

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS DA NATUREZA
CAMPUS LAGOA DO SINO

BIANCA JACOBÉ MARTINS SOARES

**DIVERSIDADE ESPECTRAL E SAZONALIDADE NO MAPEAMENTO DE
TIPOLOGIAS FLORESTAIS TROPICAIS USANDO SENTINEL-2**

Buri - SP
2025

BIANCA JACOBÉ MARTINS SOARES

**DIVERSIDADE ESPECTRAL E SAZONALIDADE NO MAPEAMENTO DE
TIPOLOGIAS FLORESTAIS TROPICAIS USANDO SENTINEL-2**

Trabalho de Conclusão de Curso
apresentado ao Centro de Ciências da
Natureza da Universidade Federal de São
Carlos, para obtenção do título de
Bacharel em Engenharia Ambiental.

Orientador: Paulo Guilherme Molin

Coorientador: Léo Eiti Haneda

Buri - SP

2025

Soares, Bianca Jacobe Martins

Diversidade espectral e sazonalidade no mapeamento de tipologias florestais tropicais usando Sentinel-2 / Bianca Jacobe Martins Soares -- 2025.
64f.

TCC (Graduação) - Universidade Federal de São Carlos,
campus Lagoa do Sino, Buri

Orientador (a): Paulo Guilherme Molin

Banca Examinadora: Aline Daniele Jacon, Angelica Faria
de Resende

Bibliografia

1. Sensoriamento Remoto. 2. Variabilidade espectral. 3.
Heterogeneidade florestal. I. Soares, Bianca Jacobe
Martins. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática
(SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Lissandra Pinhatelli de Britto - CRB/8 7539

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS DA NATUREZA
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL

Folha de Aprovação

Assinatura dos membros da comissão examinadora que avaliou e aprovou a Defesa de Trabalho de Conclusão de Curso do(a) candidato(a) Bianca Jacobe Martins Soares, realizada em 03/11/2025:

Prof. Dr. **Paulo Guilherme Molin** – Orientador(a)
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Dr^a Angelica Faria de Resende
ESALQ/USP

Dr^a Aline Daniele Jacon
UFSCar/CCN

DEDICATÓRIA

[Dedico esse trabalho a meus pais, Eber e Suzana, que são meu porto seguro, apoio, exemplo de resiliência, perseverança e amor; a minha avó Teresa e a minha avó Benedita pelo carinho, resistência e determinação; a minha família que me roubou diversos sorrisos e tornou esse percurso mais leve; aos meus amigos, que sempre me apoiaram e estiveram comigo nos melhores e piores momentos; e a Lagoa do Sino que me deu a oportunidade de viver momentos e conhecer pessoas incríveis “..Sou UFSCar, eu vim de lá, da Lagoa do Sino”. Que possamos ser perseverantes e florescer belos, tal qual aquele ipê que foi plantado por nós, o ipê amarelo. Obrigada turma 018..]

AGRADECIMENTO

Agradeço, primeiramente, a todas as orações, palavras de carinho, incentivo, abraços, amor e apoio que me sustentaram até aqui.

Agradeço aos meus pais, Eber e Suzana, por sempre me ouvirem, apoiarem, sonharem comigo esse sonho e me darem suporte para que ele pudesse ser realizado. Obrigada pelos sorrisos de recepção ao voltar pra casa e por serem meu porto seguro, onde quer que eu esteja. Amo vocês. Uma das frases que mais ouvi nessa jornada foi “Tudo tem o seu tempo” e, realmente pai, muitas coisas aconteceram durante esse processo e agora é o momento de encerrar esse ciclo.

Agradeço ao meu orientador Paulo Guilherme Molin, ao coorientador Léo Haneda e a todos que me ajudaram a desenvolver e entender esse projeto em seus detalhes, em especial: Matheus Fuza, Denner Augusto, Melodie Kern, Iuri Emmanuel, Gustavo Rossi e José Matheus. Agradeço também a Angélica Resende e a Aline Jacon por me inspirarem, por aceitarem o convite e por participarem desse momento.

Agradeço ao projeto NewFor (18/18416-2) e ao Estratégia Mata Atlântica - CCD-EMA (21/11940-0) pelo apoio estrutural financeiro, e por me permitirem entender melhor a diversidade das nossas florestas. Além de agradecer ao apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil (Processo nº 2021/11940-0), que contribuiu para a realização do trabalho.

Agradeço às pessoas que dividiram comigo não só um espaço, mas também o lugar que por um tempo chamei de casa. Obrigada, Fer e Aline, por me acolherem no meu primeiro ano de Lagoa do Sino. Obrigada, Felipe Tassi, Mateus Gomes, Mario Gabriel e Nicoli Gomes, por estarem comigo nos momentos bons e ruins, aprendi muito convivendo com vocês e tenho todos como uma família. Agradeço à Vitória Wuo por me receber em um dos períodos mais incertos que já vivemos. E agradeço à República Mulherama, meu lar, minha família, meu cantinho de paz e caos. Obrigada por me acolherem, por todos os aprendizados e por me ajudarem a chegar até aqui, cada sorriso e choro valeram a pena.

Agradeço àqueles que estiveram mais próximos nessa trajetória, seja no início ou no fim: Breno Carvalho, Luiz Fernando, Sofia Yura, Fernando Azevedo, Murilo Piccoli, Julia Andrade, Mayara, Isabelly, Vitor Gouveia, Malu (Ximi), Heloisa (Araki) e Ellen, obrigada por me ouvirem e não me deixarem desistir.

Agradeço à Márcia Floriano do Deeg, que me ajudou a ter a oportunidade de começar esse sonho, e à Juliana Dantas, por ser minha “segunda mãe” na Campina do Monte Alegre.

Agradeço ao CePE-Geo, CEPAE, LaCRE, NeseFi, ProForEXT, AAALS e BCF por me guiarem para o autoconhecimento e o encontro com meu propósito. Obrigada Bruna Renata, Malik Martins, Leticia Rossi, Jorge Pantoja, Beatriz Gonzalez, Márcio Silva, Débora Rother, Roberta Lovaglio, André Pereira e André Toledo por amizade, inspiração e confiança.

Agradeço à Geplant, que, nesses últimos meses, me deu a oportunidade de evoluir ainda mais e me inspirou a seguir buscando conhecimento e inovação. Obrigada, em especial, a Beatriz, Roberta, Ellen, Eduardo, Bazani, Leo, Gui, Renan, Thaís, Kika (Edmilda), Lais e Arthur. Obrigada por me acolherem, o presencial não é o mesmo sem vocês.

Deixo um agradecimento especial ao Aruanã, obrigada por me permitir ser parte do vale encantado.

Ao longo da minha jornada pessoal e profissional, graças às oportunidades que tive na Lagoa, conheci muitas pessoas dentro e fora da universidade. Agradeço a todos que, em algum momento, apareceram no meu caminho e me apoiaram para viver esse final de ciclo e o que virá depois.

“Onde meus talentos e paixões encontram as necessidades do mundo, lá está meu caminho, meu lugar” (Aristóteles).

RESUMO

A necessidade de monitoramento contínuo, escalável e de baixo custo das tipologias de florestas tropicais e dos ganhos de biodiversidade é crucial para cumprir os compromissos globais de Restauração de Paisagens Florestais (FLR) e compreender a dinâmica da floresta frente às mudanças climáticas. Diante da vasta extensão das florestas tropicais, o aprimoramento de sistemas de sensoriamento remoto (SR) de baixo custo é fundamental para superar barreiras técnicas no monitoramento. Em vista disso, este estudo teve como objetivo avaliar o potencial do satélite Sentinel-2A e 2B para replicar e escalar a metodologia de discriminação de classes florestais, originalmente testada com o sensor VEN μ S, em programas de FLR. A pesquisa buscou avaliar como a diversidade espectral e a influência da sazonalidade, contribuem para a classificação de tipologias florestais tropicais. O estudo foi conduzido na Estação Experimental de Ciências Florestais de Itatinga (EECFI-USP), analisando classes de floresta, tais como: florestas estacionais decíduas maduras (com mais de 80 anos de idade), regeneração natural, cerrado, áreas de restauração ativa (plantio misto de mudas nativas) e plantios homogêneos de Eucalyptus e Pinus. A partir de imagens geradas a partir de uma cena orbital de 20x20 metros de resolução espacial para o verão e uma para o período de inverno foi empregado o algoritmo *Random Forest*, para integrar diversos atributos biofísicos e estruturais: índices de vegetação avançados (NDMI, EVI, NBR, NDVI, NDVIRE e CLre1), camadas sazonais, delta verão e inverno, métricas de textura e indicadores de diversidade espectral (alfa e beta), derivados do pacote *biodivMapR*. Os resultados demonstraram a robustez da abordagem, com o modelo alcançando uma acurácia global superior a 80% e acurácia média entre classes de 86,2%. As camadas texturais, sazonais e de diversidade espectral se destacaram como os atributos mais importantes para a discriminação das classes, reforçando o papel da heterogeneidade estrutural do dossel. A maior variabilidade espectral, essencial para a diferenciação, foi observada em regeneração florestal e de restauração ativa. O estudo também confirmou o potencial das bandas Red-Edge e SWIR do Sentinel-2A e 2B na caracterização estrutural e fisiológica, estabelecendo um protocolo replicável e de baixo custo utilizando ferramentas livres (R e QGIS). Dessa forma, a metodologia proposta contribui significativamente para democratizar e ampliar o monitoramento contínuo de FLR, oferecendo subsídios técnicos essenciais para a gestão de paisagens florestais.

Palavras-chave: sensoriamento remoto; índices de vegetação; variabilidade espectral; *multispectral imager (MSI)*; heterogeneidade florestal; mudanças climáticas.

ABSTRACT

The need for continuous, scalable, and low-cost monitoring of tropical forest typologies and biodiversity gains is crucial to meet global Forest Landscape Restoration (FLR) commitments and to understand forest dynamics in the face of climate change. Given the vast extent of tropical forests, enhancing low-cost remote sensing (RS) systems is fundamental to overcoming technical barriers in monitoring. Therefore, this study aimed to evaluate the potential of the Sentinel-2A and 2B satellites to replicate and scale the forest class discrimination methodology, originally tested with the VEN μ S sensor, in FLR programs. The research sought to assess how spectral diversity and the influence of seasonality contribute to the classification of tropical forest typologies. The study was conducted at the Itatinga Forest Science Experimental Station (EECFI-USP), analyzing forest classes such as: mature seasonal deciduous forests (over 80 years old), natural regeneration, cerrado, active restoration areas (mixed planting of native seedlings), and homogeneous plantations of Eucalyptus and Pinus. Using images generated from a 20x20 meter spatial resolution orbital scene for summer and one for the winter period, the Random Forest algorithm was employed to integrate various biophysical and structural attributes: advanced vegetation indices (NDMI, EVI, NBR, NDVI, NDVIRE, and CLre1), seasonal layers, summer and winter delta, texture metrics, and spectral diversity indicators (alpha and beta), derived from the biodivMapR package. The results demonstrated the robustness of the approach, with the model achieving an overall accuracy of over 80% and an average cross-class accuracy of 86.2%. The textural, seasonal, and spectral diversity layers stood out as the most important attributes for class discrimination, reinforcing the role of canopy structural heterogeneity. The greatest spectral variability, essential for differentiation, was observed in forest regeneration and active restoration areas. The study also confirmed the potential of the Red-Edge and SWIR bands of Sentinel-2A and 2B in structural and physiological characterization, establishing a replicable and low-cost protocol using free tools (R and QGIS). Thus, the proposed methodology significantly contributes to democratizing and expanding the continuous monitoring of FLR, offering essential technical support for the management of forest landscapes.

Keywords: remote sensing; vegetation index; spectral variability; multispectral imager (MSI); forest heterogeneity; climate change.

LISTA DE FIGURAS

Figura 1: Perda de floresta tropical primária de 2002 a 2024.....	15
Figura 2: Infográfico MapBiomias: Evolução anual do uso e cobertura da terra (1985-2024), gerados a partir da coleção 10.....	19
Figura 3: Tipologias de vegetação disponíveis no mapa de cobertura vegetal natural estimada para o bioma Mata Atlântica em 2022.....	20
Figura 4: Comparação entre as bandas espectrais, a faixa de comprimento de onda e a resolução espacial de 4 satélites distintos (MODIS, Landsat-8, Sentinel-2 e Planet).....	22
Figura 5: Etapas de processamento realizadas através do pacote BiodivMapR.....	26
Figura 6: Localização da EECFI no estado de São Paulo e o conjunto amostral das classes trabalhadas no estudo.....	29
Figura 7: Composição RGB do conjunto de imagens dos períodos de verão e inverno utilizadas no estudo.....	34
Figura 8: Mapa dos índices de vegetação NDVI obtido no primeiro conjunto de variáveis utilizadas no estudo, correspondentes aos períodos de verão e inverno.....	39
Figura 9: Comparação entre o índice de vegetação EVI gerado inicialmente (a) e a camada de textura gerada a partir desse índice (b).....	40
Figura 10: Diversidade Alpha correspondente a estação inverno (a) e verão (b).....	41
Figura 11: Beta diversidade correspondente a estação inverno e verão.....	42
Figura 12: Curvas espectrais médias e amplitude de variância das diferentes classes de cobertura arbórea para o satélite Sentinel-2A nas estações de verão (a) e inverno (b).....	43
Figura 13: Comportamento espectral médio e faixa de variação das tipologias florestais no intervalo do visível ao infravermelho próximo correspondentes a verão (a) e inverno (b).....	44
Figura 14: Comparativo sazonal das curvas espectrais médias das classes de cobertura arbórea entre os períodos de verão e inverno.....	44
Figura 15: Matriz de confusão gerada a partir do modelo Random Forest.....	45
Figura 16: Gráfico de distribuição F1-Score.....	46
Figura 17: MDA geral, incluindo todas as variáveis.....	47
Figura 18: MDA filtrado, retirando as bandas espectrais para analisar a relevância das outras variáveis.....	47
Figura 19: Comparação entre o mapa temático final suavizado (a) gerado pelo modelo e o mapa com a classificação real (b) disponibilizada pela EECFI.....	50
Figura 20: Conjunto de diferentes combinações sazonais aplicadas às variáveis de verão.....	51
Figura 21: Comparação entre as matrizes de confusão deste estudo e da matriz publicada no artigo.....	51
Figura 22: Comparação entre os mapas temáticos finais suavizados, sendo: o mapa temático publicado no artigo (a) e o mapa temático gerado nesse projeto (b).....	52

LISTA DE TABELAS

Tabela 1: Descrição das classes de cobertura arbórea incluídas no estudo: Características estruturais e fotos ilustrativas.....	29
Tabela 2: Bandas do Satélite Sentinel-2 utilizadas no estudo.....	33
Tabela 3: Cálculo dos índices de vegetação a partir das bandas espectrais do satélite Sentinel-2.....	36
Tabela 4: Variáveis utilizadas.....	38
Tabela 5: Combinação sazonal para variáveis de verão e inverno.....	48

LISTA DE SIGLAS

AAALS – Associação Atlética Acadêmica Lagoa do Sino
BCF – Bateria Comando Federal
BSoil - Solo exposto
CCD – Centro de Ciência para o Desenvolvimento
CePE-Geo – Centro de Pesquisa e Extensão em Geotecnologias
CEPAE – Centro de Extensão e Pesquisa em Águas e Efluentes
CLre1 – *Red Edge Chlorophyll Index*
DeEG – Departamento de Ensino de Graduação
EucaMono - Monocultura de Eucalipto
EVI – *Enhanced Vegetation Index*
FLR - Forest Landscape Restoration
LaCRE – Laboratório de Conservação e Restauração Florestal
MSI – *Multispectral Imager*
NBR – *Normalized Burn Ratio*
NDMI – *Normalized Difference Moisture Index*
NDVI – *Normalized Difference Vegetation Index*
NDVIRE – *Red-Edge Normalized Difference Vegetation Index*
NIR - Infravermelho próximo
NESEFi – Núcleo de Estudos em Sociologia Econômica e das Finanças
OGFor - Floresta conservada semidecidual
PCA – *Principal Component Analysis*
PineMono - Monocultura de Pinus
ProforEXT – Programa de Formação em ATER e Assistência Técnica à Extensão Rural
SGFor - Floresta secundária semidecidual
SGSav - Vegetação secundária de Savana/Cerrado
SPCA – *Stacked Principal Component Analysis*
YRest - Plantio de restauração inicial
SGFor - Floresta secundária semidecidual

SUMÁRIO

1. INTRODUÇÃO	15
2. FUNDAMENTAÇÃO TEÓRICA	18
2.1. CLASSIFICAÇÃO DAS FLORESTAS TROPICAIS	18
2.2. SENSORIAMENTO REMOTO COM SENTINEL-2A	20
2.2.1. Especificações do Sensor MSI e as Bandas Red-Edge e SWIR	21
2.2.2. Desafio Tropical: Cobertura de Nuvens e Composição Temporal	22
2.3. EXTRAÇÃO DE ATRIBUTOS PARA CLASSIFICAÇÃO DE TIPOLOGIAS	23
2.3.1. Componente Espectral I: Índices de Vegetação	23
2.3.2. Componente Sazonal: Camadas Delta e Métricas Fenológicas	24
2.3.3. Componente Estrutural: Métricas de Textura (GLCM)	25
2.3.4. Componente Avançado: Métricas De Diversidade Espectral (SD) Como Proxy Estrutural/Funcional	25
2.4. MODELAGEM E CLASSIFICAÇÃO COM APRENDIZADO DE MÁQUINA	27
2.4.1. O Algoritmo Random Forest (RF) E Suas Vantagens	27
2.4.2. Análise Da Importância De Variáveis	27
3. MATERIAIS E MÉTODOS	28
3.1. ÁREA DE ESTUDO E AMOSTRAGEM	28
3.2. BANCO DE DADOS	32
3.3. SOFTWARES UTILIZADOS	34
3.4. VARIÁVEIS	35
3.4.1. Índices De Vegetação	35
3.4.2. Camadas De Textura	36
3.4.3. Camadas Delta	37
3.4.4. Camada De Diversidade Espectral	37
3.5. ANÁLISE DE AMOSTRAGEM	38
4. RESULTADOS E DISCUSSÃO	39
4.1. CARACTERIZAÇÃO DAS CLASSES DE COBERTURA ARBÓREA	39
4.1.1. Índices De Vegetação	39
4.1.2. Camadas De Textura	39
4.1.3. Diversidade Espectral: BiodivmapR	40
4.1.3.1. Índice Shannon: Alpha Diversidade	40
4.1.3.2. Beta Diversidade	41
4.1.4. Comportamento Espectral	42
4.2. CLASSIFICAÇÃO DAS CLASSES DE COBERTURA ARBÓREA	45
4.2.1. Matriz de confusão	45
4.2.2. F1 score	46
4.2.3. Mean Decrease Accuracy (MDA)	46
4.2.4. Combinação com diferentes atributos	48
4.3. MAPA TEMÁTICO	49
5. COMPARAÇÃO COM OS RESULTADOS OBTIDOS NO ARTIGO DE HANEDA50	

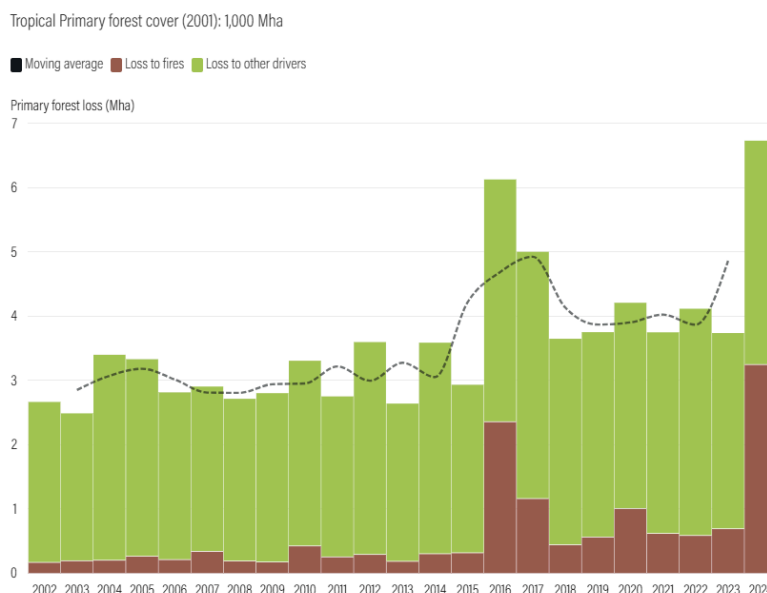
5.1. Matriz De Confusão	51
5.2. Comparação do Mapa Temático Final	51
6. ANALISANDO A METODOLOGIA APLICADA	53
7. CONSIDERAÇÕES FINAIS	54
REFERÊNCIAS	55

1. INTRODUÇÃO

O termo "floresta tropical" em plataformas de busca, está comumente associado a palavras como "biodiversidade", "clima", "chuva" e "vegetação". O monitoramento e a gestão eficiente de florestas tropicais são fundamentais para a manutenção da interconexão crítica entre a conservação da biodiversidade e o enfrentamento das mudanças climáticas (Chazdon et al., 2025). Contudo, pela sua vasta extensão global, aprimorar e aplicar o monitoramento em larga escala e obter dados confiáveis com rapidez e efetividade, se torna um desafio (Silva, 2015).

Segundo dados disponibilizados pela plataforma Global Forest Watch, no ano de 2024, os trópicos perderam cerca de 6,7 milhões de hectares de floresta tropical primária, 80% a mais do que quando comparados ao ano de 2023 (GFW, 2025) (Figura 1). A ocorrência de incêndios mais disseminados devido à intensificação das mudanças climáticas se intensificou em 2024; contudo, a perda de florestas primárias não relacionada a incêndios também apresentou um aumento de 14%. Embora as preocupações com o desmatamento e a perda de florestas primárias seja global, faz-se necessária a preocupação e concentração de estudos e ações para com as florestas localizadas nos trópicos, locais em que ocorre 94% do desmatamento do planeta (GFW, 2025).

Figura 1: Perda de floresta tropical primária de 2002 a 2024.



Fonte: GFW, 2025.

Nesse contexto, visando fortalecer os compromissos internacionais voltados à restauração de ecossistemas tropicais, foram estabelecidas metas globais de Restauração de

Paisagens Florestais (FLR, do inglês *Forest Landscape Restoration*). Buscando operacionalizar essas metas, iniciativas como o Desafio de Bonn (*Bonn Challenge*), propõe restaurar 150 milhões de hectares de áreas degradadas e desmatadas até 2020 e 350 milhões até 2030. Para complementar esse movimento, iniciativas regionais, como a Iniciativa 20x20 na América Latina, atuam em conjunto com o Desafio de Bonn, ampliando a cooperação e o alcance das ações de restauração (Initiative 20x20, [s.d.]; Bonn Challenge, 2020).

Considerando o cenário brasileiro, determinada pela Comissão Nacional para Recuperação da Vegetação Nativa (Conaveg), em 2023, foi definida a principal meta para de recuperação vegetação nativa, tendo como objetivo restaurar 12 milhões de hectares de vegetação nativa até 2030 (Brasil, 2025). Para atingir essa meta, é possível destacar movimentos como o Pacto pela restauração da Mata Atlântica que, por meio da integração de representantes dos três setores da sociedade (governo, empresas e sociedade civil) está restaurando, no país, aproximadamente 113 mil hectares (Pacto Pela Restauração da Mata Atlântica, 2024). Embora esses esforços tenham progredido, o monitoramento e a implementação dessas iniciativas enfrentam barreiras que resultam em um avanço lento, em razão de diferentes impasses institucionais, técnicos e financeiros, o que exige métodos modernos e contínuos de coleta de dados (IKI, 2023; IUCN, 2022, p 6).

Em vista disso, o sensoriamento remoto se destaca como uma ferramenta essencial, pois permite o acompanhamento à distância e em larga escala das mudanças ambientais e da cobertura florestal (Silva et al., 2019). Mais do que apenas monitorar a presença ou ausência de floresta, torna-se necessário distinguir entre diferentes tipologias florestais (por exemplo, florestas primárias, secundárias em diferentes estágios sucessionais, e plantios de restauração) (Chazdon et al., 2025). Esta distinção é fundamental, pois cada tipologia possui uma estrutura, composição e funcionalidade ecológica única (Keith D.A. et al., 2022). A capacidade de mapear e classificar essas tipologias com precisão é a base para a quantificação de serviços ecossistêmicos específicos, como o estoque de carbono, a regulação hídrica e a conservação da biodiversidade, evidenciando a importância prática e a relevância deste tipo de estudo para a gestão ambiental e a formulação de políticas públicas (Achary, 2019).

Para a avaliação da diversidade da vegetação e o monitoramento florestal, sensores ópticos (sensores multi e hiperespectrais, ou seja, sensores passivos) são frequentemente utilizados para calcular índices espectrais que correlacionam a refletância da superfície com atributos biofísicos da vegetação (Brançalion; Vieira; Celentano, 2024). Sensores populares de alta a média resolução espacial, como o Sentinel-2 (programa Copernicus da ESA),

forneem dados cruciais para essa análise. Com suas 13 bandas espectrais e alta resolução espacial e temporal, o Sentinel-2 permite a detecção de variações sutis na cobertura florestal, essenciais para o mapeamento de tipologias tropicais (European Union, 2025).

A capacidade do sensor MultiSpectral Instrument (MSI) de capturar dados em bandas estratégicas, como o Red-Edge e o Infravermelho de Ondas Curtas (SWIR, em inglês *Short Wave Infrared*), permite uma análise aprofundada da composição biofísica da vegetação (Chaves; Picoli; Sanches, 2020). Considerando a diversidade espectral, derivada do comportamento da reflectância em múltiplas bandas, tem sido progressivamente reconhecida como um proxy eficaz para a diversidade funcional e estrutural das florestas tropicais, conforme demonstram estudos recentes (Tan, 2025; Aguirre-Gutiérrez, 2025).

A metodologia adotada neste trabalho baseia-se nos princípios estabelecidos por Haneda et al. (2023), que exploraram o comportamento espectral e a diversidade de classes de cobertura arbórea em programas de FLR utilizando o microsatélite VEN μ S, que possui cobertura restrita a pequenas áreas do planeta. A chave para a discriminação eficaz dessas classes reside na utilização de índices de vegetação avançados, que maximizam a sensibilidade às variações de pigmentos e de estrutura foliar. O uso de índices como o *Enhanced Vegetation Index* (EVI), que mitigam a saturação em áreas densas, e, principalmente, os índices de Red-Edge (como CLre1, sensível à dinâmica espectral da clorofila), torna-se fundamental. Por explorarem a transição entre o vermelho e a faixa espectral do infravermelho próximo, esses índices de vegetação permitem uma diferenciação mais precisa entre florestas conservadas, secundárias e plantios de restauração, estruturas florestais que possuem assinaturas espectrais sutilmente distintas (Nasiri, 2025).

Diante disso, este estudo vem ao encontro da necessidade de melhorar e ampliar as estratégias de monitoramento, além de contribuir com as aplicações em larga escala. Apesar da eficácia demonstrada pela abordagem de Haneda et al. (2023), a replicação da metodologia com o satélite Sentinel-2A e B representa uma importante lacuna de pesquisa a ser preenchida. O sensor VEN μ S possui características espectrais e radiométricas específicas, e a transposição de uma metodologia bem-sucedida para o Sentinel-2, um sensor de acesso livre e globalmente disponível, é fundamental para democratizar e escalar o monitoramento de FLR. A comparação dos resultados obtidos com o Sentinel-2A e os dados de referência do VEN μ S permitiu avaliar o potencial de acurácia do Sentinel 2A e B (sensores do programa Copernicus) para esta aplicação específica. Em complemento, a escolha por ferramentas de código aberto e software livre, como o Google Earth Engine (GEE), o R e o QGIS, reforça a

relevância prática do estudo, oferecendo um protocolo replicável e de baixo custo para gestores ambientais e pesquisadores em todo o mundo.

2. FUNDAMENTAÇÃO TEÓRICA

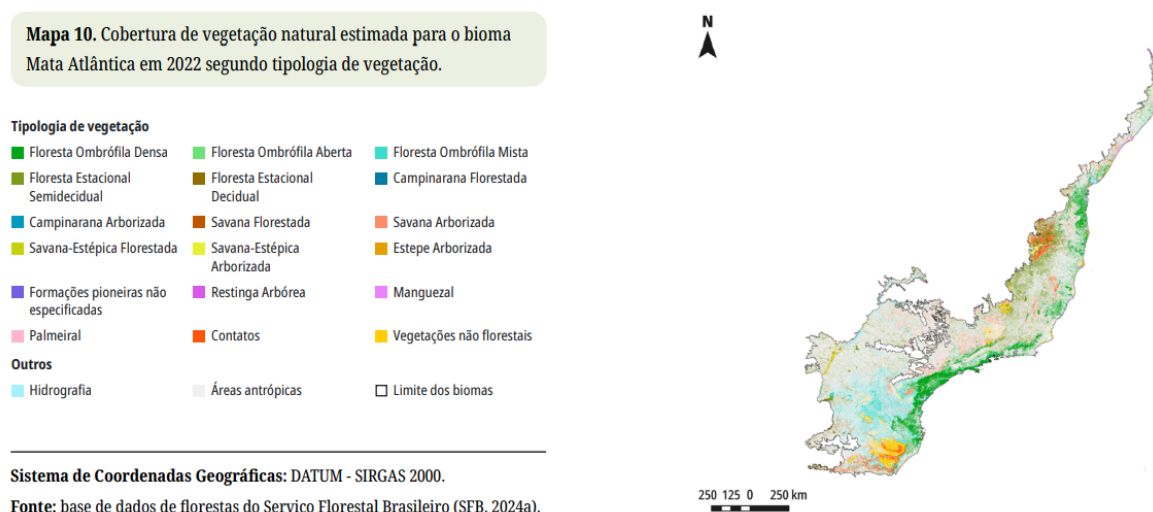
2.1. CLASSIFICAÇÃO DAS FLORESTAS TROPICAIS

As florestas tropicais representam um dos biomas mais antigos, complexos e diversos do planeta, cobrindo aproximadamente 45% da área florestal total da Terra (Mattos, 2021). Caracterizadas por se desenvolverem na zona intertropical, entre os trópicos de Câncer e de Capricórnio, estas formações vegetais são tipicamente associadas a climas quentes e úmidos, apresentando a maior produtividade e a maior variedade de espécies do planeta (Cooper, 2022). A classificação destas florestas é multifacetada, mas a distinção mais fundamental reside em sua resposta ao regime hídrico (Costa et al., 2023). Tradicionalmente, as florestas tropicais são subdivididas em Florestas Tropicais Úmidas (ou Pluviais), que recebem chuvas regulares ao longo do ano, e Florestas Tropicais Sazonais (ou Secas), que experimentam uma estação seca acentuada, influenciando diretamente a fenologia da vegetação (INTERFAITH RAINFOREST INITIATIVE, 2019). Globalmente, cerca de 40% das florestas tropicais se enquadram na definição de florestas tropicais sazonalmente secas, distribuídas em diversas regiões, incluindo a América do Sul e Central (Silva et al., 2024). Compreender as particularidades dessas tipologias, especialmente a variação sazonal, é necessário para o mapeamento acurado e a gestão eficaz dos recursos florestais.

Apesar da importância de classificar as tipologias florestais com base em fatores naturais como o regime hídrico, a realidade atual das paisagens tropicais é marcada pela intensificação da agricultura, que tem reconfigurado drasticamente as paisagens florestais. Onde antes existiam extensos contínuos de florestas primárias, hoje predomina um mosaico complexo de usos, composto por fragmentos florestais de diferentes idades, tamanhos e históricos de perturbação (Coutinho, 2016). Essa fragmentação, impulsionada por distúrbios antrópicos contínuos, quando não bem planejada e administrada, ameaça diretamente a biodiversidade e a provisão de serviços ecossistêmicos essenciais (Ma et al., 2023).

Nesse cenário de transformação, as florestas secundárias assumem um papel central na conservação. Elas surgem da regeneração natural em áreas agrícolas abandonadas e, atualmente, representam a forma dominante de vegetação nativa em muitas paisagens tropicais modificadas pelo homem (Moreno, 2019). Embora as florestas primárias possuam um valor de conservação insubstituível, sua presença é cada vez mais rara. Consequentemente, as florestas secundárias tornam-se os principais refúgios da

Figura 3: Tipologias de vegetação disponíveis no mapa de cobertura vegetal natural estimada para o bioma Mata Atlântica em 2022



Fonte: MMA, 2024.

Adicionalmente, iniciativas como o projeto NewFor (FAPESP:18/18416-2) aprofundam essa classificação ao focar nas chamadas "novas florestas", que englobam não apenas a regeneração natural, mas também plantios de restauração e sistemas agroflorestais (Brançalion, et al, 2019). Essa distinção é crucial, pois, embora os programas de restauração ampliem a cobertura de novas florestas, a destruição contínua de florestas antigas (*old-growth*), ecossistemas maduros e com alta complexidade estrutural, compromete a resiliência do bioma em longo prazo (Magnago, 2018). Tal abordagem evidencia que a classificação funcional das florestas, baseada em sua origem e idade, é necessária para avaliar o verdadeiro balanço entre perdas e ganhos florestais. As florestas recém-estabelecidas demandam um tempo considerável para desenvolver os atributos ecológicos e os serviços ecossistêmicos providos pelas florestas conservadas (González-Chaves et al., 2023). Dito isso, para realizar o monitoramento contínuo e em larga escala dessas tipologias florestais complexas, o uso de tecnologias de sensoriamento remoto é indispensável.

2.2. SENSORIAMENTO REMOTO COM SENTINEL-2A

O sensoriamento remoto é uma das ferramentas mais importantes da ciência ambiental moderna, pois permite obter informações sobre a superfície terrestre sem contato direto, utilizando sensores embarcados em satélites ou aeronaves (Chen, 2024). Sua aplicação na análise de ecossistemas florestais é especialmente relevante em regiões tropicais, onde a extensão e a complexidade das formações vegetais tornam inviável o monitoramento apenas por observações de campo. A evolução dos sensores multiespectrais e hiperespectrais ampliou o potencial de investigação, permitindo análises detalhadas da estrutura e da

dinâmica florestal em múltiplas escalas espaciais e temporais (Almeida et al., 2025).

Os dois satélites gêmeos Sentinel 2A e 2B, integrantes do programa europeu Copernicus, foram projetados especificamente para observações ambientais e de uso da terra, destacando-se por sua resolução espacial de 10 a 20 metros e revisitamento de aproximadamente cinco dias (ESA, 2024). O sensor MSI (Multispectral Instrument) capta a radiação refletida em 13 bandas espectrais, abrangendo desde o visível até o infravermelho de ondas curtas (SWIR) (ESA, 2024). Essa ampla cobertura espectral permite distinguir diferenças sutis na composição e na estrutura da vegetação, tornando o Sentinel-2A e B particularmente adequado para estudos de mapeamento florestal em ambientes tropicais, onde a diversidade e a sazonalidade são elevadas (COPERNICUS, [s.d]).

Além de sua alta resolução, o Sentinel-2 se destaca por disponibilizar gratuitamente dados com calibração radiométrica rigorosa e correções atmosféricas padronizadas, o que o torna acessível a pesquisadores e gestores ambientais (ESA, 2023). Para este trabalho, essas características são fundamentais, pois possibilitam a análise comparativa de tipologias florestais ao longo de diferentes períodos sazonais, assegurando a consistência temporal necessária à investigação da diversidade espectral e da dinâmica da vegetação tropical.


2.2.1. Especificações do Sensor MSI e as Bandas Red-Edge e SWIR

O sensor MSI do Sentinel-2A e B foi concebido para aprimorar a capacidade de discriminação da vegetação, especialmente por meio das bandas Red-Edge (B5, B6, B7 e B8A) e das bandas de infravermelho de ondas curtas (SWIR) (B11 e B12). As bandas Red-Edge situam-se na transição entre o vermelho e o infravermelho próximo, região espectral altamente sensível à concentração de clorofila e à estrutura interna das folhas (Figura 4) (Segarra, et al., 2020). Essa sensibilidade torna possível detectar variações sutis na condição fisiológica da vegetação, que muitas vezes não são perceptíveis em bandas tradicionais, como o vermelho e o NIR, permitindo uma melhor diferenciação entre espécies e estágios sucessionais (Zhang et al., 2025).

As bandas SWIR, de infravermelho de ondas curtas, por sua vez, estão relacionadas à absorção de água na vegetação e no solo, sendo amplamente utilizadas para estimar o teor de umidade e para detectar distúrbios como queimadas e degradação (Assis, 2019). Variando de 1610 nm (B11) e 2190 nm (B12) as bandas SWIR, a característica dessas bandas se apresenta mais sensível às mudanças sazonais no conteúdo de umidade, tanto nas folhas quanto no substrato. A integração das bandas Red-Edge e SWIR oferece, portanto, uma visão mais completa da vegetação, combinando aspectos biofísicos e estruturais (Figura 4) (Segarra, et

al, 2020). Essa combinação é essencial em estudos que buscam compreender o funcionamento ecológico das florestas, como é o caso deste trabalho, que explora a diversidade espectral como um indicador da heterogeneidade funcional e estrutural do dossel da vegetação tropical.

Figura 4: Comparação entre as bandas espectrais, a faixa de comprimento de onda e a resolução espacial de 4 satélites distintos (MODIS, Landsat-8, Sentinel-2 e Planet)



Fonte: Segarra et al.,2020.

Neste estudo, o termo “infravermelho próximo” será empregado em dois contextos distintos. O primeiro refere-se à banda B08, renomeada como NIR, utilizada na etapa de construção da metodologia e na apresentação dos resultados. O segundo ocorre quando o termo aparece acompanhado da expressão “faixa espectral”, designando o intervalo de comprimentos de onda correspondente ao infravermelho próximo, conforme ilustrado na Figura 4.

2.2.2. Desafio Tropical: Cobertura de Nuvens e Composição Temporal

As regiões tropicais apresentam um desafio recorrente ao sensoriamento remoto óptico: a elevada frequência de nuvens, neblina e sombras, que comprometem a obtenção de imagens limpas (Osco, 2023). Essa limitação exige o uso de técnicas de composição multitemporal, nas quais múltiplas cenas são combinadas para gerar produtos livres de nuvens, mantendo a representatividade das estações do ano. O Sentinel-2, devido à sua curta frequência de revisita, oferece uma densidade temporal adequada para a geração dessas composições (Rodríguez-puerta, 2024).

A criação de mosaicos sazonais, calculados a partir de medianas ou percentis, é essencial para reduzir ruídos atmosféricos e garantir que as diferenças espectrais observadas

reflitam variações fenológicas reais (Sorrini, 2022; ESA, 2023). Esse procedimento confere consistência à comparação entre períodos como verão e inverno, assegurando que as variações observadas sejam de origem biológica, e não artefactual. Essa abordagem é amplamente recomendada em estudos de fenologia tropical e monitoramento de restauração (Pitikanen et al. (2024).

Para este trabalho, o controle da cobertura de nuvens é fundamental, pois a confiabilidade dos índices de vegetação e da diversidade espectral depende da qualidade radiométrica das imagens. A utilização de composições sazonais permite representar as fases fenológicas típicas das florestas tropicais, criando uma base sólida para a análise da sazonalidade espectral e para a distinção de tipologias florestais ao longo do ciclo anual.

2.3. EXTRAÇÃO DE ATRIBUTOS PARA CLASSIFICAÇÃO DE TIPOLOGIAS

A extração de atributos espectrais é a etapa que transforma as imagens multiespectrais em variáveis quantitativas capazes de representar aspectos biofísicos da vegetação (Kacic, 2022). Esses atributos traduzem diferentes dimensões do dossel como a pigmentação, a estrutura, o teor de água e a textura, por meio de métricas que permitam análise estatística e de modelagem.

A importância desta etapa reside no fato de que a assinatura espectral bruta, isoladamente, pode ser insuficiente para distinguir tipologias florestais complexas, devido à sobreposição de respostas entre espécies e estágios sucessionais (Haneda et al., 2023). A integração de múltiplos atributos permite capturar tanto o comportamento espectral instantâneo quanto sua variação temporal e espacial, enriquecendo a base de informações para a classificação. Essa abordagem integrativa está alinhada com as tendências contemporâneas em ecologia de paisagens e sensoriamento remoto aplicado à biodiversidade (Haneda et al, 2023).

Assim, a extração de atributos multiespectrais e multitemporais fundamenta a compreensão da diversidade espectral, que é o núcleo conceitual deste trabalho. Cada grupo de métricas contribui para uma dimensão distinta: os índices de vegetação expressam a condição fisiológica, as camadas delta revelam a sazonalidade fenológica e as métricas de textura descrevem a heterogeneidade estrutural da floresta.

2.3.1. Componente Espectral I: Índices de Vegetação

Os índices de vegetação são combinações matemáticas entre bandas espectrais que

visam realçar a resposta da vegetação em relação ao solo e a outros elementos da paisagem. O NDVI (*Normalized Difference Vegetation Index*) é o mais amplamente utilizado, refletindo a proporção de biomassa verde por meio da diferença entre as bandas do vermelho e do infravermelho próximo (Liu et al., 2024). Outros índices, como o EVI (*Enhanced Vegetation Index*), incorporam correções atmosféricas e reduzem a saturação em áreas de alta densidade foliar, sendo úteis em florestas densas. Eles também respondem às variações sazonais, essenciais para diferenciar áreas de vegetação vigorosa, em regeneração ou sob estresse hídrico, caracterizando os ecossistemas tropicais, tornando-se ferramentas fundamentais para avaliar a dinâmica fenológica das tipologias florestais (Crespo-antia et al., 2024).

A aplicação conjunta de diferentes índices amplia a capacidade de interpretação dos dados e melhora a acurácia das classificações (Haneda et al., 2023). Essa abordagem multiespectral é teoricamente sólida, pois reflete a natureza multifatorial do comportamento espectral da vegetação determinado por pigmentos, estrutura, teor de água e geometria do dossel. Assim, os índices de vegetação constituem o primeiro eixo de análise da diversidade espectral neste estudo.

2.3.2. Componente Sazonal: Camadas Delta e Métricas Fenológicas

Embora os valores absolutos dos índices de vegetação em um único momento possam não ser suficientes para distinguir tipologias estruturalmente semelhantes (exemplo: áreas de restauração densa e floresta conservada), a variação desses índices ao longo do ciclo anual oferece uma dimensão de classificação superior. Portanto, a extração de camadas Delta se torna um pilar metodológico (Haneda et al., 2023).

A sazonalidade é um componente intrínseco da ecologia tropical e influencia diretamente o comportamento espectral da vegetação (Ramos, 2023). As chamadas camadas delta representam a variação de um mesmo índice entre duas estações (por exemplo, verão e inverno), funcionando como um indicador quantitativo da amplitude fenológica. Essa métrica permite identificar áreas de vegetação perene, que apresentam pequenas variações, e áreas caducifólias ou de restauração recente, com variações espectrais mais expressivas (Dronova, 2022).

No contexto deste trabalho, as camadas Delta desempenham papel central na compreender como a variabilidade temporal influencia a diversidade espectral e a classificação de tipologias florestais. Elas evidenciam o dinamismo ecológico das florestas tropicais e contribuem para distinguir formações das classes de floresta e solo exposto com

assinaturas espectrais semelhantes, mas padrões sazonais distintos.

2.3.3. Componente Estrutural: Métricas de Textura (GLCM)

Complementarmente à informação temporal (camadas Delta), a heterogeneidade estrutural da floresta, que se manifesta como padrões de sombra, dossel e sub-bosque, pode ser capturada por meio de métricas de textura. Estas métricas são fundamentais para refinar a distinção entre tipologias, especialmente aquelas que compartilham espectros semelhantes, mas diferem na arquitetura, como uma floresta em estágio avançado de regeneração ou conservação e um plantio comercial (Farwell, 2021).

As métricas de textura expressam a heterogeneidade espacial da vegetação e são amplamente utilizadas para inferir a estrutura do dossel. Por meio da análise de variações locais de brilho ou reflectância é possível identificar padrões de sombra, altura e irregularidade da copa. Texturas elevadas geralmente indicam dosséis complexos e heterogêneos, típicos de florestas conservadas, enquanto valores baixos são característicos de áreas homogêneas, como plantações e pastagens (Kim, et al., 2009) .

A importância da textura no mapeamento florestal está na sua capacidade de representar aspectos estruturais que os índices espectrais não capturam (Conto, 2024). Enquanto índices como NDVI e EVI refletem propriedades fisiológicas, as métricas de textura revelam diferenças físicas de arquitetura e de organização do dossel. Essa complementaridade teórica reforça o papel da textura como variável-chave na análise da diversidade estrutural (Farwell, 2021).

Diversos estudos destacam que a integração de métricas de textura com índices de vegetação aumenta significativamente a precisão de classificações temáticas, especialmente em ambientes de alta complexidade (Farwell, 2021; Haneda et al., 2023; Kim, et al., 2009). Para este trabalho, essas métricas oferecem suporte teórico essencial à caracterização da heterogeneidade intra-classe, contribuindo para a diferenciação de tipologias florestais tropicais em estágios sucessionais variados.

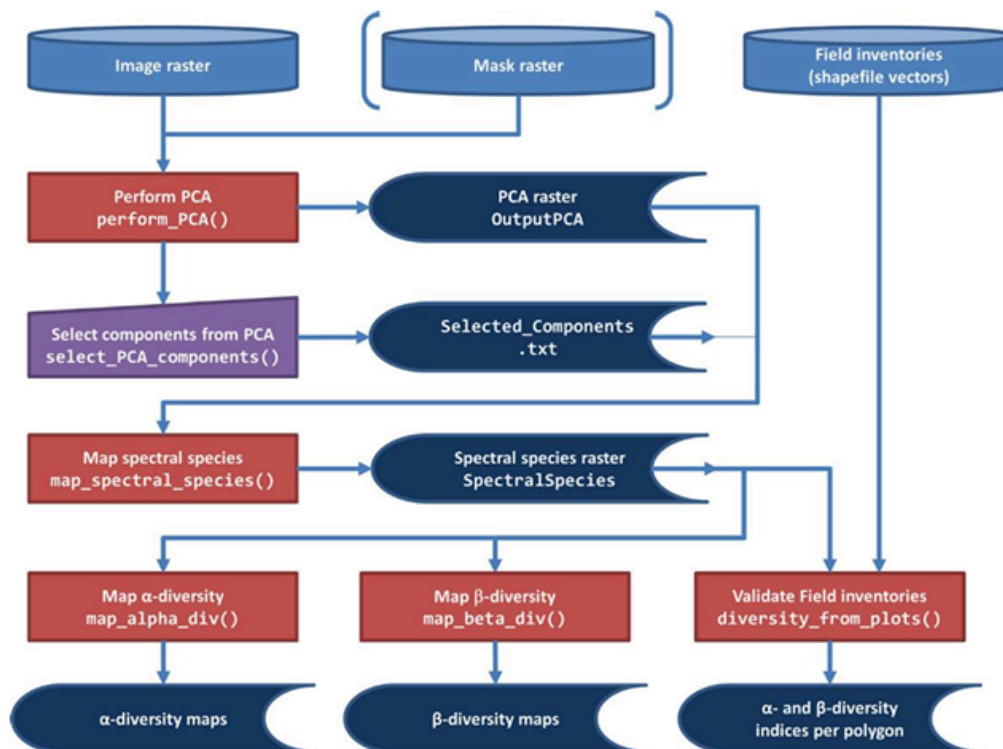
2.3.4. Componente Avançado: Métricas De Diversidade Espectral (SD) Como Proxy Estrutural/Funcional

A diversidade espectral (SD, em inglês *Spectral Diversity*) é uma métrica desenvolvida a partir do princípio de que a variabilidade espectral capturada por sensores remotos reflete a diversidade biológica e funcional de um ecossistema (Rossi, et al., 2021). Essa ideia, conhecida como *Spectral Variation Hypothesis*, sustenta que áreas com maior

variação nas assinaturas espectrais apresentam também maior heterogeneidade de espécies, estruturas e funções ecológicas (Kim et al., 2009). A SD expressa, portanto, um conceito de biodiversidade observada indiretamente, por meio da variação nos valores de reflectância entre pixels vizinhos, funcionando como um indicador da complexidade ecológica das paisagens florestais tropicais (Ribeiro et al., 2024).

Nos últimos anos, o conceito de diversidade espectral foi consolidado operacionalmente por meio do pacote `biodivMapR`, desenvolvido por Féret e colaboradores, que possibilita calcular métricas de diversidade alfa e beta a partir de imagens multiespectrais e hiperespectrais (Féret et al., 2022). Esse pacote implementa uma sequência metodológica que inclui a redução de dimensionalidade (geralmente via PCA ou SPCA), a classificação de espécies espectrais por meio de algoritmos de agrupamento (como o k-means) e o cálculo de índices de diversidade baseados em entropia de Shannon, variância espectral e dissimilaridade entre janelas (Figura 5). A aplicação do `biodivMapR` tem se destacado em estudos de monitoramento florestal por traduzir a teoria ecológica da diversidade espectral em produtos espaciais quantitativos, capazes de representar padrões de heterogeneidade funcional na vegetação (Féret et al., 2022).

Figura 5: Etapas de processamento realizadas através do pacote `BiodivMapR`



Fonte: Féret et al., 2019.

Em contextos tropicais, o uso do `biodivMapR` é especialmente relevante, pois permite

explorar integralmente a riqueza espectral do Sentinel-2, cujas bandas Red-Edge e SWIR são sensíveis à variação de pigmentos, água e estrutura do dossel. As métricas de diversidade alfa (heterogeneidade local) e beta (diferença entre comunidades espectrais) oferecem uma visão complementar aos índices de vegetação e às métricas de textura, integrando dimensões funcionais e estruturais da paisagem. Assim, a diversidade espectral representa uma abordagem teórica e aplicada de ponta no sensoriamento remoto, permitindo avaliar o estado ecológico e a maturidade estrutural das florestas tropicais de forma não destrutiva, repetitiva e em larga escala (Matunaga, 2022; Dutrieux et al., 2024).

2.4. MODELAGEM E CLASSIFICAÇÃO COM APRENDIZADO DE MÁQUINA

2.4.1. O Algoritmo *Random Forest* (RF) E Suas Vantagens

O *Random Forest* (RF) é um algoritmo de aprendizado de máquina baseado em múltiplas árvores de decisão, que combina resultados por meio de votação para produzir classificações mais estáveis e precisas. Sua principal vantagem está na capacidade de lidar com conjuntos de dados complexos e de alta dimensionalidade, sem pressupor distribuições estatísticas específicas (EMBRAPA, 2015). Essa flexibilidade o torna amplamente utilizado em estudos de sensoriamento remoto, principalmente em mapeamentos florestais que envolvem grande número de variáveis espectrais, sazonais e estruturais.

Do ponto de vista teórico, o RF é considerado um método não paramétrico, capaz de modelar relações não lineares entre os atributos e as classes de interesse (Belgiu, Drăguț 2016). Em estudos ambientais, ele apresenta bom desempenho mesmo em contextos com variáveis correlacionadas e classes desbalanceadas, mantendo baixos índices de sobreajuste. Além disso, o RF permite avaliar a importância das variáveis, o que fornece interpretações ecológicas sobre quais fatores mais contribuem para distinguir tipologias florestais (Rigatti, 2016).

A escolha do RF neste tipo de análise está diretamente relacionada à sua robustez, reprodutibilidade e interpretabilidade. Em comparação com métodos mais complexos, como redes neurais profundas, o RF mantém uma relação equilibrada entre acurácia e transparência, o que é especialmente valorizado em pesquisas acadêmicas voltadas à gestão e monitoramento de ecossistemas florestais tropicais (Haneda et al., 2023).

2.4.2. Análise Da Importância De Variáveis

A análise da importância das variáveis é uma etapa essencial na interpretação dos

resultados obtidos com o *Random Forest*. Por meio dessa análise, é possível identificar quais atributos, sejam eles índices de vegetação, camadas sazonais, métricas de textura ou diversidade espectral, têm maior peso na discriminação entre as tipologias florestais (Mohammadpour et al., 2022). Essa informação fornece uma visão funcional da paisagem, indicando se a separação das classes se deve mais a fatores fisiológicos, estruturais ou sazonais (Dwiputra et al, 2023).

O *Mean Decrease Accuracy* (MDA) é uma das principais métricas utilizadas para avaliar a importância das variáveis em modelos do tipo *Random Forest* (Breiman, 2001). Essa métrica quantifica o quanto cada variável contribui para a acurácia global do modelo. Em outras palavras, mede o impacto que a remoção (ou permutação) de uma variável tem sobre o desempenho preditivo do modelo.

Do ponto de vista teórico, compreender a importância das variáveis contribui para validar os conceitos de sazonalidade e diversidade espectral como eixos centrais do estudo. Identificar o peso relativo desses componentes na classificação das tipologias florestais tropicais permite avançar na compreensão de como o funcionamento ecológico e a heterogeneidade estrutural se refletem nas assinaturas espectrais. Essa análise fundamenta, portanto, a relevância científica do tema e reforça a contribuição do trabalho para o campo do sensoriamento remoto aplicado à ecologia tropical.

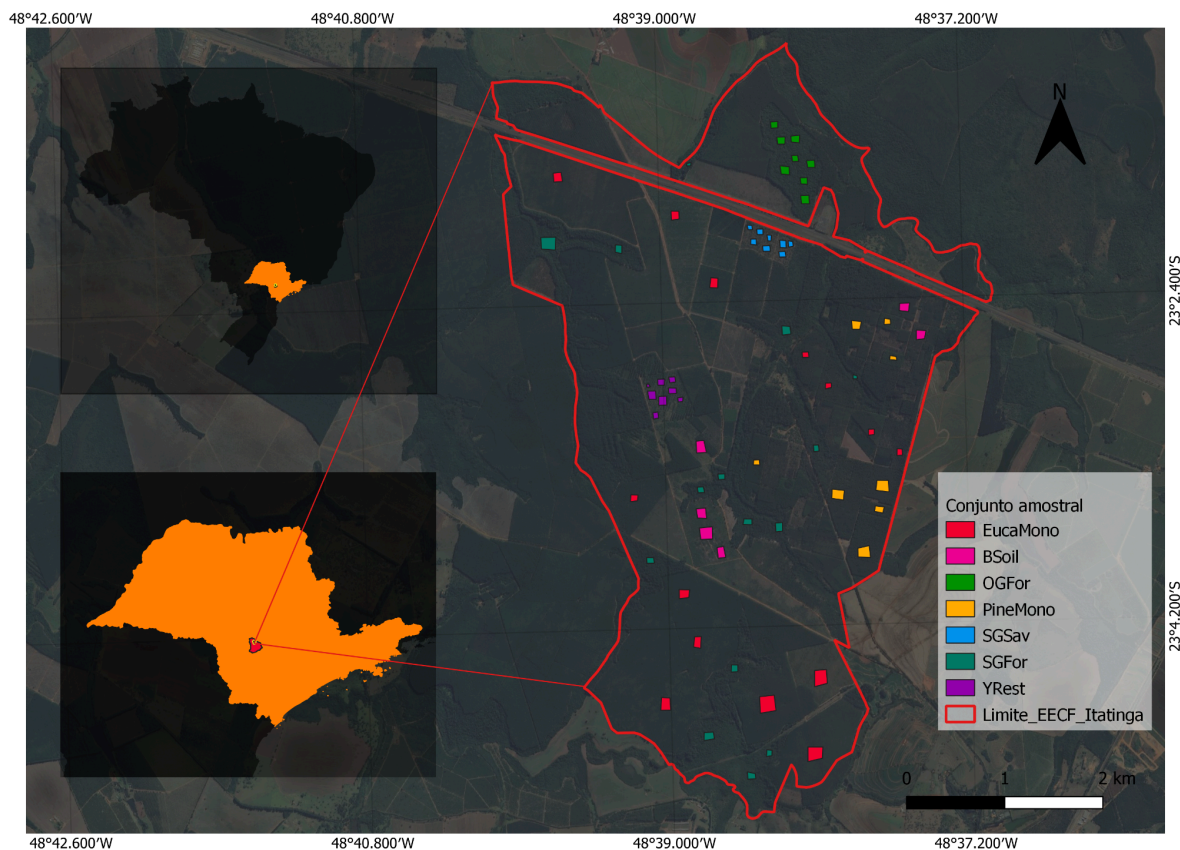
3. MATERIAIS E MÉTODOS

3.1. ÁREA DE ESTUDO E AMOSTRAGEM

A área de estudos foi a Estação Experimental de Ciências Florestais - Itatinga (EECFI), localizada a Latitude 23°10' S e Longitude 48°40' W, com uma área total de aproximadamente 2119,6 ha (Figura 6). O local abriga formações florestais de diferentes origens e finalidades, incluindo florestas plantadas de *Eucalyptus* e *Pinus*, áreas de floresta nativa conservada e secundária, além de áreas em processo de restauração e fragmentos de savana arbórea. Entre 2003 e 2022, a estação serviu como base para a conclusão de dissertações de mestrado, teses de doutorado, além de manter trabalhos em andamento, consolidando-se como um pilar na formação de pesquisadores (Garcia, 2020). A EECFI possui como objetivos: dar suporte técnico e operacional para a implementação de atividades voltadas para a educação, a ciência e o desenvolvimento tecnológico; elaborar e implementar atividades de educação ambiental e extensão florestal; promover a conservação e a restauração ambiental além de planejar e promover o uso múltiplo florestal. A história da EECFI, marcada pela passagem da silvicultura industrial para a pesquisa e conservação, e seu

impressionante volume de produção acadêmica e extensão, atestam seu potencial contínuo para o avanço das ciências florestais no Brasil (Figura 6) (ESALQ/USP, 2025).

Figura 6: Localização da EECFI no estado de São Paulo e o conjunto amostral das classes trabalhadas no estudo.





















Fonte: Autoria própria, 2025.

As classes de cobertura florestal utilizadas neste estudo foram delimitadas com base em sua composição, estrutura e finalidade de manejo, utilizando um mapa pré-existente de uso e cobertura do solo da EECFI. A partir desse mapa, foram definidos polígonos de amostragem representativos para cada classe florestal, seguindo a quantidade e localização das amostras utilizadas por Haneda et al. (2023) e aplicando a mesma nomenclatura: Eucalyptus (EucaMono), Pinus (PineMono), floresta estacional madura (OGFor), floresta estacional secundária (SGFor), restauração inicial (YRest), savana, também denominada como Cerrado (SGSav) e solo exposto (BSoil) (Tabela 1). Esses polígonos serviram como base para o treinamento e validação dos modelos de classificação (Figura 6).

Tabela 1: Descrição das classes de cobertura arbórea incluídas no estudo: Características estruturais e fotos ilustrativas

Classes de cobertura arbórea	Descrição	0°	45°	90°

<p>Monocultura de Eucalipto (“EucaMono”)</p>	<p>Vastas plantações monoculturais de <i>Eucalyptus</i> sp. - 2 a 20 anos de idade - Árvores de folhas largas - Árvores altas - Dossel fechado - Ausência de espécies nativas regenerando no sub-bosque - Alta intensidade de indivíduos - Baixa diversidade de espécies</p>			
<p>Monocultura de Pinus (“PineMono”)</p>	<p>Plantações monoculturais de <i>Pinus</i> sp. - 20 a 30 anos de idade - Árvores agulhadas - Árvores altas - Dossel fechado - Ausência de espécies nativas regenerando no sub-bosque - Alta densidade de indivíduos - Baixa diversidade de espécies</p>			
<p>Floresta estacional semidecidual madura (“OGFor”)</p>	<p>- Árvores de folhas largas - Árvores altas - Dossel fechado - Sub-bosque denso de espécies nativas - Alta densidade de indivíduos - Alta diversidade de espécies</p>			

<p>Floresta secundária semidecidual (“SGFor”)</p>	<p>Florestas secundárias estabelecidas por regeneração espontânea</p> <ul style="list-style-type: none"> - ± 50 anos de idade - Árvores de folhas largas - Árvores altas - Dossel fechado - Presença de sub-bosque - Alta densidade de indivíduos - Alta diversidade de espécies 			
<p>Vegetação secundária de Cerrado/Savana (“SGSav”)</p>	<p>Vegetação nativa estabelecida por regeneração espontânea</p> <ul style="list-style-type: none"> - ± 50 anos - Árvores de folhas largas - Árvores pequenas - Dossel aberto - Baixa densidade de indivíduos - Alta diversidade de espécies 			
<p>Plantio de restauração inicial/jovem (“YRest”)</p>	<p>Plantio de restauração estabelecido pela abordagem de nucleação</p> <ul style="list-style-type: none"> - ± 2 anos - Árvores de folhas largas - Árvores pequenas - Dossel aberto - Alta diversidade de espécies 			

Solo exposto ("BSoil")	- Área de solo exposto	-	-	-
---------------------------	---------------------------	---	---	---

Fonte: Adaptado de Haneda et al, 2023.

O conjunto amostral foi construído a partir dos polígonos de referência mencionados, cada um representando uma classe de cobertura florestal. Esses polígonos foram reamostrados para uma área de 20 x 20 metros, compatível com as bandas do Sentinel-2 utilizadas no estudo. Em seguida, as amostras foram convertidas em formato raster e sobrepostas à cena orbital correspondente, assegurando o alinhamento espacial entre as variáveis preditoras e a variável resposta. O conjunto amostral foi constituído por 14 amostras para EucaMono, 8 amostras para PineMono, 8 amostras para OGFor, 15 amostras para SGFor, 8 amostras para SGSav, 8 amostras para YRest e 6 amostras para BSoil (Figura 5).

Para evitar o mascaramento e a sobreposição das classes durante o loop de predição do modelo *Random Forest*, o total de amostras foi balanceado entre as classes para reduzir o viés de predição, resultando em 72 amostras por classe e uma distribuição uniforme de pixels por tipologia florestal. Esse procedimento foi realizado por meio de técnicas de *upsampling e downsampling*, garantindo a representatividade de todas as classes de interesse. Além disso, para cada amostra foi associado um identificador único de polígono (*poly_id*), contendo as informações de cada classe, utilizado posteriormente na etapa de validação cruzada.

As amostras resultantes foram utilizadas para treinar e validar o modelo de classificação supervisionada, assegurando que cada conjunto (treino e teste) representasse de forma equilibrada a variabilidade espectral e estrutural das formações florestais presentes na área de estudo.

3.2. BANCO DE DADOS

As imagens de satélite utilizadas neste estudo foram provenientes do sensor MSI a bordo do satélite Sentinel-2. A aquisição foi realizada por meio da plataforma Google Earth Engine (GEE), utilizando a coleção COPERNICUS/S2_SR_HARMONIZED, correspondente

ao nível de processamento Sentinel-2A e 2B, o que garante a correção atmosférica, maior disponibilidade de imagens e a conversão dos dados em reflectância de superfície.

Neste estudo, utilizou-se um total de 10 bandas espectrais (Tabela 2). Embora as bandas apresentassem resolução espacial de 10 e 20 metros, buscando utilizar melhor os índices de vegetação e todo seu potencial, estabeleceu-se, para todas as bandas, 20 metros de resolução espacial, apresentando melhor equilíbrio entre nível de detalhe e cobertura espectral. As bandas utilizadas foram: Azul, Verde, Vermelho, Red-Edge 1, Red-Edge 2, Red-Edge 3, Red-Edge 4, NIR, SWIR1 e SWIR2. As imagens foram renomeadas e reorganizadas por meio de funções de pré-processamento que padronizaram as nomenclaturas das bandas e garantiram a consistência radiométrica entre as cenas.

Tabela 2: Bandas do Satélite Sentinel-2 utilizadas no estudo.

Resolução	Nr da Banda	Nome da Banda	Comprimento de Onda Central (nanômetro)
10 m	B02	Blue (Azul)	490
	B03	Green (Verde)	560
	B04	Red (Vermelho)	665
	B08	NIR (Infravermelho Próximo)	842
20 m	B05	Red Edge 1	705
	B06	Red Edge 2	740
	B07	Red Edge 3	783
	B08A	Red Edge 4	865
	B11	SWIR 1	1610
	B12	SWIR 2	2190

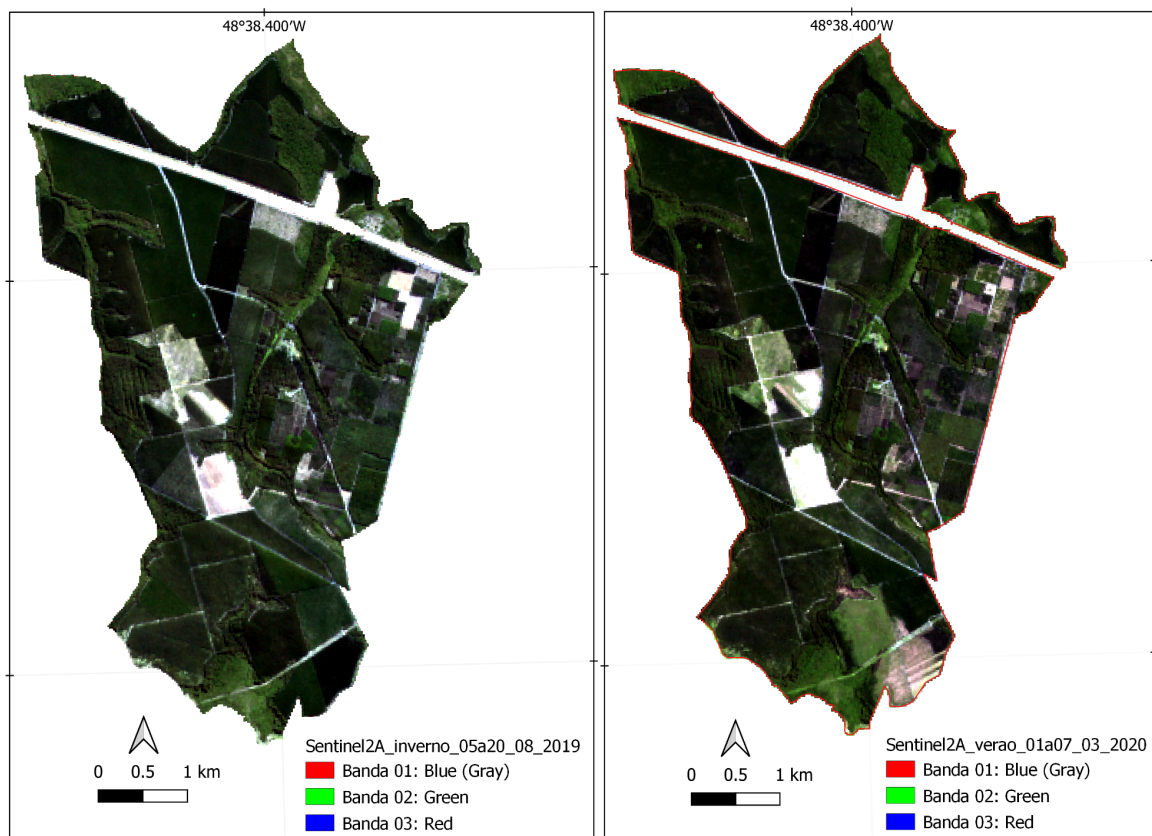
Fonte: Adaptado de Sentinel Hub, s.d.

O conjunto de imagens foi filtrado espacialmente para o limite da EECFI e temporalmente para o intervalo de 5 a 20 de agosto de 2019, correspondente ao período de inverno (estação mais seca), e de 01 a 07 de março 2020, equivalente ao período de verão, (estação mais chuvosa) faixa temporal que contempla as datas utilizadas no artigo de Haneda et al, 2023. Adicionalmente, foi aplicado um filtro de qualidade para excluir cenas com cobertura de nuvens superior a 10%, assegurando a integridade dos valores de reflectância. Após o pré-processamento, as imagens foram compostas pela mediana dos pixels válidos, resultando em uma composição livre de nuvens representativa do período sazonal.

A imagem final foi recortada (através da função clip) com base no shapefile da área

de estudo e exportada em formato GeoTIFF, com sistema de referência EPSG:31982 (SIRGAS 2000 / UTM zona 23S) e resolução espacial de 20 m, compatível com as demais etapas de processamento no ambiente R. Esse procedimento garantiu que todas as variáveis derivadas (índices de vegetação, camadas delta, textura e diversidade espectral) fossem calculadas sobre uma base radiometricamente uniforme e espacialmente coerente (Figura 7). Em sequência, utilizando o software QGIS e o arquivo de cabeçalho (.hdr) da imagem processada, foram determinados os valores dos centróides espectrais das bandas. Esses comprimentos de onda, em nanômetros (nm), foram utilizados para o desenvolvimento do modelo de classificação, sendo eles: 496,6 (B02), 560,0 (B03), 664,5 (B04), 703,9 (B05), 740,2 (B06), 782,5 (B07), 835,1 (B08), 864,8 (B8A), 1613,7 (SWIR 1) e 2202,4 (SWIR 2) nm (Tabela 3).

Figura 7: Composição RGB do conjunto de imagens dos períodos de verão e inverno utilizadas no estudo



Fonte: Autoria própria, 2025.

3.3. SOFTWARES UTILIZADOS

O processamento e a análise dos dados foram conduzidos em três principais ambientes computacionais:

- Google Earth Engine (GEE): utilizado para obtenção das cenas Sentinel-2A e 2B,

aplicação de filtros atmosféricos e temporais, e exportação das imagens compostas para o ambiente local;

- R (versão 4.3.3): responsável pelo cálculo dos índices espectrais, camadas delta, métricas de textura, diversidade espectral e modelagem supervisionada com o algoritmo *Random Forest*;
- QGIS (versão 3.34): empregado para o pós-processamento cartográfico, análise espacial e composição dos mapas finais.

A combinação dessas três plataformas proporcionou um fluxo de trabalho reprodutível e transparente, integrando etapas de pré-processamento, análise quantitativa e representação espacial dos resultados.

3.4. VARIÁVEIS

3.4.1. Índices De Vegetação

Os índices de vegetação foram derivados das bandas do Sentinel-2, com ênfase em métricas biofísicas relevantes para a diferenciação de tipologias florestais. Foram calculados 6 índices para cada estação do ano: NDVI (*Normalized Difference Vegetation Index*), EVI (*Enhanced Vegetation Index*), NDVI_{re1} (*Red-Edge Normalized Difference Vegetation Index*), CL_{re1} (*Red-Edge Chlorophyll Index*), NDMI (*Normalized Difference Moisture Index*) e NBR (*Normalized Burn Ratio*).

Esses índices foram gerados separadamente para as estações de verão e inverno, de forma a capturar a variação fenológica das formações florestais. Cada índice expressa um atributo biofísico distinto, como vigor vegetativo, teor de clorofila, umidade e distúrbios, ampliando a capacidade de interpretação ecológica dos dados.

Os valores derivados foram posteriormente utilizados como variáveis preditoras no modelo de classificação supervisionada. Buscando ampliar o desempenho do modelo, não se distanciar dos índices utilizados por Haneda et al, 2023, e diminuir a probabilidade de sobreajuste das variáveis, outros índices de vegetação recomendados pela comunidade acadêmica foram considerados. A importância relativa de cada índice foi avaliada pelo algoritmo *Random Forest*, por meio da métrica *Mean Decrease Accuracy* (MDA), a fim de identificar quais variáveis espectrais tiveram maior influência na discriminação das classes florestais. A escolha dos índices utilizados neste estudo se deu através das variáveis que demonstraram maior desempenho na métrica MDA (Tabela 3).

Tabela 3: Cálculo dos índices de vegetação a partir das bandas espectrais do satélite Sentinel-2.

Índices de vegetação aplicados às imagens Sentinel-2					
Variável	Name	Tradução (português BR)	Bandas (nanômetros)	Fórmulas Sentinel-2 (IDB, 2024)	Referência
NDVI	Normalized Difference Vegetation Index	Índice de Vegetação por Diferença Normalizada	x = NIR (835.1 nm); y = RED (664.5 nm).	$((x-y)/(x+y))$	(Index Database, [s.d])
NDVIre1	Red Edge Normalized Difference Vegetation Index	Índice de Vegetação de Diferença Normalizada Red Edge	x = NIR (835.1 nm); y = RedEdge1 (703.9 nm).	$((x-y)/(x+y))$	(Index Database, [s.d])
CLre1	Chlorophyll IndexRedEdge	Índice de clorofila Red Edge	x = NIR (835.1 nm); y = RedEdge1 (703.9 nm).	$((x/y)-1)$	(Index Database, [s.d])
EVI	Enhanced Vegetation Index	Índice de Vegetação Aprimorado	x = RedEdge4 (864.8 nm); y = RedEdge1 (703.9 nm); z = Blue (496.6 nm)	$((2.5*(x - y))/((x + (6 * y) + (7.5 * z)) + 1))$	(Sentinel Hub ² , [s.d])
NDMI	Normalized Difference Moisture Index	Índice de umidade de diferença normalizada	x = NIR (835.1 nm) y = SWIR1 (1613.7 nm)	$((x - y) / (x + y))$	(Sentinel Hub ² , [s.d])
NBR	Normalized Burn Ratio	Taxa de queima normalizada	x = NIR (835.1 nm) y = SWIR2 (2202.4 nm)	$((x - y) / (x + y))$	(Sentinel Hub ² , [s.d])

Fonte: Autoria própria, 2025.

3.4.2. Camadas De Textura

As métricas de textura foram geradas a partir dos índices de vegetação (NDVI, EVI, NDVIre1, CLre1, NDMI e NBR), utilizando a função focal() no R para calcular o desvio-padrão móvel. Considerando uma resolução espacial de 20x20 metros das imagens Sentinel-2A, o tamanho de janela móvel aplicado que demonstrou melhor desempenho foi de 3x3. Essa abordagem quantifica a variação local da reflectância, representando a heterogeneidade estrutural do dossel.

Valores elevados de textura indicam maior complexidade e irregularidade da

cobertura arbórea, típicas de florestas conservadas, ou áreas de transição entre as classes, enquanto valores baixos caracterizam áreas homogêneas, como plantações e savanas abertas. As camadas geradas foram nomeadas conforme o índice de origem (por exemplo, NDVI_sd3x3, NDMI_sd3x3), compondo um conjunto de variáveis estruturais complementares à análise espectral. Além das camadas de textura para cada índice espectral, foram geradas também camadas de textura referentes às camadas delta calculadas (exemplo: NDVIre1_delta_sd3x3).

3.4.3. Camadas Delta

As camadas delta foram obtidas pela diferença entre os índices de vegetação de verão e inverno, destacando as variações sazonais na resposta espectral da vegetação. Essa métrica expressa quantitativamente a amplitude fenológica das formações florestais, refletindo processos como floração, desfolhamento e regeneração.

Essas camadas foram integradas ao conjunto de variáveis preditoras para representar o componente temporal da paisagem, fundamental na análise da sazonalidade espectral e na distinção entre tipologias estruturalmente semelhantes, mas com comportamentos fenológicos distintos (Haneda et al, 2023).

3.4.4. Camada De Diversidade Espectral

A diversidade espectral foi calculada utilizando o pacote *biodivMapR* (versão 1.14.6), que operacionaliza o conceito de “espécies espectrais”. O procedimento envolveu três etapas: filtragem radiométrica, redução de dimensionalidade (SPCA) e agrupamento espectral (k-means) com 50 clusters. A partir dessa classificação, foram derivados os mapas de diversidade alfa (heterogeneidade local) e diversidade beta (dissimilaridade espacial).

A etapa de filtragem radiométrica teve como objetivo eliminar pixels contaminados por sombras, nuvens, corpos d'água e outros artefatos atmosféricos que poderiam comprometer a análise espectral. Foram utilizados limiares específicos para as bandas espectrais e índices derivados, ajustados conforme as características das imagens Sentinel-2 e recomendações do pacote *biodivMapR* (v1.0–2.0). Na etapa “Mask_raster” (Figura 5) o limiar de NDVI = 0,1 foi adotado para restringir a análise às áreas com presença efetiva de vegetação, excluindo superfícies com baixa reflectância verde ou sem cobertura vegetal. Para a banda azul (496,6 nm), foi aplicado um valor de 1100 como limite inferior, removendo pixels excessivamente escuros associados à sombra ou à presença de água. Já na banda do NIR (835,1 nm), o limiar de 1000 permitiu identificar e suprimir regiões com alta reflectância anômala, frequentemente associadas à presença de nuvens ou brilho especular. A definição

desses valores buscou equilibrar a exclusão de ruídos radiométricos e a manutenção da variabilidade espectral natural das tipologias florestais, evitando a exclusão de classes como solo exposto, por apresentar baixa diversidade, assegurando assim a integridade das análises subsequentes de diversidade espectral e sazonalidade.

A diversidade alfa foi estimada com base no índice de Shannon e janela de 5×5 pixels, enquanto a diversidade beta foi calculada por Análise de Coordenadas Principais (PCoA) em janelas de 10×10 pixels. Esses indicadores refletem a variação funcional e estrutural das formações florestais, fornecendo uma dimensão espectral complementar à sazonalidade e à textura. Essa abordagem permitiu quantificar a heterogeneidade espectral intra e interclasse, representando um avanço metodológico em relação a métricas tradicionais.

3.5. ANÁLISE DE AMOSTRAGEM

A classificação supervisionada foi conduzida com o algoritmo *Random Forest* (RF). O modelo foi treinado com o conjunto de variáveis preditoras (índices de vegetação, camadas delta, textura e diversidade espectral), apresentadas na Tabela 4 e validado com a variável resposta (classes florestais).

A validação cruzada por polígono foi utilizada para evitar dependência espacial entre os conjuntos de treino e teste, dividindo as amostras em 70% para treinamento e 30% para validação. O processo foi repetido 30 vezes, gerando estatísticas médias de desempenho, como acurácia global e F1-score por classe. Depois disso, aplicou-se a métrica MDA, para identificar quais atributos espectrais e sazonais foram mais relevantes na distinção das tipologias florestais tropicais.

O mapa temático final foi gerado a partir da predição do modelo treinado sobre a imagem multivariada, sendo posteriormente suavizado com um filtro 3×3 para reduzir ruídos pontuais. Por fim, a composição e a edição cartográfica foram realizadas no QGIS, resultando em mapas interpretativos e de alta qualidade visual.

Tabela 4: Variáveis utilizadas

Arquivo	Número de variáveis
Bandas de inverno	10
Bandas de verão	10
Índices de vegetação de inverno	6
Índices de vegetação de verão	6

Camadas delta	6
Camadas de textura	18
Diversidade alpha inverno	1
Diversidade alpha verão	1
Componentes PCA inverno	3
Componentes PCA verão	3
Total	64

Fonte: Autoria própria, 2025.

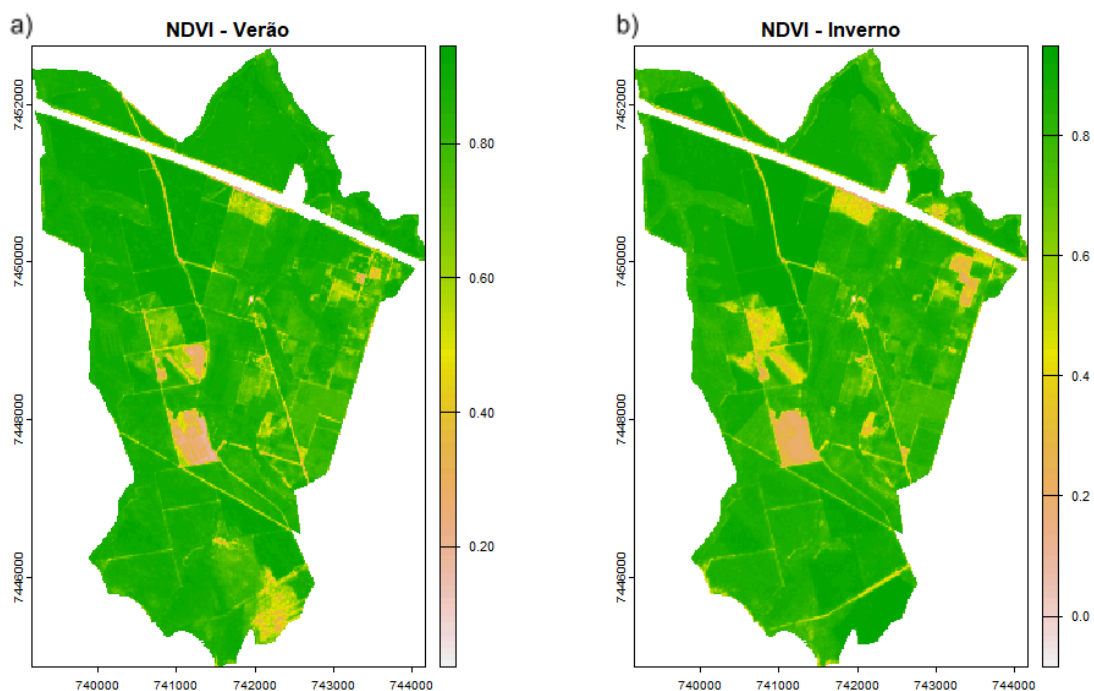
4. RESULTADOS E DISCUSSÃO

4.1. CARACTERIZAÇÃO DAS CLASSES DE COBERTURA ARBÓREA

4.1.1. Índices De Vegetação

Como primeiro resultado, foram gerados os índices de vegetação para as cenas de verão (a) e de inverno (b). Os resultados da aplicação matemática do índice NDVI podem ser observados na Figura 8.

Figura 8: Mapa dos índices de vegetação NDVI obtido no primeiro conjunto de variáveis utilizadas no estudo, correspondentes aos períodos de verão e inverno



Fonte: Autoria própria, 2025

4.1.2. Camadas De Textura

A Figura 9, abaixo, apresenta o comportamento espacial do EVI, indicando a

intensidade da atividade fotossintética, e da sua respectiva camada de textura (desvio-padrão em janela 3×3), ambos obtidos a partir da imagem Sentinel-2 correspondente à estação de verão. O mapa (a), apresenta os valores do EVI, que expressam a densidade e o vigor da vegetação, variando de valores mais baixos em áreas abertas ou solos expostos a valores mais altos em regiões florestadas e com dossel fechado, com valores mais altos nas áreas florestadas e menores em solos expostos ou áreas agrícolas. O segundo mapa (b) mostra a textura do EVI, em que regiões mais homogêneas (como plantações densas e florestas contínuas) apresentam baixos valores de textura, enquanto áreas mais heterogêneas (como bordas de fragmentos e mosaicos de uso do solo) exibem maiores variações locais.

Figura 9: Comparação entre o índice de vegetação EVI gerado inicialmente (a) e a camada de textura gerada a partir desse índice (b)



Fonte: Autoria própria, 2025.

Essa representação complementa a avaliação espectral ao incorporar a dimensão espacial da variabilidade, essencial para distinguir diferentes tipologias florestais e compreender a organização estrutural da paisagem. Nesse exemplo, observa-se que associar índice de vegetação e sua textura contribui para uma caracterização mais detalhada da cobertura vegetal e da dinâmica ecológica observada durante a estação de verão.

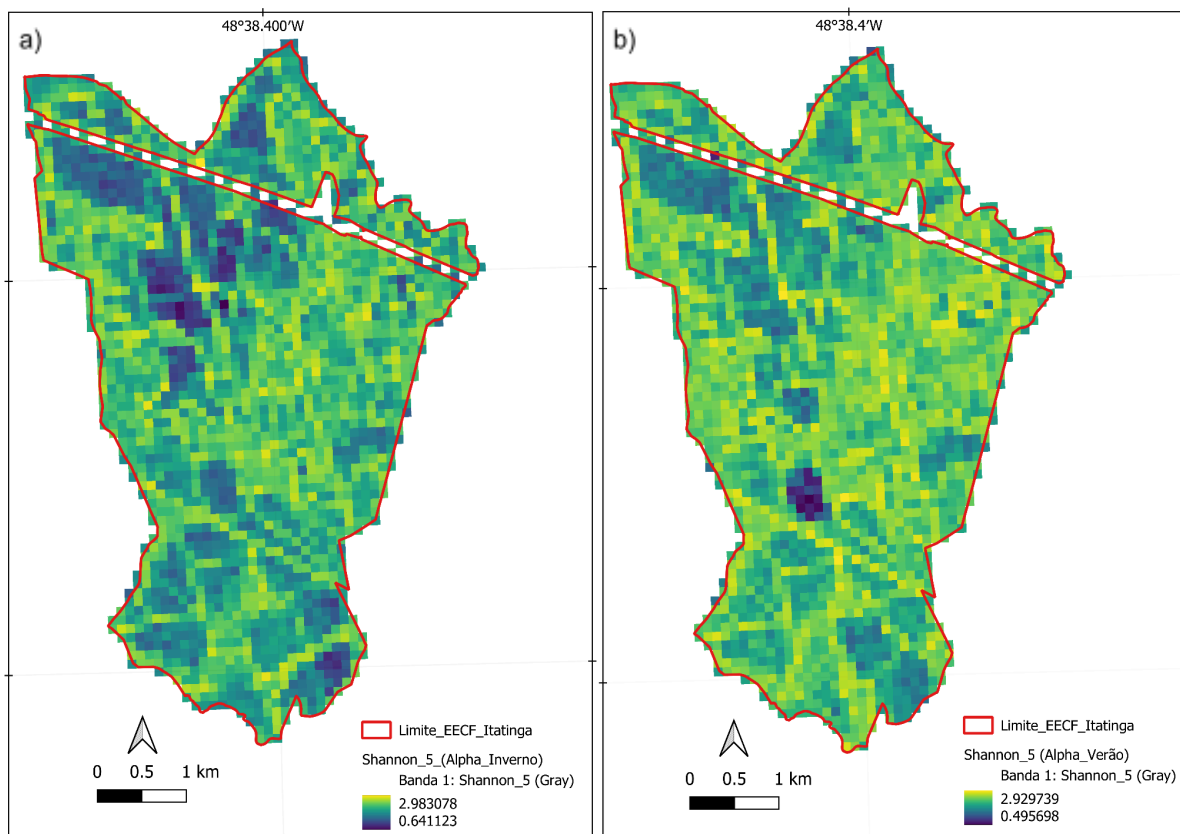
4.1.3. Diversidade Espectral: BiodivmapR

4.1.3.1. Índice Shannon: Alpha Diversidade

Na Figura 10 abaixo, é possível identificar a componente Shannon, também utilizada

como variável Alpha, correspondente a estação inverno (a), e ao lado encontra-se a variável Alpha correspondente a estação verão (b), ambas que calculam a diversidade das espécies da área de estudo. É possível observar que o índice Shannon, para o inverno variou entre 0,641 e 2,983, enquanto que para o verão, variou de 0,496 a 2,930. Esses valores indicam uma maior variabilidade de espécies na região, assim, é possível observar que o pacote identificou nas áreas mais claras, onde estão localizadas as classes de floresta secundária (SGFor) e floresta conservadas (OGFor), uma maior diversidade, enquanto que para áreas em que compreende os monocultivos de Eucalipto (EucaMono) e Pinus (PineMono) o pacote identificou com menor diversidade.

Figura 10: Diversidade Alpha correspondente a estação inverno (a) e verão (b)

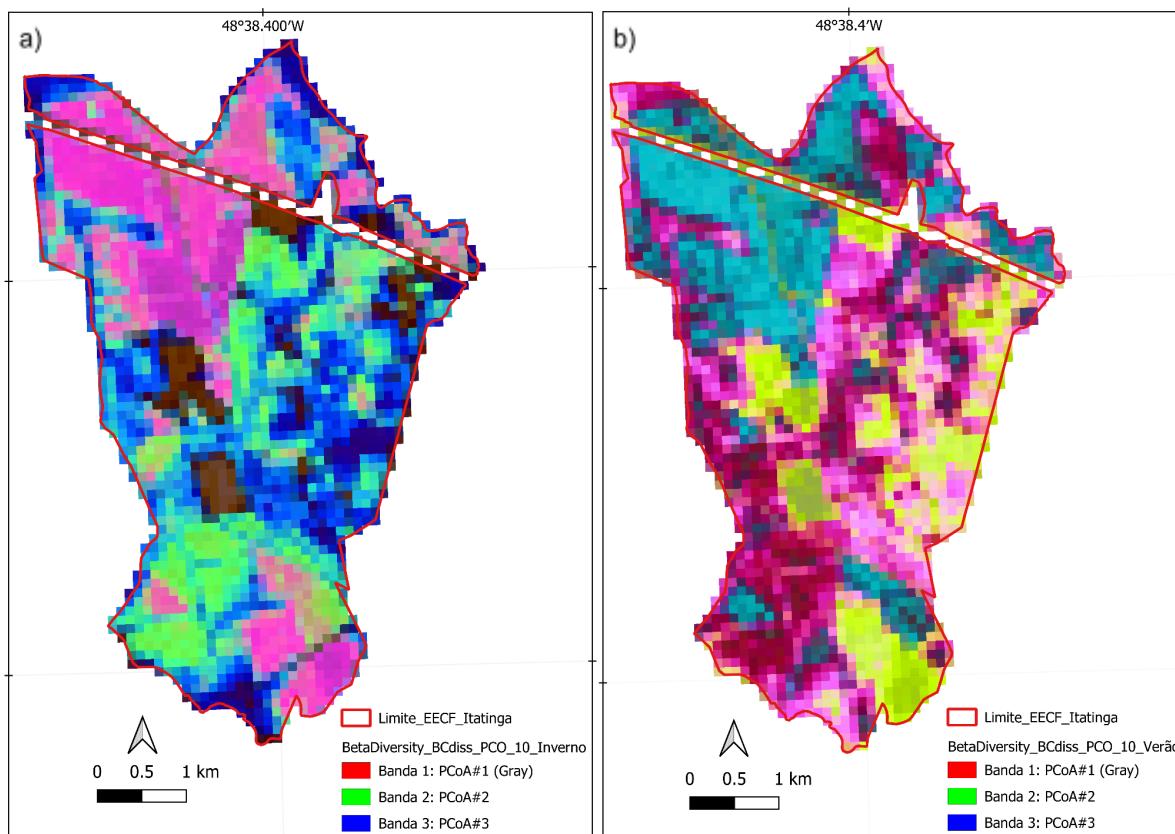


Fonte: Autoria própria, 2025.

4.1.3.2. Beta Diversidade

Na Figura (11) abaixo, é possível observar os mapas de Beta diversidade, correspondentes a estação de inverno (a) e verão (b). A intensidade e diferenciação das cores em ambas as estações indica uma heterogeneidade na paisagem o que implica na alteração sazonal na diversidade espectral das classes ao longo do ano.

Figura 11: Beta diversidade correspondente a estação inverno e verão



Fonte: Autoria própria, 2025.

4.1.4. Comportamento Espectral

As curvas espectrais sintetizam o comportamento radiométrico médio das diferentes tipologias florestais ao longo do espectro do Sentinel-2A E 2B, evidenciando padrões consistentes e variações sazonais marcantes entre o verão e o inverno. No intervalo do visível (VIS: 490–665nm), todas as classes de floresta tropical apresentam baixa reflectância, especialmente nas bandas azul (B02) e vermelha (B04) (Tabela 2), devido à forte absorção pela clorofila, comportamento típico de dosséis densos e fisiologicamente ativos. Nas bandas da faixa espectral infravermelho próximo com valores próximos a banda do visível (VIR: 700–864 nm), as diferenças tornam-se mais expressivas: florestas conservadas (OGFor) e secundárias (SGFor) mantêm elevada reflectância, associada à estrutura foliar mais complexa e à maior multiplicidade de reflexões internas, enquanto áreas de restauração inicial (YRest), Pinus (PineMono) e Savana (SGSav) exibem valores intermediários, com respostas mais suaves na transição do Red-Edge para o NIR.

Na classe de solo exposto (BSoil), ocorre uma diferença observada pelo aumento contínuo da reflectância ao longo de todo o espectro, acentuado nas faixas SWIR (1610 e 2190 nm), sensíveis ao teor de umidade e à composição mineral da superfície (Peng Li et al.,

2024). Em contraponto, nas formações que apresentam vegetação, as curvas do SWIR decaem de forma mais evidente, refletindo maior absorção hídrica e diferenças estruturais entre as coberturas.

Analisando as figuras a seguir (Figura 12, Figura 13 e Figura 14) é possível observar que a comparação entre estações mostra que a variabilidade sazonal se manifesta sobretudo nas bandas do infravermelho, com redução geral da reflectância no inverno (faixa mais contínua no gráfico). Esse comportamento está associado à menor biomassa foliar e ao declínio do teor de água nas copas, o que diminui a intensidade da resposta no NIR e acentua o contraste entre as tipologias. Em contrapartida, no verão, observa-se maior separabilidade entre as classes florestais, especialmente entre floresta conservada e restauração, reforçando o papel da fenologia tropical e da umidade foliar na modulação da resposta espectral.

Figura 12: Curvas espectrais médias e amplitude de variância das diferentes classes de cobertura arbórea para o satélite Sentinel-2A nas estações de verão (a) e inverno (b)

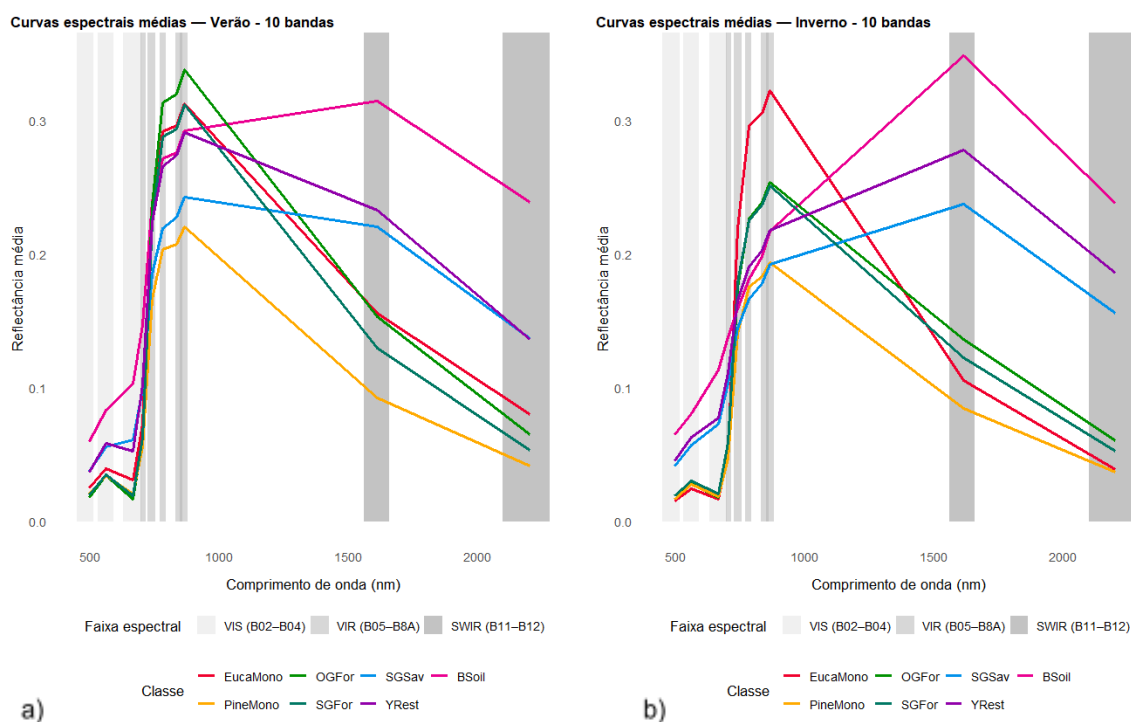


Figura 13: Comportamento espectral médio e faixa de variação das tipologias florestais no intervalo do visível ao infravermelho próximo correspondentes a verão (a) e inverno (b).

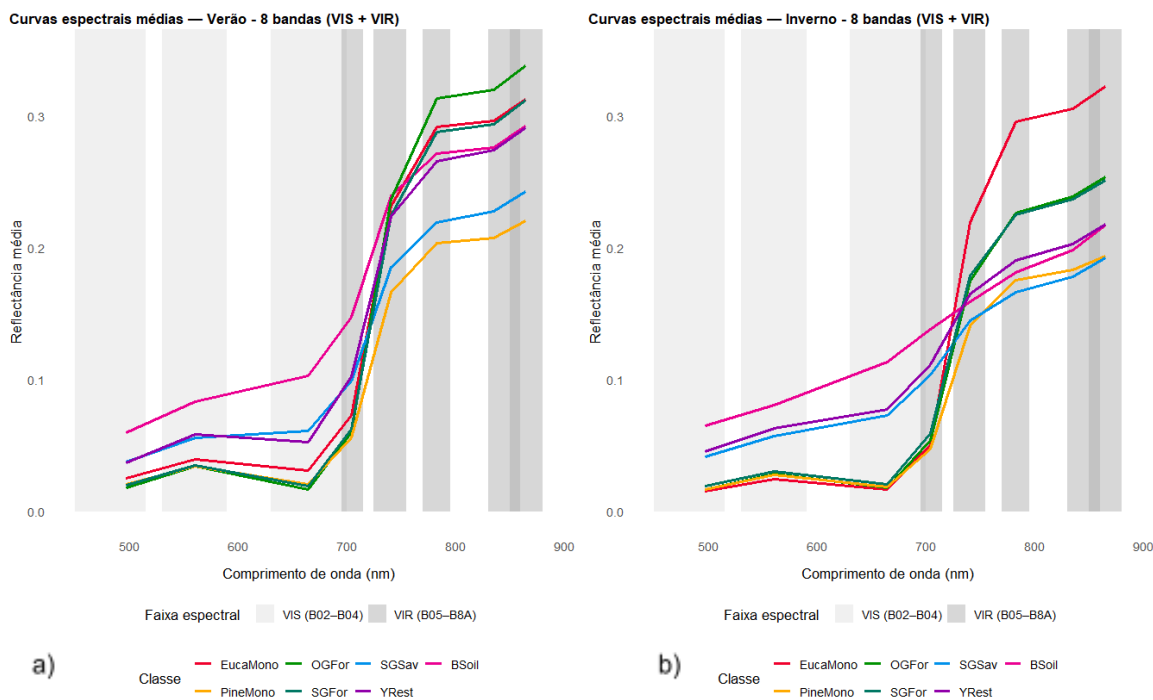
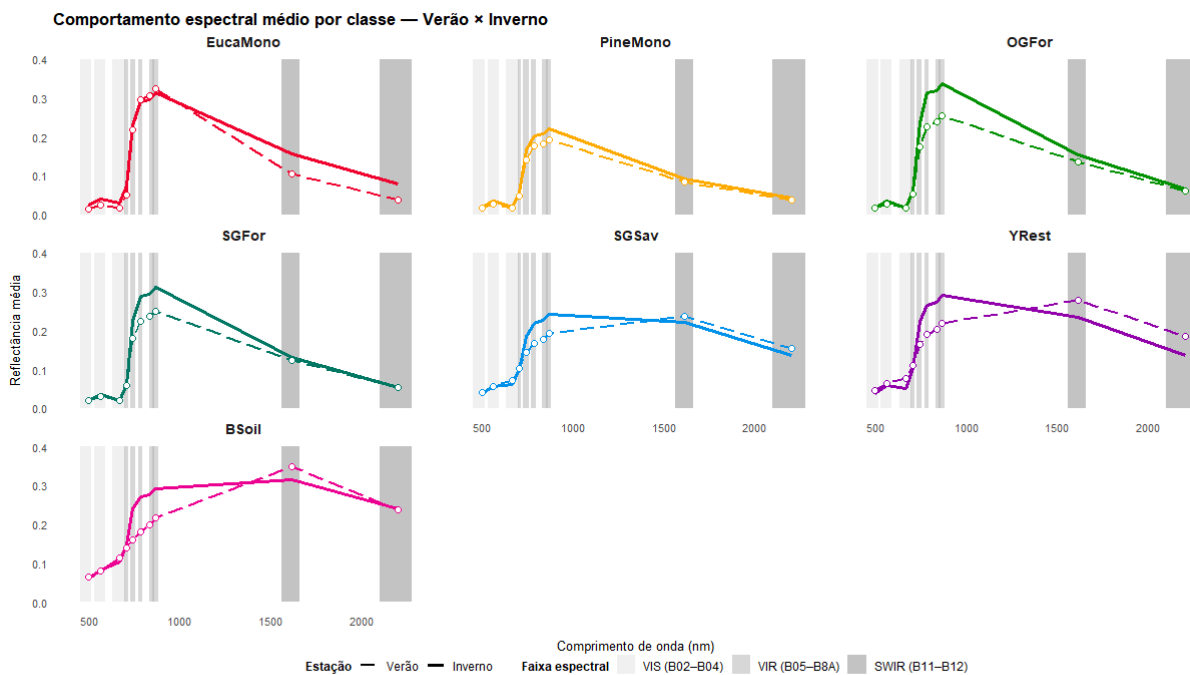


Figura 14: Comparativo sazonal das curvas espectrais médias das classes de cobertura arbórea entre os períodos de verão e inverno



Fonte: Autoria própria, 2025.

De modo geral, os padrões observados confirmam a sensibilidade do Sentinel-2 para diferenciar variações estruturais e sazonais da vegetação, destacando o potencial das bandas do Red-Edge e SWIR na caracterização de tipologias florestais e no monitoramento de

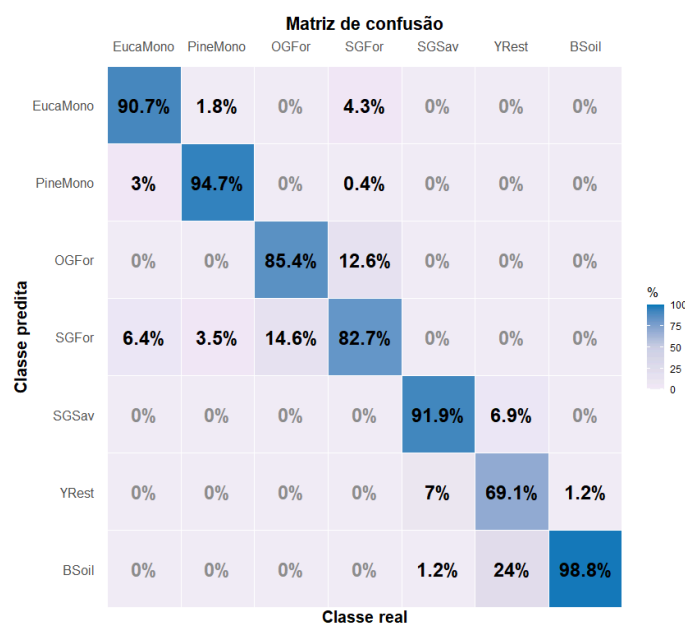
processos de restauração e sucessão ecológica.

4.2. CLASSIFICAÇÃO DAS CLASSES DE COBERTURA ARBÓREA

4.2.1. Matriz de confusão

Analisando a matriz de confusão (Figura 15), observa-se que o modelo *Random Forest* apresentou um desempenho satisfatório na diferenciação de tipologias florestais, demonstrando uma acurácia superior a 80% para a maioria das classes. As maiores taxas de acerto foram observadas para os plantios homogêneos (EucaMono e PineMono) e para o solo exposto (BSoil), que apresentaram assinaturas espectrais mais estáveis e de fácil separação. Em contrapartida, as classes associadas a formações heterogêneas, como SGFor e YRest, apresentaram confusões mais acentuadas com tipologias estruturalmente próximas, como OGFor e SGSav. Esse padrão é coerente do ponto de vista ecológico, pois reflete a sobreposição espectral entre estágios sucessionais intermediários e a variabilidade estrutural de áreas em regeneração, onde a presença simultânea de vegetação e solo exposto tende a reduzir a separabilidade espectral.

Figura 15: Matriz de confusão gerada a partir do modelo *Random Forest*



Fonte: Autoria própria, 2025.

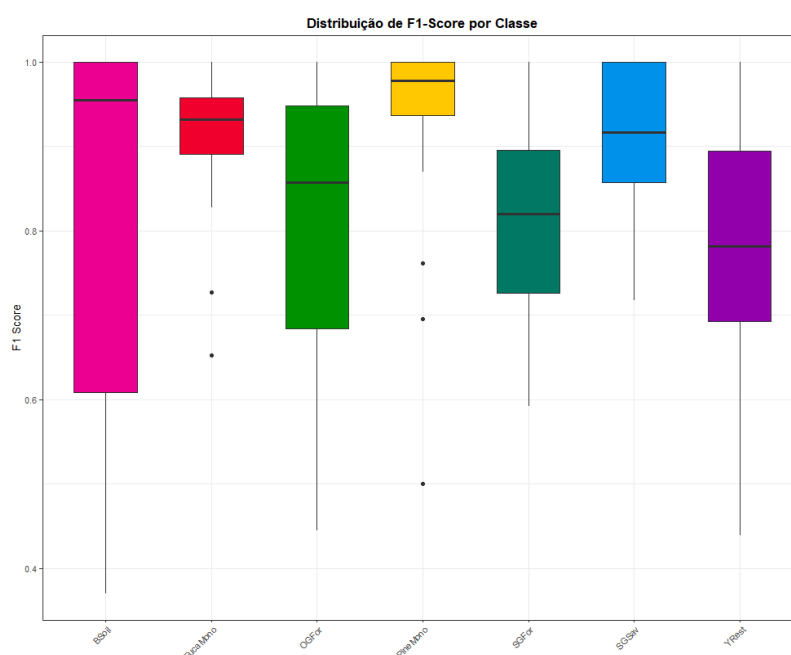
Resultados semelhantes foram encontrados por Haneda et al. (2023) e Almeida et al. (2025), destacando a influência da sazonalidade e da heterogeneidade florística sobre o comportamento espectral das florestas tropicais. Dessa forma, o desempenho do modelo indica que o uso combinado de índices espectrais e métricas sazonais é eficaz para caracterizar a estrutura e a dinâmica das formações florestais, embora a distinção de classes

em transição sucessional ainda represente um desafio metodológico.

4.2.2. F1 score

A análise da distribuição do F1-Score complementa os resultados obtidos pela matriz de confusão, permitindo avaliar de forma mais robusta o desempenho preditivo do modelo. As classes EucaMono, PineMono e BSoil apresentaram os valores médios de F1-Score mais elevados e consistentes, próximos de 1, indicando alta estabilidade e acurácia na classificação. Esse comportamento está associado à maior homogeneidade espectral dessas tipologias e à definição clara de suas assinaturas espectrais (Figura 16).

Figura 16: Gráfico de distribuição F1-Score



Fonte: Autoria própria, 2025.

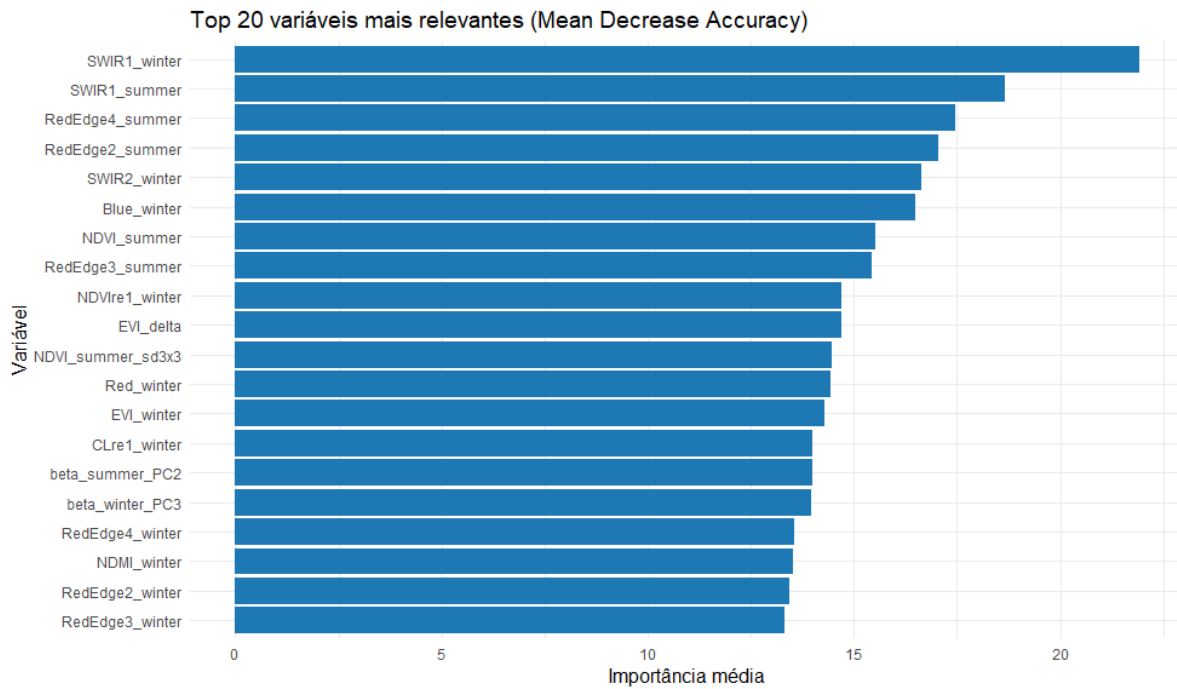
Por outro lado, as classes associadas a formações florestais em transição, como SGFor e YRest, apresentaram maior variabilidade nos escores e valores medianos mais baixos, indicando dificuldades do modelo em separar formações estruturalmente heterogêneas. Essa tendência é coerente com o comportamento espectral das florestas tropicais, em que a sazonalidade e a diversidade fisionômica reduzem a separabilidade entre estágios sucessionais (Haneda et al., 2023; Almeida et al., 2025). Essa métrica apresenta uma visão equilibrada da capacidade do modelo de identificar corretamente cada classe.

4.2.3. Mean Decrease Accuracy (MDA)

Após as 30 interações do modelo foram gerados também dois gráficos (Figuras 17 e 18) para avaliar a relevância das 64 variáveis utilizadas. As bandas de satélite que apresentaram os maiores valores para o MDA foram as bandas do “SWIR” 1 e 2, e

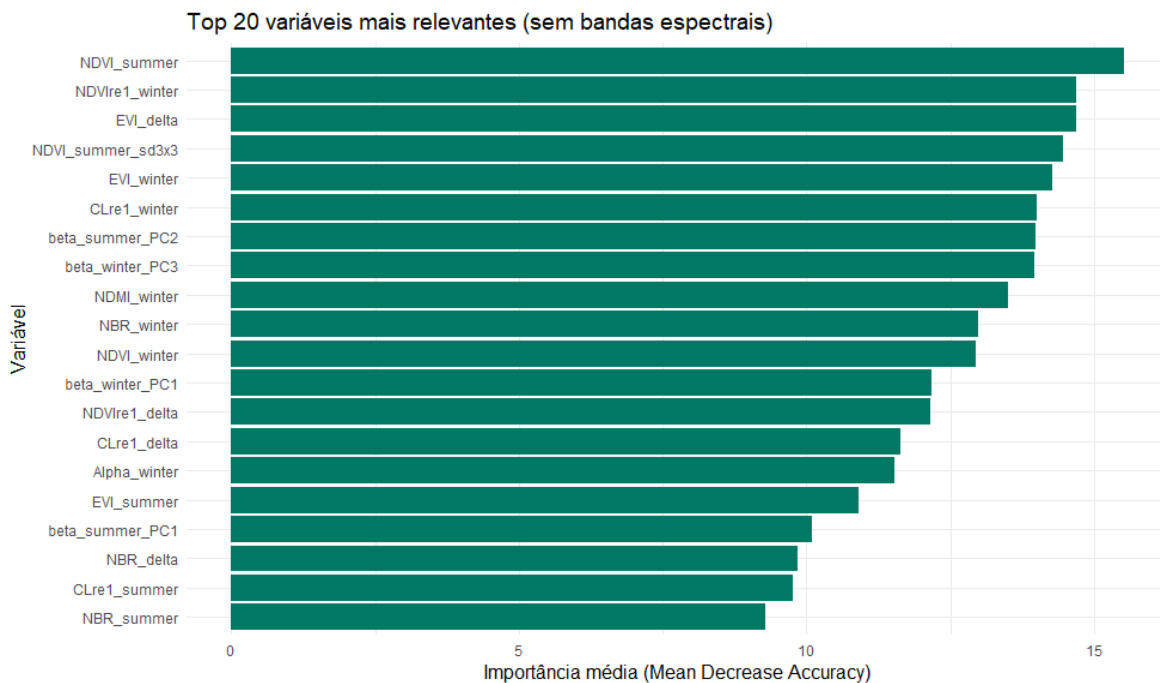
“RedEdge” 2 e 4, ocupando os 5 primeiros lugares.

Figura 17: MDA geral, incluindo todas as variáveis



Fonte: Autoria própria, 2025

Figura 18: MDA filtrado, retirando as bandas espectrais para analisar a relevância das outras variáveis



Fonte: Autoria própria, 2025.

De modo geral os índices de vegetação não apresentaram um papel significativo no modelo (Gráfico 1). Contudo, analisando o Gráfico 2, é possível observar que os índices e as

camadas de inverno possuem um grande peso para diferenciação das classes dentro do modelo. É válido observar que as variáveis texturais e de diversidade espectral também apresentaram um ótimo desempenho dentro do modelo.

4.2.4. Combinação com diferentes atributos

Para âmbito de comparação, a partir da obtenção dos resultados dos gráficos 1 e 2 gerou-se uma tabela de combinações relacionando variáveis somente de verão (CV) ou variáveis somente de inverno (CI) com o intuito de avaliar a acurácia de cada uma dessas junções (Tabela 5).

Tabela 5: Combinação sazonal para variáveis de verão e inverno

Arquivo	CV-1	CV-2	CV-3	CI-1	CI-2	CI-3	CI-4	Modelo Completo
Bandas de inverno (10)				X	X	X	X	X
Bandas de verão (10)	X	X	X					X
Índices de vegetação de inverno (6)				X	X	X	X	X
Índices de vegetação de verão (6)	X	X	X					X
Camadas delta (6)							X	X
Camadas de textura de inverno (6)					X	X	X	X
Camadas de textura de verão (6)		X	X					X

Arquivo	CV-1	CV-2	CV-3	CI-1	CI-2	CI-3	CI-4	Modelo Completo
Camadas de textura delta (6)							X	X
Alpha diversidade de inverno (1)						X	X	X
Alpha diversidade de verão (1)			X					X
Componentes PCA de inverno (3)						X	X	X
Componentes PCA de verão (3)			X					X
Acurácia Global	70.8 %	73.5 %	73.8 %	83.1%	84.5%	83.8%	85.7%	86.4 %

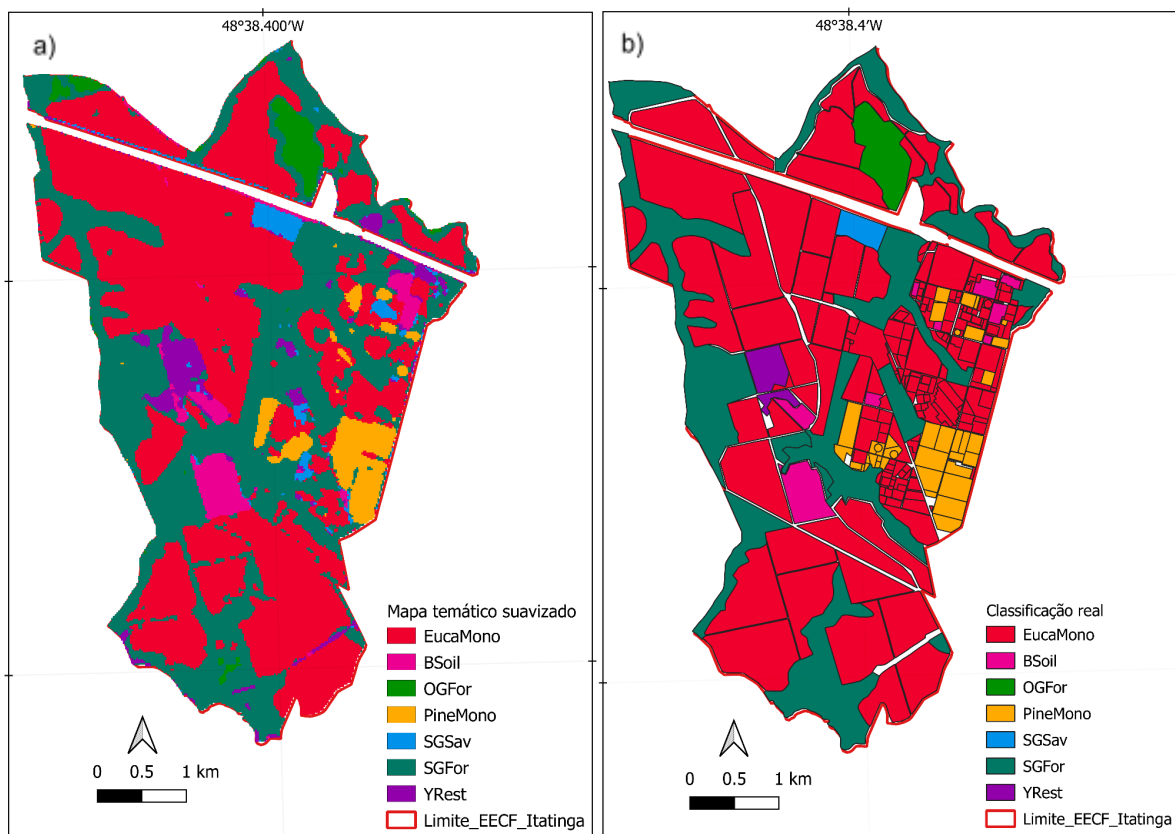
Fonte: Autoria própria, 2025.

Como observado, a combinação das variáveis de inverno apresentou uma acurácia global próxima da acurácia global do modelo completo, que utiliza as 64 variáveis. Esse resultado reflete no seu comportamento quanto ao MDA e na heterogeneidade da paisagem favorecida pela estação do ano.

4.3. MAPA TEMÁTICO

Analisando os resultados visualmente, temos o mapa temático final suavizado, com a eliminação de possíveis ruídos, onde é possível observar a localização de cada classe determinada pelo modelo e comparar com a classificação real da área de estudo (Figura 19).

Figura 19: Comparação entre o mapa temático final suavizado (a) gerado pelo modelo e o mapa com a classificação real (b) disponibilizada pela EECFI



Fonte: Autoria própria, 2025.

A classe YRest, de restauração inicial, se mantém com uma distinção das classes reais da área de estudo reforçando as dificuldades do modelo em separar formações estruturalmente heterogêneas.

5. COMPARAÇÃO COM OS RESULTADOS OBTIDOS NO ARTIGO DE HANEDA

Utilizando 66 variáveis, a metodologia desenvolvida por Haneda et al, 2023, alcançou uma acurácia global de 91,9%. Em seu estudo, Haneda utilizou o satélite VEN μ S, de resolução espacial de 5m, recorrência de 2 dias e 12 bandas de resolução espectral (Figura 20).

b)

Figura 20: Conjunto de diferentes combinações sazonais aplicadas às variáveis de verão.

Table 5

Description of the three combinations with different attributes configuration and their overall accuracy.

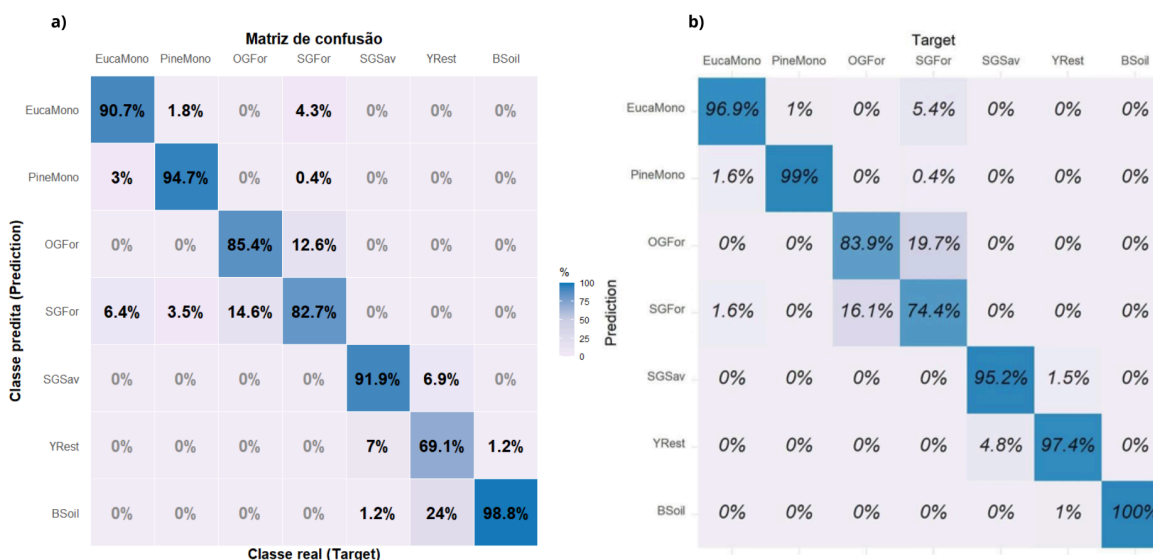
Layer	Comb. 1	Comb. 2	Comb. 3	Full Model
Winter bands (11)				X
Summer bands (11)	X	X	X	X
Winter vegetation indices (6)				X
Summer vegetation indices (6)	X	X	X	X
Delta layers (6)				X
Winter textural features (6)				X
Summer textural features (6)		X	X	X
Delta textural features (6)				X
Winter alpha diversity (1)				X
Summer alpha diversity (1)			X	X
Winter PCA components (3)				X
Summer PCA components (3)			X	X
OVERALL ACCURACY	77%	85.5%	87.6%	91.9%

Fonte: Leo Haneda et al, 2023

5.1. Matriz De Confusão

Analisando as duas matrizes de confusão (Figura 21) geradas em ambos os estudos nota-se que, embora o modelo de Haneda et al, 2023 tenha demonstrado um ótimo desempenho a metodologia e o modelo ainda apresentam dificuldades de distinguir classes de floresta tropical em estágio inicial (YRest), secundário (SGFor) e bem desenvolvido (OGFor). No caso do modelo gerado neste estudo, é possível observar uma elevada confusão na diferenciação de solo exposto (BSoil) e restauração inicial (YRest), essa resposta pode se apresentar devido a ausência de dossel denso das florestas em estágio inicial de plantio.

Figura 21: Comparação entre as matrizes de confusão deste estudo e da matriz publicada no artigo



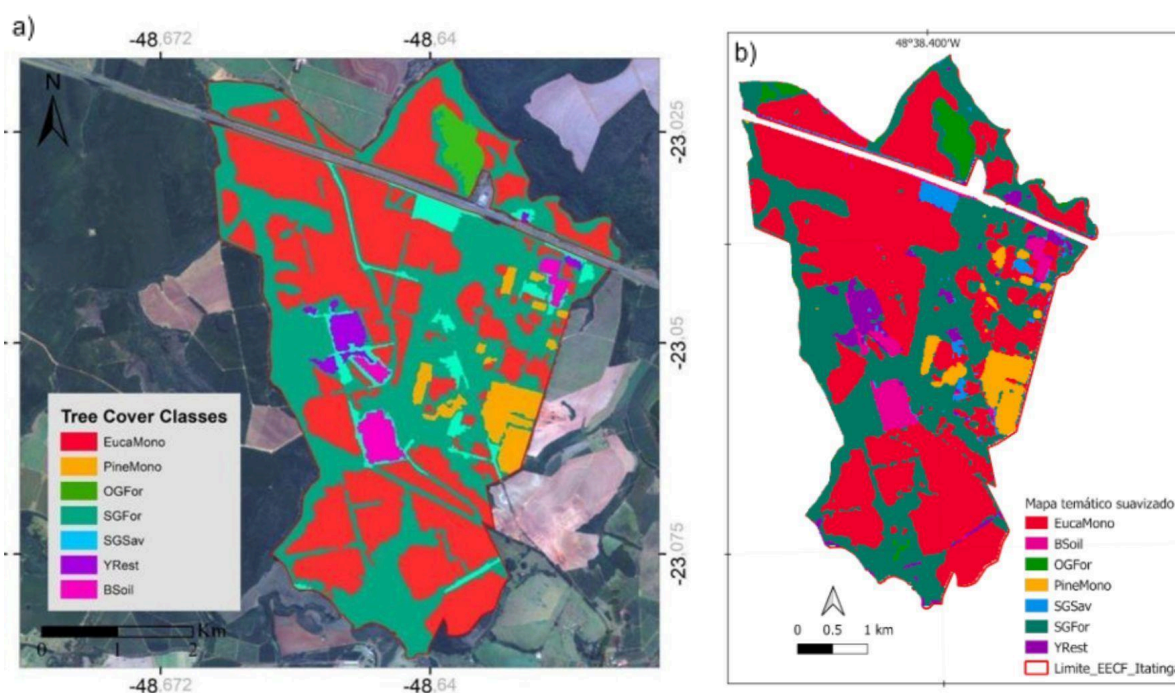
Fonte: Autoria própria, 2025

5.2. Comparação do Mapa Temático Final

Os mapas apresentados a seguir, ilustram o resultado da classificação supervisionada de ambos os trabalhos, gerados a partir de imagens orbitais com diferentes resoluções

espaciais e processados com o modelo *Random Forest*. O mapa (a), foi produzido com uma cena de 5 m de resolução espacial, do satélite VEN μ S, permitindo maior detalhamento das feições e revelando a complexidade espectral e estrutural da paisagem, o que resulta na identificação de pequenas manchas e maior fragmentação entre as classes. Já o mapa (b) gerado neste estudo, foi elaborado a partir de imagens Sentinel-2A e 2B com resolução espacial de 20 m, o que confere um padrão mais generalizado e homogêneo da cobertura florestal, reduzindo o ruído espacial e favorecendo a interpretação das tipologias em escala de paisagem (Figura 22).

Figura 22: Comparação entre os mapas temáticos finais suavizados, sendo: o mapa temático publicado no artigo (a) e o mapa temático gerado nesse projeto (b)



Fonte: Autoria própria, 2025

A diferença de resolução entre as imagens explica as variações de detalhamento e contorno observadas, sem comprometer a coerência geral entre os dois produtos. Em ambos os casos, destaca-se o predomínio das classes EucaMono e PineMono, representando os plantios homogêneos de silvicultura, seguidos por áreas de OGFor, SGFor, YRest e SGSav.

O uso combinado de índices espectrais, camadas sazonais e métricas de textura permitiu diferenciar essas formações com um bom desempenho, evidenciando o papel das bandas Red-Edge e SWIR na diferenciação estrutural e fenológica da vegetação. Assim, a análise comparativa entre as resoluções demonstra que, embora o detalhamento espacial influencie o grau de fragmentação identificado, o método aplicado mantém boa consistência temática e potencial para o monitoramento multiescalar de florestas tropicais e de processos

de restauração em cenários de mudanças climáticas.

6. ANALISANDO A METODOLOGIA APLICADA

O presente estudo com Sentinel-2 reforça que imagens multiespectrais de resolução média (10-20 m) podem ser eficazes para a classificação supervisionada de classes arbóreas contrastantes quando se emprega uma combinação de índices de vegetação, camadas sazonais (deltas), texturas e métricas de diversidade espectral. Em analogia ao trabalho de Haneda et al. (2023), que utilizou o satélite VEN μ S em paisagens restauradas no Brasil, apresentando altas acurácias ao adotar variáveis de diversidade espectral e fenologia, constatou-se que mesmo sensores de resolução inferior podem alcançar resultados altos se as variáveis extraídas analisarem bem a heterogeneidade da paisagem.

Em termos de comportamento espectral, foi possível confirmar que as bandas visível e NIR, isoladamente, têm limitações para distinguir classes como “Floresta semidecidual primária” e “secundária” ou monoculturas homogêneas, replicando o que Haneda et al. observaram. No entanto, incorporando bandas red-edge e SWIR, bem como texturas derivadas dos índices, é possível capturar diferenças funcionais e estruturais que não emergem apenas de reflectância simples. Estudos recentes com Sentinel-2 reforçam esse ponto: por exemplo, Donnini et al. (2024) demonstrou correlações significativas entre diversidade espectral derivada de Sentinel-2 e diversidade arbórea de campo em florestas do Quebec (Donnini et al., 2024); bem como Yang et al. (2024) que utilizou séries temporais de Sentinel-2 para mapeamento de espécies arbóreas baseado em perfis fenológicos (Yang et al., 2024).

A sazonalidade mostrou-se um diferencial importante: ao usar deltas entre estações (verão e inverno) e variáveis derivadas da estação de maior atividade foliar, foi possível ampliar a separabilidade entre classes mais similares. Isso corrobora achados de Jiang et al. (2025), que combinaram séries multitemporais de Sentinel-2 com LiDAR para identificação de espécies arbóreas e mostraram que combinações de três estações superam abordagens de uma ou duas estações (Jiang et al., 2025).

Com isso, apesar dos bons resultados, persistem limitações próprias de sensores de resolução intermediária: a mistura de pixels em fragmentos muito pequenos ou mistos, a cobertura de nuvens e a impossibilidade de capturar plenamente a estrutura tridimensional do dossel. A literatura recente sugere como caminho futuro a fusão de Sentinel-2 com dados LiDAR ou Radar para agregar profundidade estrutural e a extensão das séries temporais para capturar variabilidade interanual (Jiang et al., 2025). Assim, o presente estudo amplia o

arcabouço metodológico validado por Haneda et al. (2023) e demais trabalhos recentes, reforçando que a abordagem combinatória (índices + texturas + deltas sazonais + diversidade espectral) é promissora para monitoramento de restauração florestal, embora deva evoluir com fusões de dados, maior resolução e replicação em larga escala.

7. CONSIDERAÇÕES FINAIS

Este trabalho permitiu validar o potencial do satélite Sentinel-2 para escalar a metodologia de discriminação de tipologias florestais tropicais, com uma acurácia global superior a 80% no modelo *Random Forest*. O trabalho confirmou a capacidade do sensor *MultiSpectral Instrument* (MSI) em fornecer subsídios técnicos para o monitoramento contínuo e de baixo custo em programas de Restauração de Paisagens Florestais (FLR). O uso estratégico das bandas Red-Edge e SWIR do Sentinel-2 demonstrou ser fundamental na caracterização estrutural e fisiológica do dossel, reforçando a aplicabilidade do sensoriamento remoto disponível e de baixo custo para a gestão florestal.

A aplicação integrada de métricas espectrais, sazonais e estruturais demonstrou que a diversidade espectral é uma abordagem robusta para a distinção de tipologias florestais tropicais e para o entendimento dos impactos das mudanças climáticas sobre a vegetação. A análise sazonal destacou a relevância da variação fenológica na resposta espectral da vegetação, revelando padrões associados à disponibilidade hídrica e à dinâmica de estresse ambiental, fatores diretamente influenciados pelo clima.

Portanto, a metodologia proposta constitui um protocolo replicável e de baixo custo para o monitoramento da restauração e da saúde das florestas tropicais, fornecendo subsídios científicos essenciais para políticas públicas voltadas à conservação da biodiversidade, resiliência florestal e à mitigação dos efeitos das mudanças climáticas.

REFERÊNCIAS

Acharya, R.; Maraseni, T.; Cockfield, G. Tendência global da valoração dos serviços ecossistêmicos florestais – Uma análise de publicações. *Ecosyst. Serv.* 2019, 39, 100979.

Aguirre-Gutiérrez, J.; Rifai, S. W.; Deng, X. et al. Variação de características funcionais do dossel em florestas tropicais da Terra. *Nature*, v. 641, p. 129–136, 2025. DOI: 10.1038/s41586-025-08663-2.

Almeida, D. R. A. de et al. Remote sensing approaches to monitor tropical forest restoration: current methods and future possibilities. *Journal of Applied Ecology*, [s.l.], v. 62, n. 1, p. 110–124, 2025. DOI: 10.1111/1365-2664.14830. Disponível em: <https://besjournals.onlinelibrary.wiley.com/doi/full/10.1111/1365-2664.14830>. Acesso em: 27 ago. 2025.

Assis, L. S.; Campos, M.; Girão, V. J. (Orgs.). *Manejo de fragmentos florestais degradados*. Campinas, SP: The Nature Conservancy(TNC); Fundação José Pedro de Oliveira, 2019. 172 p. ISBN 978-85-60797-32-5. Disponível em: <https://www.tnc.org.br/content/dam/tnc/nature/en/documents/brasil/manejodefragmentosflorestaisdegradados.pdf>. Acesso em: 27 ago. 2025.

Belgiu, Mariana & Drăguț, Lucian. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*. 114. 24-31. 10.1016/j.isprsjprs.2016.01.011.

Bonn Challenge. *Impacto e potencial da restauração da paisagem florestal (Relatório em português)*. Gland, Suíça: International Union for Conservation of Nature, 2020. Disponível em: <https://www.bonnchallenge.org/sites/default/files/resources/files/%5Bnode%3Anid%5D/Bonn%20Challenge%20Report%20-%20Portuguese.pdf>. Acesso em: 27 ago. 2025.

Brançalion, P. H. S. et al. Global restoration opportunities in tropical rainforest landscapes. *Science Advances*, Washington, v. 5, n. 7, p. eaav3223, 10 jul. 2019. DOI: 10.1126/sciadv.aav3223. Disponível em: <https://www.science.org/doi/10.1126/sciadv.aav3223>. Acesso em: 25 ago. 2025.

Brançalion, P.; Vieira, D.; Celentano, D. *Protocolo de monitoramento da restauração da Mata Atlântica e da Amazônia via sensoriamento remoto*. 2024. Disponível em: https://www.researchgate.net/publication/382879665_protocolo_de_monitoramento_da_resta

uracao_da_mata_atlantica_e_da_amazonia_via_sensoriamento_remoto. Acesso em: 27 ago. 2025.

Brasil. Ministério do Meio Ambiente e Mudança do Clima (MMA). Florestas do Brasil – Dados e estatísticas. FLOBR, 2024, v0-24. Brasília, 2024. Disponível em: https://www.gov.br/florestal/pt-br/centrais-de-conteudo/publicacoes/publicacoes-diversas/flob_r_2024_v0-24___online.pdf. Acesso em: 27 ago. 2025.

Conto, T., Armston, J. & Dubayah, R. Caracterizando a complexidade estrutural das florestas da Terra com lidar espacial. *Nat Commun* 15, 8116 (2024). <https://doi.org/10.1038/s41467-024-52468-2>.

Costa, FRC, Schietti, J., Stark, SC e Smith, MN (2023), O outro lado da seca nas florestas tropicais: as regiões com lençóis freáticos rasos da Amazônia atuam como refúgios hidrológicos em larga escala contra a seca? *New Phytol*, 237: 714-733. <https://doi.org/10.1111/nph.17914>

Breiman, L. Random forests. *Machine Learning*, v. 45, p. 5–32, 2001.

Chaves, M. E. D.; Picoli, M. C. A.; Sanches, I. D. Recent applications of Landsat 8/OLI and Sentinel-2/MSI for land use and land cover mapping: a systematic review. *Remote Sensing*, v. 12, n. 18, p. 3062, 2020. DOI: <https://doi.org/10.3390/rs12183062>.

Chazdon, R. L., Blüthgen, N., Brancalion, P. H., Heinrich, V., & Bongers, F. (2025). Drivers and benefits of natural regeneration in tropical forests. *Nature Reviews Biodiversity*, 1-17. <https://doi.org/10.1038/s44358-025-00043-y>.

Chen, Gang., Zhou, Yuyu., Voog, James A.t., Stokes, Eleanor C. Remote sensing of diverse urban environments: From the single city to multiple cities, *Remote Sensing of Environment*, Volume 305, 2024, 114108, ISSN 0034-4257, <https://doi.org/10.1016/j.rse.2024.114108>.

Cooper, DLM, Lewis, SL, Sullivan, MJP et al. Padrões consistentes de espécies comuns em comunidades de árvores tropicais. *Nature* 625, 728–734 (2024). <https://doi.org/10.1038/s41586-023-06820-z>

Copernicus Data Space Ecosystem. Sentinel-2 – Documentation. [S.l.]: Copernicus, [s.d.]. Disponível em: <https://documentation.dataspace.copernicus.eu/Data/SentinelMissions/Sentinel2.html>. Acesso

em: 27 ago. 2025.

Coutinho, L. M. *Biomass brasileiros*. São Paulo: Oficina de Textos, 2016. E-book. ISBN 9788579752551. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9788579752551/>. Acesso em: 26 ago 2025.

Crespo-Antia, J. P. et al. Correspondência de índices de vegetação e vigor de árvores em povoamentos de abetos prateados dos Pireneus. *Remote Sensing*, v. 16, p. 4564, 2024. DOI: 10.3390/rs16234564.

Dronova, I. Remote sensing of vegetation phenology: towards the comprehensive characterization of terrestrial vegetation phenology using satellite data. *Journal of Ecology*, v. 110, n. 7, p. 1329–1349, 2022. DOI: 10.1111/1365-2745.13897.

Donini, J., Et Al. (2024). Spectral Diversity as a Predictor of Tree Diversity: Exploring challenges and opportunities across forest ecosystems. *Journal*.

Dutrieux, L. P.; Haneda, L.; Molin, P. G. Spectral metrics for tropical forest functional mapping using Sentinel-2 time series. *Remote Sensing of Environment*, v. 304, p. 114038, 2024.

Dwiputra, A.; Coops, N. C.; Schwartz, N. B. Gedi waveform metrics in vegetation mapping — a case study from a heterogeneous tropical forest landscape. *Environmental Research Letters*, v. 18, n. 1, p. 015007, 2023. DOI: 10.1088/1748-9326/acad8d.

Empresa Brasileira De Pesquisa Agropecuária – Embrapa. Utilizando técnicas preditivas que combinam modelagem e seleção de atributos. Brasília: Embrapa, 2015. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1033086/1/utlizandotecnicas.pdf>.

European Space Agency. Sentinel-2 – Documentation: Level-2A Surface Reflectance. [s.l.], 2023. Disponível em: <https://documentation.dataspace.copernicus.eu/Data/SentinelMissions/Sentinel2.html>. Acesso em: 29 ago. 2025.

European Commission; ESA. Sentinel-2. Copernicus Data Space Ecosystem. [S.l.], 2024. Disponível em: <https://dataspace.copernicus.eu/data-collections/copernicus-sentinel-data/sentinel-2>. Acesso

em: 29 ago. 2025.

ESALQ/USP. Sistema de Valoração Econômica do Ecossistema: Estação Experimental de Ciências Florestais – Itatinga. Disponível em: <https://www.esalq.usp.br/svee/lcf-itatinga>. Acesso em: 13 mai. 2025.

European Union; European Space Agency. Sentinel-2: Data Collection. Disponível em: <https://dataspace.copernicus.eu/data-collections/copernicus-sentinel-data/sentinel-2>. Acesso em: 27 ago. 2025.

Farwell, L. S. et al. Satellite image texture captures vegetation heterogeneity and explains patterns of bird richness. *Remote Sensing of Environment*, v. 253, p. 112175, 2021. DOI: 10.1016/j.rse.2020.112175.

Féret, Jean-Baptiste; De Boissieu, Florian. BiodivmapR: An R package for α - and β -diversity mapping using remotely sensed images. *Methods in Ecology and Evolution*, v. 11, n. 1, p. jan. 2019.

Féret, J.-B. et al. biodivMapR: an R package for α and β -diversity mapping using spectral species concept. *Ecological Informatics*, v. 68, p. 101568, 2022.

Garcia, Bruno. A inserção da Agroecologia na Estação Experimental de Ciências Florestais de Itatinga (EECFI). *Cadernos de Agroecologia*, São Cristóvão, SE, v. 15, n. 2, 2020. Disponível em: <https://cadernos.aba-agroecologia.org.br/cadernos/article/view/5998/3482>. Acesso em: 05 nov. 2025.

González-Chaves, A. D.; Carvalheiro, L. G.; Piffer, P. R.; D'albertas, F.; Giannini, T. C.; Viana, B. F.; Metzger, J. P. Evidence of time-lag in the provision of ecosystem services by tropical regenerating forests to coffee yields. *Environmental Research Letters*, v. 18, n. 2, p. 025002, 2023. DOI: <https://doi.org/10.1088/1748-9326/acb161>.

Gfw: Goldman, E.; Carter, S.; Sims, M. Fires drove record-breaking tropical forest loss in 2024. Washington, DC: World Resources Institute, 2025. Disponível em: <https://gfr.wri.org/latest-analysis-deforestation-trends>. Acesso em: 26 ago. 2025.

Haneda, L. E. Et Al. Forest landscape restoration: spectral behavior and diversity of tropical tree cover classes. *Remote Sensing Applications: Society and Environment*, v. 29, p. 100882, 2023. DOI: 10.1016/j.rsase.2022.100882.

Index Database. Index: Chlorophyll Red-Edge (Chlred-edge). [S.l.]: IndexDatabase. [s.d]. Disponível em: <https://www.indexdatabase.de/db/i-single.php?id=252>.

INITIATIVE 20x20. Website. [S.l.], [s.d.]. Disponível em: <https://initiative20x20.org/>. Acesso em: 27 ago. 2025.

Instituto Do Homem E Meio Ambiente Da Amazônia (Imazon). Boletim SAD – Dez/2024. Belém: Imazon, jan. 2025. Disponível em: https://imazon.fly.storage.tigris.dev/uploads/2025/01/INFBoletimSAD_Dez2024_A4_297x210_ImprePessoal.pdf. Acesso em: 26 ago. 2025.

International Climate Initiative (IKI). The Forest Landscape Restoration (FLR) Implementation Hub: delivering the Bonn Challenge. [S.l.]: IKI, 2023. Disponível em: <https://www.international-climate-initiative.com/PROJECT2136-1>. Acesso em: 27 ago. 2025.

International Union For Conservation Of Nature (IUCN). Restoration Barometer V9. Gland: IUCN, dez. 2022. Disponível em: https://restorationbarometer.org/wp-content/uploads/BE_IUCN_RestorationBarometer_V9.pdf. Acesso em: 27 ago. 2025.

Interfaith Rainforest Initiative. Tropical Forests: a resource under threat (issue primer) [versão português]. [S.l.]: Interfaith Rainforest Initiative, [s.d.]. Disponível em: https://www.interfaithrainforest.org/s/Interfaith_IssuePrimer_TropicalForests_PT.pdf. Acesso em: 27 ago. 2025.

Jiang, Y., Li, X., Peng, L., Li, C., & Song, T. (2025). Assessing the potential of multi-seasonal Sentinel-2 satellite imagery combined with airborne LiDAR for tree species classification. *Scientific Reports*, 15, 25107.

Kacic, J. et al. Spectral diversity as a bridge between biodiversity and remote sensing observations. *Ecological Indicators*, v. 145, p. 109757, 2022.

Keith, DA, Ferrer-Paris, JR, Nicholson, E. et al. Uma tipologia baseada em funções para os ecossistemas da Terra. *Nature* 610, 513–518 (2022). <https://doi.org/10.1038/s41586-022-05318-4>

Li, P.; Li, W.; Shi, D.; Nath, A. J. Normalized Difference Red-NIR-SWIR: a new Sentinel-2 three-band spectral index for mapping freshly opened swiddens in the tropics. *Ecological*

Informatics, v. 82, p. 102775, 2024. DOI: 10.1016/j.ecoinf.2024.102775.

Liu, H.; Cao, Y.; Xiao, J.; Yuan, Z.; Hao, Z.; Bai, X.; Wu, Y.; Liu, Y. A daily gap-free Normalized Difference Vegetation Index (NDVI) dataset from 1981–2023 in China. *Scientific Data*, v. 10, p. 121, 2024. DOI: 10.1038/s41597-023-02096-0.

Ma, J., Li, J., Wu, W. et al. Global forest fragmentation change from 2000 to 2020. *Nat Commun* 14, 3752 (2023). DOI: <https://doi.org/10.1038/s41467-023-39221-x>.

Ma, M.; Liu, J.; Liu, M.; Zeng, J.; Li, Y. Tree Species Classification Based on Sentinel-2 Imagery and Random Forest Classifier in the Eastern Regions of the Qilian Mountains. *Forests* 2021, 12, 1736. DOI: <https://doi.org/10.3390/f12121736>.

Magnago, L. F. S. Et Al. Loss of biodiversity and shifts in aboveground biomass drivers in tropical rainforests with different disturbance histories. *Biodiversity and Conservation*, v. 27, n. 13, p. 3399–3413, 2018.

MapBiomias. MapBiomias Brasil – Plataforma de cobertura e uso da terra no Brasil. Infográficos, [S.l.], [s.d.]. Disponível em: <https://brasil.mapbiomas.org/infograficos/>. Acesso em: 27 ago. 2025.

MapBiomias. Relatório Anual do Desmatamento no Brasil – RAD, 2024. São Paulo: MapBiomias, 15 maio 2025. Disponível em: https://alerta.mapbiomas.org/wp-content/uploads/sites/17/2025/05/RAD2024_15.05.pdf. Acesso em: 26 ago. 2025.

Matunaga, H. Monitoramento da biodiversidade em áreas de restauração florestal: uma abordagem integrada de sensoriamento remoto. TCC (Graduação) – Universidade Federal de São Carlos (UFSCar), Lagoa do Sino, 2022.

Mattos, R. Q. M. A. Florestas. [S.l.]: Embrapa, 2021. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1143844/1/Mattos-RQMA-Florestas.pdf>. Acesso em: 25 ago. 2025.

Mohammadpour, P.; Viegas, DX; Viegas, C. Mapeamento de Vegetação com Floresta Aleatória Utilizando Sentinel 2 e GLCM Texture Feature – Um Estudo de Caso para a Região da Lousã, Portugal. *Sensor Remoto* 2022, 14, 4585. <https://doi.org/10.3390/rs14184585>

Moreno, V. S. Ecologia funcional de florestas estacionais semidecíduais em paisagens

agrícolas da Mata Atlântica. 2019. Tese (Doutorado em Ciências – Recursos Florestais) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2019. Disponível em:

https://teses.usp.br/teses/disponiveis/11/11150/tde-22082019-152301/publico/Vanessa_de_Souza_Moreno_versao_revisada.pdf. Acesso em: 27 ago. 2025.

Nasiri, V.; Hawryło, P.; Tompalski, P.; Wertz, B.; Socha, J. Linking remotely sensed growth-related canopy attributes to interannual tree-ring width variations: a species-specific study using Sentinel optical and SAR time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 221, 2025. DOI: 10.1016/j.isprsjprs.2025.02.002.

Oscó, L. P. Avanços em aprendizagem profunda aplicada ao sensoriamento remoto. 2023. Tese (Doutorado em Tecnologias Ambientais) – Universidade Federal de Mato Grosso do Sul, Campo Grande, 2023. Disponível em: https://repositorio.ufms.br/retrieve/ec1e95aa-ef37-4dda-8b9f-122f59418d72/TeseUFMS_LucasOscó_v4_Combinado_Comp.pdf. Acesso em: 27 ago. 2025.

Pacto Pela Restauração Da Mata Atlântica. Cartilha comemorativa: 15 anos do Pacto pela Restauração da Mata Atlântica. São Paulo: Pacto pela Restauração da Mata Atlântica, 2024. Disponível em: <https://www.pactomataatlantica.org.br/wp-content/uploads/2024/08/cartilha-comemorativa-Pacto-15-Anos-Web.Pdf>. Acesso em: 27 ago. 2025.

Pitkänen, T. P.; Balazs, A.; Tuominen, S. Automated Sentinel-2 mosaicking for large area forest mapping. *International Journal of Applied Earth Observation and Geoinformation*, v. 127, p. 103659, 2024. DOI: 10.1016/j.jag.2024.103659.

Ramos, D. M.; Andrade, J. M.; Alberton, B. C.; et al. Multiscale phenology of seasonally dry tropical forests in an aridity gradient. *Frontiers in Environmental Science*, v. 11:1275844, 2023. DOI: 10.3389/fenvs.2023.1275844.

Ribeiro, L. S. Et Al. Spectral diversity as a proxy for vegetation heterogeneity in tropical restoration landscapes. *Remote Sensing Applications: Society and Environment*, v. 35, p. 101929, 2024.

Rigatti, S. J. Floresta aleatória. *Revista de Medicina de Seguros*, v. 47, n. 1, p. 31–39, 2016. DOI: 10.17849/in-sm-47-01-31-39.1.

Rodríguez-Puerta, F. et al. Five-year evaluation of Sentinel-2 cloud-free mosaic generation under varied cloud cover conditions in Hawai'i. *Remote Sensing*, v. 16, n. 24, p. 4791, 2024.

Rossi, Christian & Kneubuehler, Mathias & Schuetz, Martin & Schaepman, Michael & Haller, Rudolf & Risch, Anita. (2021). Remote sensing of spectral diversity: A new methodological approach to account for spatio-temporal dissimilarities between plant communities. *Ecological Indicators*. 130. 108106. 10.1016/j.ecolind.2021.108106.

Sentinel Hub¹. Sentinel-2 Bands, s.d.. Disponível em: <https://custom-scripts.sentinel-hub.com/custom-scripts/sentinel-2/bands/>. Acesso em: 05 nov. 2025.

Sentinel Hub Custom Scripts². EVI (Enhanced Vegetation Index). Sentinel-2. [S.l.]: Sentinel Hub, s.d.. Disponível em: <https://custom-scripts.sentinel-hub.com/custom-scripts/sentinel-2/evi/>.

Segarra, J; Buchailot, M. L; Araus, J. L; Kefauver, S. C. Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications. *Agronomy*, v.10, n.5, p.641-648, 2020.

Silva, Carlos Alberto, Valbuena, R., Pinagé, E. R., Mohan, M., de Almeida, D. R. A., Broadbent, E. N., Jaafar, W. S. W. M., de Almeida Papa, D., Cardil, A., & Klauberg, C. (2019). ForestGapR: An R Package for Forest Gap Analysis from Canopy Height Models. *Methods in Ecology and Evolution*. <https://doi.org/10.1111/2041-210X.13211>.

Silva, D. A. Da; Ferreira, M. E.; Ferreira, L. G. Análise da degradação florestal na Amazônia utilizando séries temporais de imagens Landsat e computação em nuvem (Google Earth Engine). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais de evento. São José dos Campos: INPE, 2015. p. 896-903. Disponível em: <http://www.dsr.inpe.br/sbsr2015/files/p0896.pdf>. Acesso em: 28 ago. 2025.

Silva, J. N. B. da et al. Estimativas de sequestro de carbono por diferentes métodos em ecossistemas florestais: uma abordagem sobre a floresta tropical sazonalmente seca (Caatinga). *Revista Brasileira de Meio Ambiente*, v. 12, n. 1, p. 75–93, 2024. DOI: 10.5281/zenodo.11267197.

Sorrini, T. B. Restaurando o *campus*: envolvendo alunos e plantando árvores para a transformação ambiental da ESALQ/USP. 2022. Dissertação/Tese (Recursos Florestais) –

ESALQ/USP, Piracicaba, 2022.

Tan, J.; Li, J.; Ma, T.; Yan, X.; Huo, Z. Leveraging Sentinel-1/2 time series and deep learning for accurate forest tree species mapping. *Frontiers in Forests and Global Change*, v. 8, 2025. DOI: 10.3389/ffgc.2025.1599510.

Yang, B., et al. (2024). Mapping Forest Tree Species Using Sentinel-2 Time Series Data with High Temporal and Spatial Resolution. *Journal: Forests*.

Zhang, Y.; Fan, Z.; Yan, W.; Ge, C.; Sun, H. A practical method for red-edge band reconstruction for Landsat image by synergizing Sentinel-2 data with machine learning regression algorithms. *Sensors (Basel)*, v. 25, n. 11, p. 3570, 2025. DOI: 10.3390/s25113570.