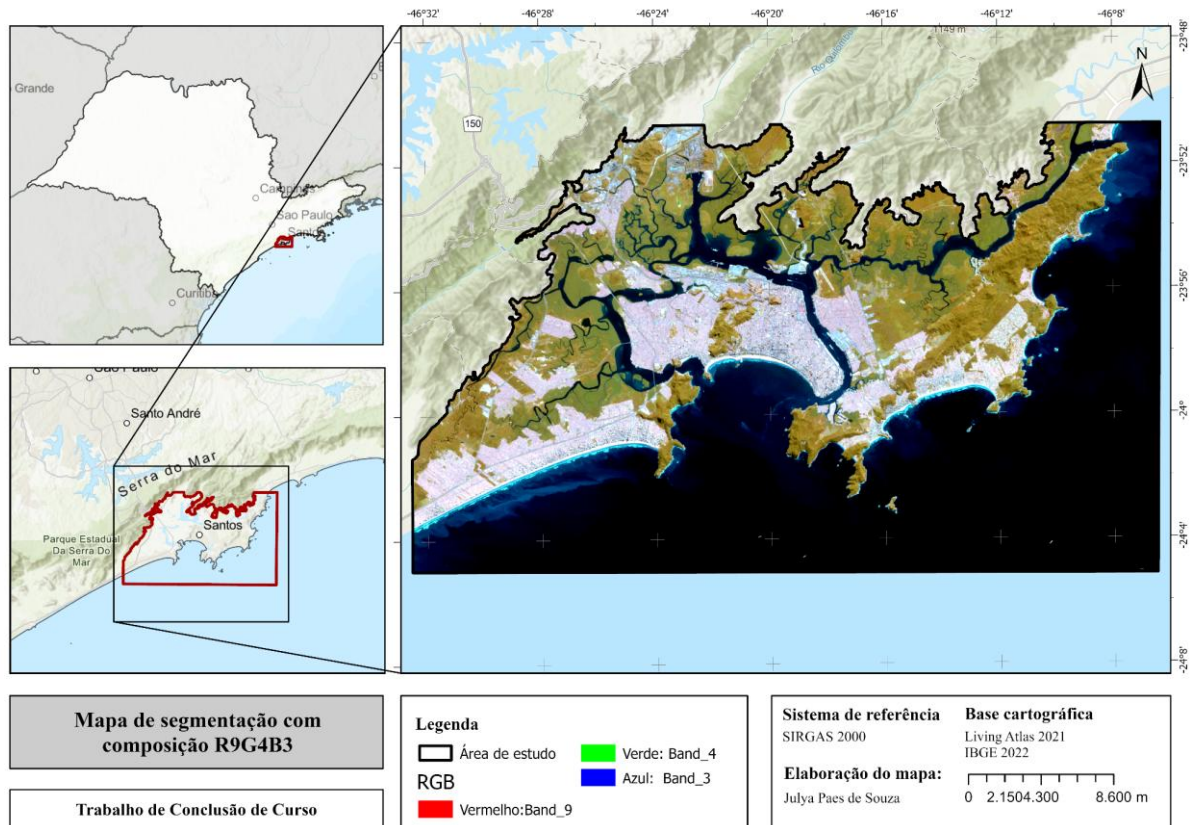
Figura 14- Erro SVM R10G9B1



Fonte: Autoria própria, 2025.

Embora essa segmentação tenha aprimorado a identificação de manguezais, ainda persistiram confusões nas transições água-terra, mostrando que a inclusão de novas bandas seria necessária para separar adequadamente solos e áreas urbanas. Essa necessidade motivou o uso e a análise da composição R9G4B3 (Band_9/B11, Band_4/B8, Band_3/B4), que combina o SWIR 1, o NIR e o Vermelho, privilegiando áreas não fotossinteticamente ativas e aumentando o contraste entre solos expostos e superfícies urbanizadas (Figura 15). O principal resultado desta segmentação é a melhoria da separabilidade espectral dentro das classes de solo exposto e áreas urbanas. Desta forma, esta composição fornece um poderoso conjunto de dados para refinar os segmentos de classes antrópicas. A informação de segmentação aqui gerada é crucial para garantir que as classes de "área construída" não sejam confundidas com classes de "solo modificado" ou com superfícies de água turbidez elevada, contribuindo para uma acurácia superior no mapeamento da expansão urbana.

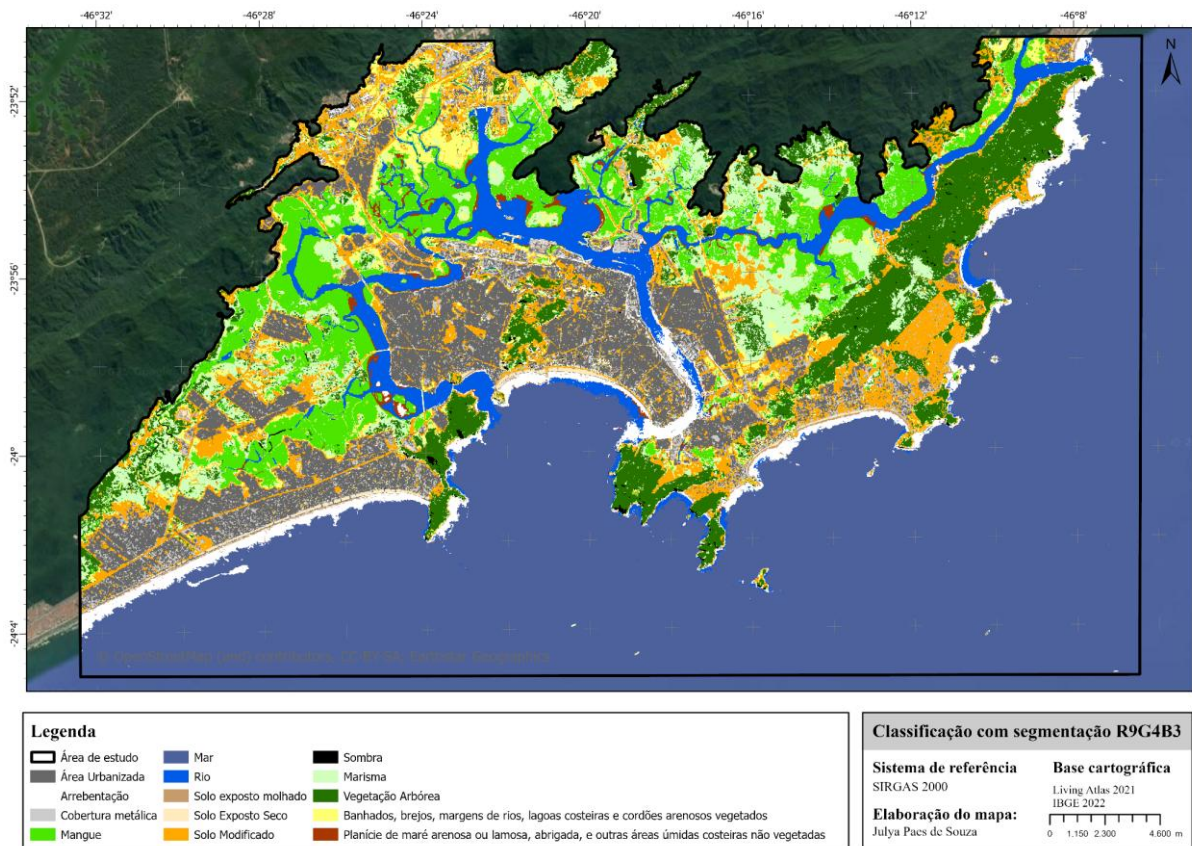
Figura 15 - Segmentação R9G4B3



Fonte: Autoria própria, 2025.

A classificação obtida através da segmentação R9G4B3 é crucial para a redução do erro de comissão em classes não-vegetais. Esta classificação é a mais eficiente na delimitação da classe área construída (juntamente com solo exposto). O espectro Infravermelho Próximo (NIR), posicionado no canal vermelho, faz com que a diferença entre os materiais de construção e a vegetação seja maximizada. Isso resulta em uma acurácia do usuário superior para a classe área construída, pois a confusão com a vegetação ou solo claro (comuns no RGB natural) é drasticamente reduzida. O Red Edge se mostrou particularmente eficaz para detectar a estrutura foliar e o vigor vegetativo característicos das espécies de mangue, o que torna a classificação de grande valia para o presente estudo (Figura 16).

Figura 16 - Classificação SVM R9G4B3



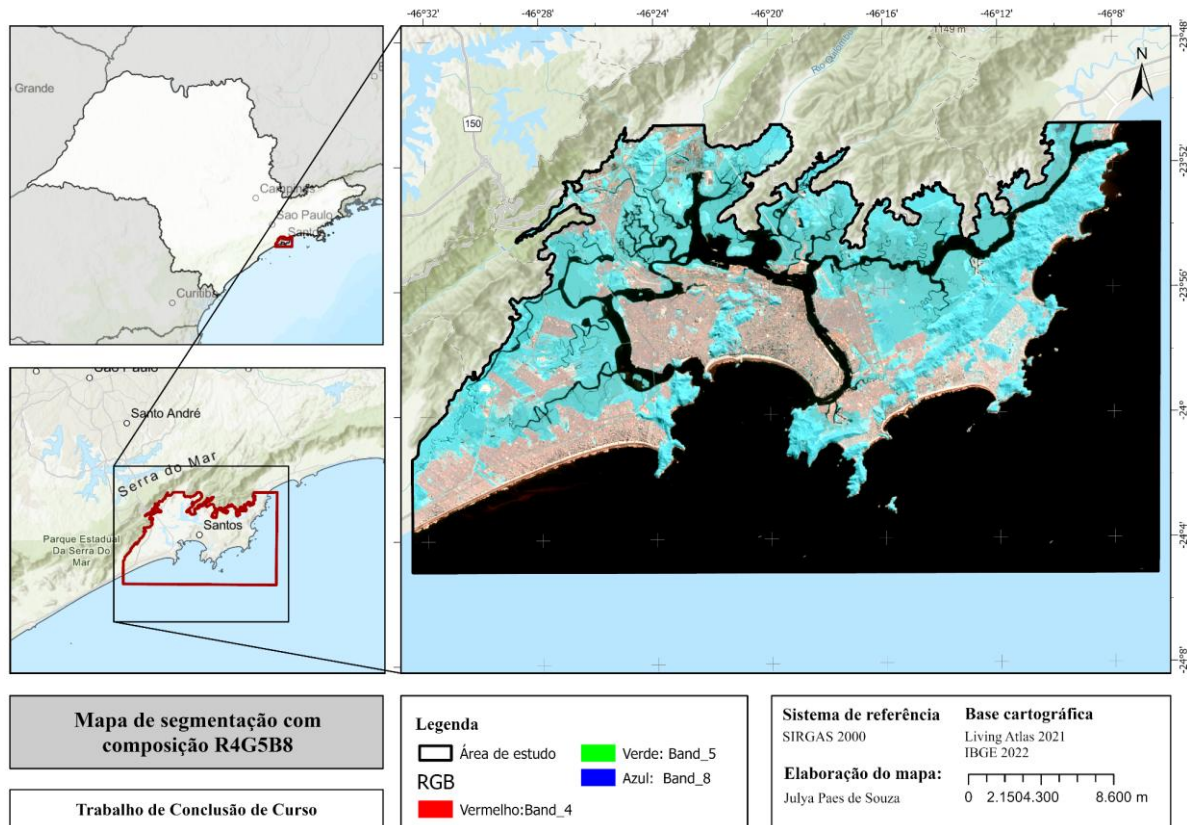
Fonte: Autoria própria, 2025.

As principais confusões ocorreram entre áreas urbanas, metálicas e solos secos, devido à similaridade espectral no visível, mas sem interferir nas zonas de mangue. Assim, a R9G4B3 demonstrou o melhor desempenho específico para o objetivo deste estudo, identificando com precisão boa todos os elementos relevantes para o ecossistema dos manguezais. Por fim, a composição R4G5B8 (Band_4/B8, Band_5/B5, Band_8/B8A) foi selecionada com o objetivo de aprofundar a análise das transições entre ambientes continentais e costeiros, especialmente nas zonas de estuário e planícies de maré. Essa combinação de bandas envolve o NIR, o Red Edge 1 e o NIR estreito, resultando em uma representação de cores falsas com contraste acentuado entre superfícies úmidas e secas, tornando-a particularmente adequada para estudos de hidrodinâmica e dinâmica costeira.

No produto de segmentação (Figura 17), é possível observar que as feições aquáticas (rios, canais estuarinos e áreas de maré) aparecem bem destacadas em tons escuros, contrastando fortemente com as áreas de solo exposto e vegetação. Essa definição favorece a leitura das interfaces terra-água, permitindo distinguir de forma mais precisa as zonas alagáveis e áreas com saturação hídrica. As superfícies vegetadas, por sua vez, assumem tons

intermediários, refletindo a alta resposta do infravermelho próximo e curto em tecidos vegetais com elevado conteúdo de biomassa. A resposta espectral combinada dessas bandas produz um mosaico onde as variações de umidade, densidade foliar e estrutura superficial são evidenciadas de maneira muito mais nítida do que nas composições anteriores.

Figura 17 - Segmentação R4G5B8



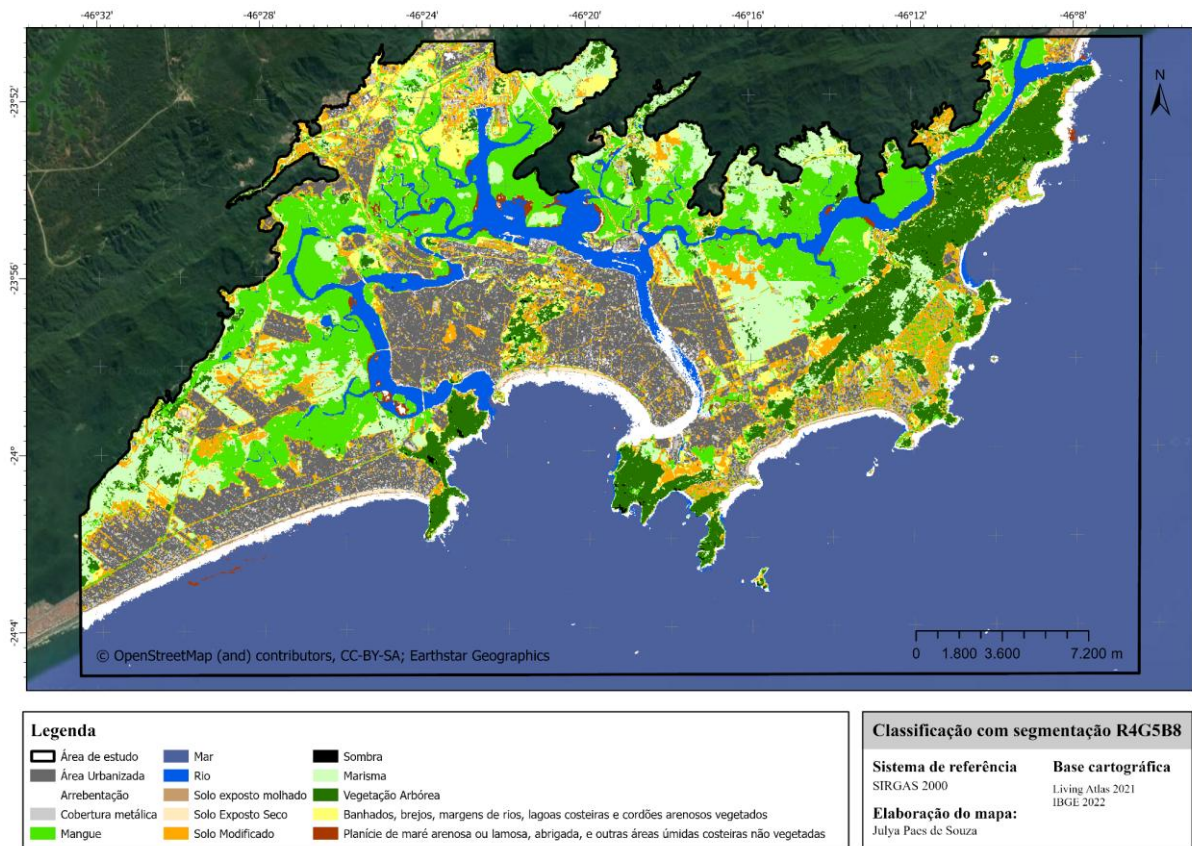
Fonte: Autoria própria, 2025.

Na classificação derivada dessa segmentação (Figura 18), observa-se que o algoritmo SVM conseguiu representar de forma consistente a organização espacial dos ecossistemas costeiros. As áreas de água, solo úmido e vegetação densa foram claramente individualizadas, confirmando o alto potencial da composição para diferenciar alvos com variações de teor de água e biomassa. As áreas de manguezal aparecem bem delimitadas, com continuidade espacial coerente ao longo das margens estuarinas, embora ainda haja confusão pontual nas regiões de transição com vegetação arbórea e solos lamosos, resultado previsível, dado o comportamento espectral similar dessas classes no infravermelho.

Visualmente, nota-se também que a R4G5B8 tende a realçar feições continentais e solos internos úmidos com maior intensidade do que zonas intertidais, o que indica um leve

superdimensionamento das áreas vegetadas e uma sub-representação das superfícies encharcadas expostas. Essa característica é comum em composições dominadas pelo NIR, uma vez que a forte resposta da vegetação pode mascarar pequenas variações de umidade superficial. Ainda assim, o produto apresenta alta coerência geomorfológica, refletindo a estrutura ambiental da planície costeira, a continuidade dos canais de maré e a segmentação precisa das feições hidrológicas.

Figura 18 - Classificação R4G5B8



Fonte: Autoria própria, 2025.

As classificações realizadas com o algoritmo *Support Vector Machine* (SVM) apresentaram resultados condizentes com as características espectrais dos ecossistemas costeiros da Baixada Santista, revelando padrões distintos de desempenho a depender da segmentação aplicada. A análise integrada dos resultados demonstra como a escolha das bandas espectrais influencia diretamente a separabilidade entre as classes e, conseqüentemente, a precisão na detecção dos manguezais, que é o foco central deste estudo.

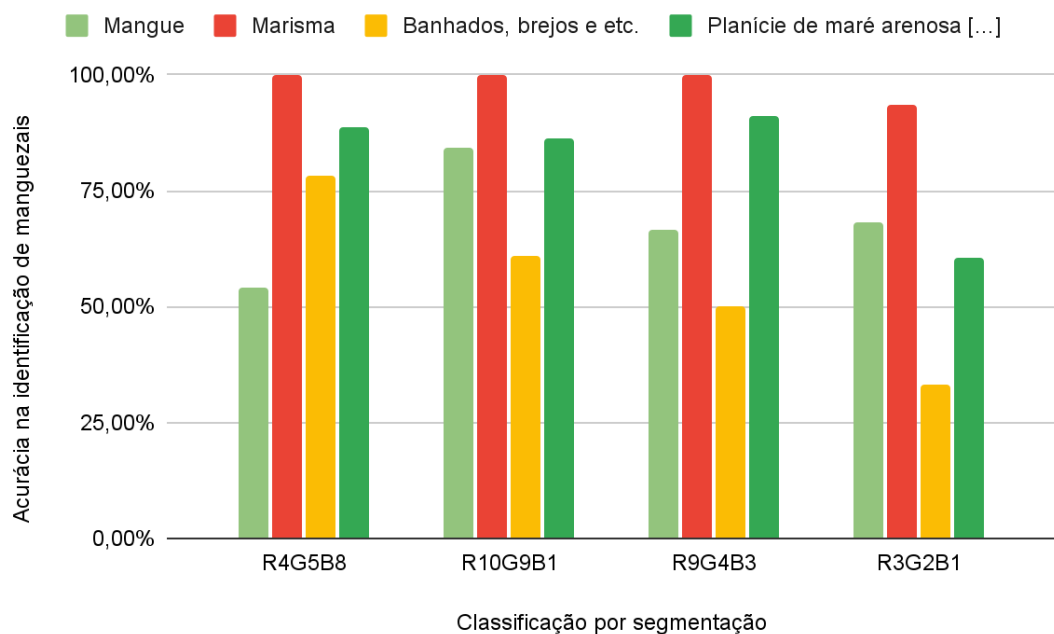
A figura 19 ilustra como cada combinação espectral influenciou o desempenho do SVM especificamente nas classes que compõem um manguezal. Observa-se se tratando apenas de mangues, a segmentação R10G9B1 apresentou o melhor desempenho, com 84,21% de acerto, seguida da R9G4B3 e da R3G2B1, enquanto a R4G5B8 registrou valores inferiores (Tabela 1).

Tabela 1 – Precisão na identificação de classes de ecossistemas de manguezais por classificação segundo a acurácia global convertida em porcentagem

Classe/classificação	R4G5B8	R10G9B1	R9G4B3	R3G2B1
Mangue	54,05%	84,21%	66,67%	68,18%
Marisma	100,00%	100,00%	100,00%	93,33%
Banhados, brejos etc.	78,26%	60,98%	50,00%	33,33%
Planície de maré arenosa [...]	88,89%	86,49%	91,18%	60,38%

Fonte: Autoria própria, 2025.

Figura 19 - Identificação de classes de ecossistemas de manguezais por classificação (%)



Fonte: Autoria própria, 2025.

Além disso, também foi considerado o desempenho geral de cada modelo, gerado a partir da matriz de confusão e analisando a acurácia global e o índice de Kappa (Figura 20 e tabela 2). A R10G9B1 obteve os maiores valores médios de acurácia global (~ 77,06%) e de Kappa (~75,29%), indicando não apenas boa classificação da classe foco do estudo, mas

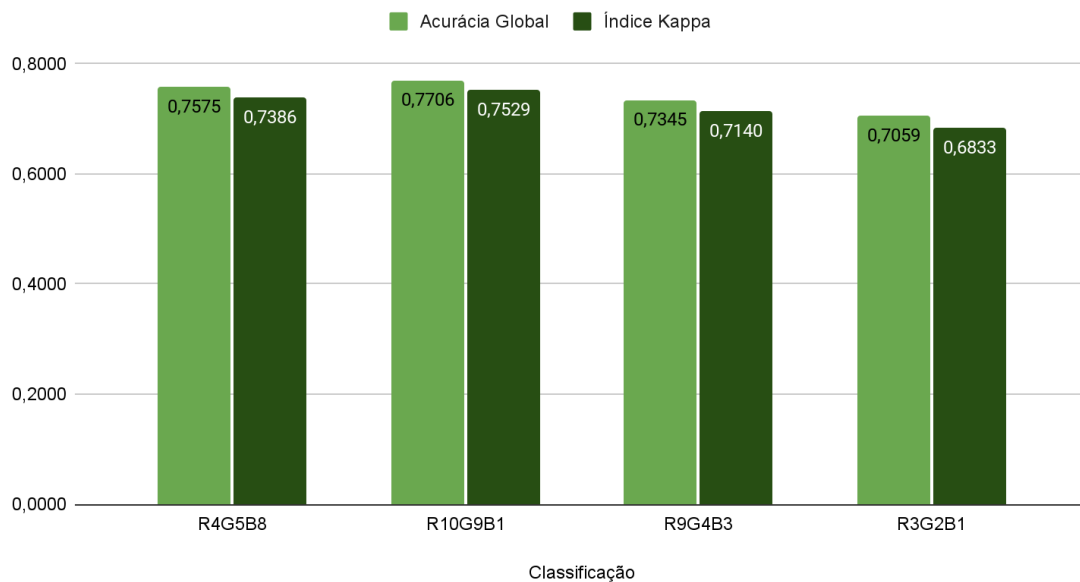
também alta confiabilidade estatística, uma vez que o índice Kappa corrige os acertos aleatórios. Embora as segmentações R4G5B8 e R9G4B3 também apresentem consistência aceitável, seus resultados sugerem menor sensibilidade às variações microambientais características dos manguezais. Já a R3G2B1, baseada exclusivamente no espectro visível, demonstrou desempenho mais limitado, sobretudo pela baixa resposta às variações de umidade superficial e densidade vegetativa.

Tabela 2 – Desempenho geral por classificação

Classificação	Acurácia Global	Índice Kappa
R4G5B8	0,7575	0,7386
R10G9B1	0,7706	0,7529
R9G4B3	0,7345	0,7140
R3G2B1	0,7059	0,6833

Fonte: Autoria própria, 2025.

Figura 20 - Desempenho geral por classificação



Fonte: Autoria própria, 2025.

Assim, o conjunto dos resultados apoiado pelas análises visuais, estatísticas e gráficas demonstra que o algoritmo SVM apresenta elevada eficiência na classificação de ecossistemas de manguezal, desde que associado a segmentações com adequação espectral e a bandas

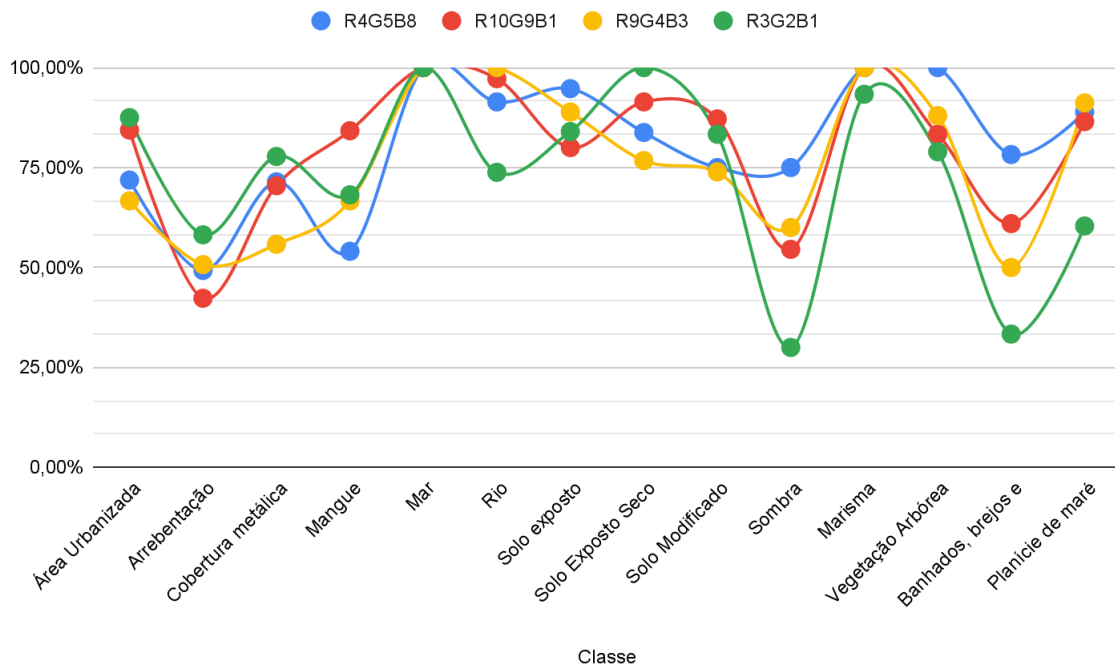
capazes de representar com precisão os parâmetros biofísicos do ambiente. O desempenho observado reforça a importância do uso de combinações que incluam o infravermelho próximo (NIR) e o infravermelho de ondas curtas (SWIR) na distinção dos ambientes costeiros tropicais.

O gráfico exposto na figura 21 apresenta a performance de “estabilidade”, ou seja, o quanto as classificações se mantêm assertivas de modo geral, por classe, das quatro composições testadas, expressa em percentuais de acurácia por classe. A leitura integrada mostra, novamente, que a R10G9B1 (linha vermelha) tem comportamento mais estável e consistente ao longo das classes, atingindo picos máximos para classes importantes para o estudo, como mangue e marisma/apicum, além de evitar quedas acentuadas em muitas categorias. Isso confirma a razão pela qual essa composição é a mais apropriada para o mapeamento temático dos manguezais, uma vez que ela combina boa discriminabilidade das classes alagadas com estabilidade nos demais alvos.

A R4G5B8 (linha azul) também apresenta desempenho elevado e relativamente estável, com pequenas variações entre classes. Mostra boa capacidade em realçar feições associadas à umidade e à vegetação densa, sendo robusta em muitas classes, embora em alguns alvos específicos perca para a R10G9B1. Já a R9G4B3 (linha amarela) tende a fornecer bom contraste para classes antrópicas e solos expostos, com acurácias altas em áreas urbanas e materiais inertes, mas levemente inferiores nas classes dominadas por água ou umidade, em comparação com composições que utilizam mais bandas SWIR e NIR.

Por fim, a R3G2B1 (linha verde), correspondente ao RGB natural, apesar de útil visualmente, apresenta as maiores flutuações e as quedas de desempenho mais pronunciadas, especialmente em classes de sombra e nas transições entre água e terra. Isso reforça suas limitações para classificação automática em ambientes úmidos e heterogêneos.

Figura 21 - Estabilidade estatística entre classes por segmentação/classificação



Fonte: Autoria própria, 2025.

Em suma, o gráfico confirma a principal conclusão do estudo. O SVM se mostrou efetivo quando associado a segmentações espectralmente adequadas, e a composição R10G9B1 (Band_10/B12, Band_9/B11, Band_1/B2), que combina bandas do SWIR 2, SWIR 1 e azul, apresentou a melhor combinação entre discriminação dos manguezais e estabilidade entre as demais classes. Mesmo assim, cada composição demonstrou pontos fortes específicos, como a R9G4B3, mais eficiente na identificação de áreas urbanas e solos expostos, e a R4G5B8, que se destacou na representação de feições úmidas. Esses resultados indicam que o desempenho pode variar conforme o tipo de alvo mapeado, reforçando a importância da escolha criteriosa das bandas em estudos de classificação temática.

6 CONSIDERAÇÕES FINAIS

O presente estudo demonstrou a eficácia do uso de imagens multiespectrais do satélite Sentinel-2, combinadas ao classificador *Support Vector Machine (SVM)* e à abordagem orientada a objetos (GEOBIA), no mapeamento e análise da distribuição dos manguezais na Baixada Santista (SP). A metodologia empregada possibilitou não apenas identificar com certa precisão as áreas de mangue, mas também compreender suas interações espaciais com outros tipos de cobertura, como marismas, solos úmidos, planícies lamosas e áreas urbanizadas, compondo um retrato detalhado e coerente do mosaico costeiro. Com isso, foi possível cumprir o objetivo de mapear a distribuição dos manguezais utilizando dados multiespectrais de média resolução.

Os resultados confirmaram que a integração entre análise espectral detalhada e classificação supervisionada é essencial para lidar com a complexidade dos ecossistemas costeiros, nos quais predominam gradientes ambientais contínuos e forte heterogeneidade espacial. O uso das bandas multiespectrais do Sentinel-2, abrangendo desde o visível até o infravermelho de ondas curtas (SWIR), foi determinante para distinguir alvos de reflectância semelhante, sobretudo nas transições entre ambientes terrestres e aquáticos, que são zonas onde os métodos tradicionais de classificação apresentam maior limitação.

A análise comparativa entre as segmentações testadas evidenciou que, embora todas as composições tenham permitido ao SVM capturar os principais padrões espectrais e estruturais da planície costeira, a composição R10G9B1 (Band_10/B12, Band_9/B11, Band_1/B2), que combina bandas do SWIR 2, SWIR 1 e azul, destacou-se como a mais adequada para o mapeamento de manguezais, atendendo ao objetivo central do estudo, que consistiu em identificar a configuração espectral mais eficiente para discriminar as classes de interesse.

Ainda assim, os resultados indicam potencial de aprimoramento. A integração das bandas SWIR da R10G9B1 com novas configurações poderia oferecer uma classificação ainda mais robusta, unindo a capacidade de distinguir gradientes de umidade e estrutura com a resposta vigorosa do dossel vegetativo. Essa abordagem tenderia a reduzir as confusões entre classes espectralmente próximas e a aumentar a confiabilidade da classificação em áreas de alta heterogeneidade espacial, além de evitar erros grosseiros como foi exposto anteriormente. Esta reflexão está alinhada ao objetivo de identificar limitações e apresentar subsídios para o refinamento metodológico em estudos futuros.

Do ponto de vista metodológico, a segmentação orientada a objetos mostrou-se uma etapa essencial no processo classificatório, pois melhorou o refinamento das fronteiras entre classes, reduziu ruídos e aumentou a coerência espacial dos polígonos resultantes. Essa característica foi especialmente relevante em ecossistemas de transição, como os manguezais, onde as variações de reflectância ocorrem de forma gradual, influenciadas por fatores como salinidade, saturação hídrica e densidade da vegetação.

De modo geral, o desempenho do SVM confirma sua eficiência e estabilidade para o mapeamento de ambientes costeiros complexos, desde que aliado a segmentações adequadas e a uma seleção criteriosa das bandas espectrais. O algoritmo demonstrou alta capacidade de generalização, permitindo discriminar alvos espectralmente semelhantes sem necessidade de grandes volumes de amostras de treinamento, o que é uma vantagem relevante em áreas de difícil acesso, como zonas intertidais e estuarinas.

Do ponto de vista aplicado, este trabalho evidencia o potencial do sensoriamento remoto combinado ao aprendizado de máquina como ferramenta estratégica para o monitoramento ambiental e a gestão costeira integrada. A metodologia proposta é passível de replicação em outras regiões da costa brasileira, oferecendo suporte a órgãos públicos e instituições de pesquisa no acompanhamento de processos de degradação ambiental, expansão urbana e alterações na cobertura vegetal, especialmente diante do contínuo crescimento portuário e industrial na área de estudo. Além disso, os resultados obtidos apresentam valor prático significativo, podendo subsidiar planos de manejo, iniciativas de restauração ecológica e políticas públicas voltadas à conservação dos manguezais, ecossistemas essenciais para a biodiversidade, o armazenamento de carbono azul e o bem-estar socioeconômico das comunidades litorâneas.

Assim, conclui-se que o uso integrado de imagens Sentinel-2, GEOBIA e SVM constitui uma abordagem tecnicamente sólida e cientificamente eficaz para o mapeamento de ecossistemas costeiros. A experiência obtida na Baixada Santista reforça o papel das tecnologias de sensoriamento remoto como instrumentos indispensáveis para o avanço da pesquisa ambiental e o fortalecimento das estratégias de conservação e gestão sustentável dos manguezais brasileiros, cumprindo de maneira satisfatória todos os objetivos propostos ao l

7 REFERÊNCIAS

- ALBUQUERQUE, Rita Maria Vasconcelos Louzada; DO NASCIMENTO FARIAS, Elciane Maria; MAIA, Rafaela Camargo. Educação Ambiental para o Ecossistema Manguezal: O papel dos pescadores artesanais. **Conexões-Ciência e Tecnologia**, v. 9, n. 3, 2015.
- ALONGI, Daniel M. Carbon sequestration in mangrove forests. **Carbon management**, v. 3, n. 3, p. 313-322, 2012.
- AMBARWARI, Agus; HUSNI, Emir Mauludi. Studying How Machine Learning Maps Mangroves in Moderate-Resolution Satellite Images. **Indonesian Journal of Artificial Intelligence and Data Mining**, v. 6, n. 2, p. 270-280, 2023.
- AMORIM, Lucas de Oliveira *et al.* Injeção de ruído em serviços de aprendizagem de máquina na nuvem. 2023.
- ANDREOLA, Rafaela. Support Vector Machines na classificação de imagens hiperespectrais. 2009.
- ALVARES, Clayton Alcarde *et al.* Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- AUTORIDADE PORTUÁRIA DE SANTOS. *Minfra aprova nova poligonal que duplica área do Porto de Santos*. Santos: **Autoridade Portuária de Santos**, 19 jan. 2022. Disponível em: <https://www.portodesantos.com.br/2022/01/19/minfra-aprova-nova-poligonal-que-duplica-area-do-porto-de-santos/r>. Acesso em: 31 out. 2025.
- BAATZ, Martin. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. **Angewandte geographische informationsverarbeitung**, p. 12-23, 2000.
- BARBIER, Edward B. Valuing the environment as input: review of applications to mangrove-fishery linkages. **Ecological economics**, v. 35, n. 1, p. 47-61, 2000.
- BARBOSA, G. *et al.* Segurança em redes 5g: Oportunidades e desafios em detecção de anomalias e previsão de tráfego baseadas em aprendizado de máquina. **Proceedings of the Minicursos do XXI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais, Online, Belém**, p. 4-7, 2021.

BAXES, Gregory A. **Digital image processing: principles and applications**. John Wiley ; Sons, Inc., 1994.

BENZ, Ursula C. *et al.* Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of photogrammetry and remote sensing**, v. 58, n. 3-4, p. 239-258, 2004.

BLASCHKE, Thomas. Object based image analysis for remote sensing. **ISPRS journal of photogrammetry and remote sensing**, v. 65, n. 1, p. 2-16, 2010.

HAY, Geoffrey J.; CASTILLA, Guillermo. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: **Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 75-89.

CARVALHO, Márcio Santos *et al.* Quantificação e qualificação de resíduos sólidos coletados em áreas estuarinas dos Municípios de São Francisco do Conde e Maragogipe, Bahia. 2016.

CETESB – Companhia Ambiental do Estado de São Paulo. *Caracterização climática e meteorológica na área de estudo – APAMLC: relatório técnico*. São Paulo: SIGAM, 2018.

CHANG, Zhilu *et al.* Landslide susceptibility prediction based on remote sensing images and GIS: Comparisons of supervised and unsupervised machine learning models. **Remote Sensing**, v. 12, n. 3, p. 502, 2020.

CHELIZ, Pedro Michelutti; OLIVEIRA, R. C. Mundialização, riscos e impactos ambientais no litoral brasileiro: a Baixada Santista. **Risco e Vulnerabilidade Ambiental: métodos e experiências**, 2020.

CHOLLET, Francois. **Deep learning with Python**. simon and schuster, 2021.

CHUVIECO, E. Fundamentos de teledetección espacial. **Madrid: Unigraf**, 1990.

COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.

CONGALTON, Russell G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, v. 37, n. 1, p. 35-46, 1991.

- COSTANZA, Robert et al. The value of the world's ecosystem services and natural capital. **nature**, v. 387, n. 6630, p. 253-260, 1997.
- CORREIA, Monica Dorigo; SOVIERZOSKI, Hilda Helena. **Ecosistemas marinhos: recifes, praias e manguezais**. Maceió: Edufal, 2005.
- CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. **Machine learning**, v. 20, n. 3, p. 273-297, 1995.
- COSTA, Welando Bráulio Araújo da. Avaliação dos impactos ambientais e caracterização dos serviços ecossistêmicos do manguezal, estuário do rio Mamanguape: contribuições aos objetivos de desenvolvimento sustentável (ODS). 2023.
- CUENCA-OCAY, Ginalyn. Mangrove ecosystems' role in climate change mitigation. **Davao Research Journal**, v. 12, n. 2, p. 72-75, 2019.
- CUNHA-LIGNON, Marília. Dinâmica do manguezal no Sistema de Cananéia-Iguape, Estado de São Paulo–Brasil. **Universidade de São Paulo**, v. 10, 2001.
- CUNHA-LIGNON, M. *et al.* Análise da dinâmica de cobertura e uso da terra em áreas de manguezal da Baixada Santista (SP, Brasil) com o uso de imagens de satélite. *Revista da Gestão Costeira Integrada*, v. 11, n. 4, p. 401-412, 2011.
- DA SILVA, Leandro Félix *et al.* ANÁLISE DA EFICIÊNCIA DE CLASSIFICADORES SUPERVISIONADOS NO MAPEAMENTO DE USO DA TERRA E COBERTURA VEGETAL. **GEOFRONTER**, v. 1, n. 2, 2016.
- DA SILVA, Orlando Roque; GOMES, Marise de Barros Miranda. Impactos das atividades portuárias no sistema estuarino de Santos/Impacts of activities in port system estuarine Santos. **Revista Metropolitana de Sustentabilidade (ISSN 2318-3233)**, v. 2, n. 2, p. 64-81, 2012./
- DAVE, Chintan P.; JOSHI, Rahul; SRIVASTAVA, S. S. A survey on geometric correction of satellite imagery. **International Journal of Computer Applications**, v. 116, n. 12, 2015.
- DAVIS, Jeffrey M. Support vector machines for classification and quantitative analysis. **Microscopy and Microanalysis**, v. 20, n. S3, p. 656-657, 2014.

DE GROOT, Rudolf S.; WILSON, Matthew A.; BOUMANS, Roelof MJ. A typology for the classification, description and valuation of ecosystem functions, goods and services. **Ecological economics**, v. 41, n. 3, p. 393-408, 2002.

DIAS, André Pereira *et al.* Análise espacial aplicada à delimitação de áreas úmidas da planície de inundação do Médio Araguaia. 2014.

DO BRASIL, Atlas dos Manguezais; DO SUL, P. H. Instituto Chico Mendes de Conservação da Biodiversidade. **Brasília: Instituto Chico Mendes de Conservação da Biodiversidade**, 2018.

DRUSCH, Matthias *et al.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote sensing of Environment**, v. 120, p. 25-36, 2012.

ELLIS, J. *et al.* Effects of terrigenous sedimentation on mangrove physiology and associated macrobenthic communities. **Marine Ecology Progress Series**, v. 270, p. 71-82, 2004.

ESRI. *ArcGIS Pro: version 3.1*. Redlands, CA: Environmental Systems Research Institute, 2023. Disponível em: <https://www.esri.com/en-us/arcgis/products/arcgis-pro/overview>. Acesso em: 10 nov. 2025.

ESRI. Segment Mean Shift (Spatial Analyst). ArcGIS Pro Tool Reference. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/segment-mean-shift.htm>. Acesso em: 2 dez. 2025.

FATOURECHI, Mehrdad *et al.* Comparison of evaluation metrics in classification applications with imbalanced datasets. In: *Seventh International Conference on Machine Learning and Applications*, 2008. IEEE, p. 777-782.

FERRAZ, Vasty Veruska Rodrigues. *Abordagem pedagógica dos saberes populares dos(as) pescadores(as) e marisqueiros(as) do município de Cariacica-ES da perspectiva da educação ambiental crítica*. 2017.

FITZ, Paulo Roberto. **Geoprocessamento sem complicação**. Oficina de textos, 2018.

FIGUEIREDO, Divino. *Conceitos básicos de sensoriamento remoto*. **São Paulo**, 2005.

FLORENZANO, Teresa Gallotti. Imagens de satélite para estudos ambientais. In: **Imagens de satélite para estudos ambientais**. 2002. p. 97-97.

FRUEHAUF, Sandra Pavan. **Rhizophora mangle (Mangue vermelho) em áreas contaminadas de manguezal na Baixada Santista**. 2005. Tese de Doutorado. Universidade de São Paulo.

FU, Wenxue *et al.* Remote sensing satellites for digital earth. **Manual of digital earth**, v. 10, p. 978-981, 2020.

GONÇALVES, Manuel Vítor Portugal. *Análise de plantas de mangue como bioindicadoras da qualidade ambiental nas Ilhas de Tinharé e Boipeba, município de Cairu, Bahia, Brasil*. 2010.

HAGHIGHI, Sepand *et al.* PyCM: Multiclass confusion matrix library in Python. **Journal of Open Source Software**, v. 3, n. 25, p. 729, 2018.

HAYASHI, Sanae N. *et al.* Status of mangroves land use on the Brazilian Amazon coast from RapidEye imagery and GEOBIA approach. **Anais da Academia Brasileira de Ciências**, v. 95, n. 2, p. e20210468, 2023.

JUTZ, S.; MILAGRO-PEREZ, M. Pilar. Copernicus: the european earth observation programme. **Revista de Teledetección**, n. 56, p. V-XI, 2020.

KRENAK, Ailton. **Ideias para adiar o fim do mundo (Nova edição)**. Editora Companhia das letras, 2019.

KUMAR, Pushpam. **The economics of ecosystems and biodiversity: ecological and economic foundations**. Routledge, 2012.

DE LACERDA, Luiz Drude. **Mangrove ecosystems: function and management**. Springer Science ; Business Media, 2002.

LEITE, Nícia Bezerra Formiga. *Expansão urbana e seus efeitos sobre a mobilidade e acessibilidade avaliada com o auxílio dos sistemas de informação geográfica (SIG) em Teresina-PI*. 2013.

LIRA, Cristina *et al.* Sistemas de informação geográfica: Análise de Dados de Satélite. **Lisboa: DGRM**, 2016.

- LOVELAND, Thomas R.; DEFRIES, Ruth S. Observing and monitoring land use and land cover change. **Geophysical Monograph Series**, v. 153, p. 231-246, 2004.
- MOREIRA, Igor Antônio Gomes. **O espaço geográfico: geografia geral e do Brasil**. Atica, 1979.
- MILLENNIUM ECOSYSTEM ASSESSMENT, M. E. A. **Ecosystems and human well-being**. Washington, DC: Island press, 2005.
- NAGELKERKEN, I. S. J. M. *et al.* The habitat function of mangroves for terrestrial and marine fauna: a review. **Aquatic botany**, v. 89, n. 2, p. 155-185, 2008.
- DE OLIVEIRA, João Bertoldo. **Solos do Estado de São Paulo: descrição das classes registradas no mapa pedológico**. IAC, 1999.
- OLIVEIRA, P. Paleovegetação e paleoclimas do Quaternário do Brasil. **quaternário do Brasil**, p. 52-74, 2005.
- PAL, Mahesh. Random forest classifier for remote sensing classification. **International journal of remote sensing**, v. 26, n. 1, p. 217-222, 2005.
- PAIVA, Ana Paula Veras de. **Transformação da paisagem costeira: considerações sobre a conservação do município de São Sebastião-SP**. 2007. Tese de Doutorado. Universidade de São Paulo.
- PENHA, Thales Vaz. Detecção de áreas queimadas na Amazônia utilizando imagens de média resolução espacial, técnicas de Geobias e mineração de dados. **INPE: São José dos Campos**, p. 167, 2018.
- POLIDORIO, Airton Marco *et al.* Correção radiométrica de imagens multiespectrais CBERS e Landsat ETM usando atributos de reflectância e de cor. **Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, v. 12, p. 4241-4248, 2005.
- POURGHASEMI, Hamid Reza *et al.* Landslide susceptibility mapping using support vector machine and GIS at the Golestan Province, Iran. **Journal of Earth System Science**, v. 122, n. 2, p. 349-369, 2013.

PUSHPARAJ, Jagalingam; HEGDE, Arkal Vittal. Evaluation of pan-sharpening methods for spatial and spectral quality. **Applied Geomatics**, v. 9, n. 1, p. 1-12, 2017.

RABCHEVSKY, G. A. Remote sensing of the Earth's surface. **Journal of Remote Sensing (three parts) Vol**, v. 1, 1970.

RESENDE, Marcos Ribeiro; BERNUCCI, Liedi Légi Barianni; QUINTANILHA, José Alberto. Classificação híbrida: pixel a pixel e baseada em objetos para o monitoramento da condição da superfície dos pavimentos rodoviários. **Boletim de ciências geodésicas**, v. 18, p. 397-420, 2012.

RODRIGUEZ-GALIANO, Victor Francisco *et al.* An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS journal of photogrammetry and remote sensing**, v. 67, p. 93-104, 2012.

ROSS, J. L. S.; FIERZ, M. S. M. Geomorfologia da Baixada Santista e da plataforma continental adjacente. In: ALMEIDA, T. T.; ALMEIDA, R. A. P. (orgs.). *Geologia e recursos minerais do Estado de São Paulo*. São Paulo: CPRM, 2007. p. 1-20.

SANKALIYA, Alpesh R. IHS based pan sharpening with geo-image processing. 2015.

SCHAEFFER-NOVELLI, Yara. *Manguezal: ecossistema entre a terra e o mar*. 1995.

SCHAEFFER-NOVELLI, Yara *et al.* Variability of mangrove ecosystems along the Brazilian coast. **Estuaries**, v. 13, n. 2, p. 204-218, 1990.

SCHÖLKOPF, Bernhard; SMOLA, Alexander J. **Learning with kernels: support vector machines, regularization, optimization, and beyond**. MIT press, 2002.

SHAO, Guofan; TANG, Lina; LIAO, Jiangfu. Overselling overall map accuracy misinforms about research reliability. **Landscape Ecology**, v. 34, n. 11, p. 2487-2492, 2019.

SHUJRAH, Awais Ahmed; RAJPER, Samina; JUMANI, Awais Khan. Measurement of e-learners' level of interest in online course using support vector machine. **Indian Journal of Science and Technology**, v. 12, n. 40, p. 1-9, 2019.

SINAI, Lior. **Random forests**. Disponível em: <https://liorsinai.github.io/machine-learning/2020/09/29/random-forests.html>. Acesso em: 9 maio 2025.

SILVA, Edilma Fernandes da; OLIVEIRA, Jorge Eduardo Lins; SCHIAVETTI, Alexandre. Conhecimento Ecológico Local (CEL) na pesca artesanal da Reserva de Desenvolvimento Sustentável Estadual Ponta do Tubarão RN, Brasil. **Bol. Inst. Pesca (Impr.)**, p. 355-375, 2014.

SOUZA, Caroline A. *et al.* Biodiversidade e conservação dos manguezais: importância bioecológica e econômica. **Educação Ambiental sobre Manguezais. São Vicente: Unesp**, p. 16-56, 2018.

STROBL, Carolin; MALLEY, James; TUTZ, Gerhard. An introduction to recursive partitioning: rationale, application, and characteristics of classification and regression trees, bagging, and random forests. **Psychological methods**, v. 14, n. 4, p. 323, 2009.

SUGUIO, Kenitiro; MARTIN, Louis. Formações quaternárias marinhas do litoral paulista e sul fluminense=: Quaternary marine formations of the state of São Paulo and southern Rio de Janeiro. **Special Publication**, n. 1, p. 55, 1978.

VEIGA, Vinicius Mendes. *Análise comparativa do índice de vegetação por diferença normalizada (NDVI) e indicadores fitossociológicos em um manguezal contaminado por petróleo: estudo de caso no manguezal do rio Iriri, canal de Bertioga, Santos (SP)*. 2023.

VANNUCCI, Marta. **Os manguezais e nós: uma síntese de percepções**. Edusp, 2003.

VAPNIK, Vladimir. **The nature of statistical learning theory**. Springer science & business media, 2013.

WEAVER, Robert J.; STEHNO, Abigail L. Mangroves as coastal protection for restoring low-energy waterfront property. **Journal of Marine Science and Engineering**, v. 12, n. 3, p. 470, 2024.