



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

NÍVEA MARIA MAFRA RODRIGUES

**CARACTERIZAÇÃO ESPECTRAL E FUSÃO DE DADOS LIDAR E HIPERESPECTRAIS
COLETADOS POR DRONE PARA ESTIMAR A BIOMASSA ACIMA DO SOLO DE
FLORESTAS SECUNDÁRIAS DA MATA ATLÂNTICA**

JERÔNIMO MONTEIRO – ES

2025

NÍVEA MARIA MAFRA RODRIGUES

**CARACTERIZAÇÃO ESPECTRAL E FUSÃO DE DADOS LIDAR E HIPERESPECTRAIS
COLETADOS POR DRONE PARA ESTIMAR A BIOMASSA ACIMA DO SOLO DE
FLORESTAS SECUNDÁRIAS DA MATA ATLÂNTICA**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutora em Ciências Florestais na Área de Concentração Ciências Florestais.

Orientador: Dr. Gilson Fernandes da Silva

Coorientador: Dr. André Quintão de Almeida

JERÔNIMO MONTEIRO – ES

2025

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

R696c Rodrigues, Nívea Maria Mafra, 1995-
Caracterização espectral e fusão de dados LiDAR e hiperspectrais coletados por drone para estimar a biomassa acima do solo de florestas secundárias da Mata Atlântica / Nívea Maria Mafra Rodrigues. - 2025.
141 f.

Orientador: Gilson Fernandes da Silva.
Coorientador: André Quintão de Almeida.
Tese (Doutorado em Ciências Florestais) - Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias.

1. Sensoriamento remoto. 2. Floresta tropical. 3. Biomassa.
I. Silva, Gilson Fernandes da. II. Almeida, André Quintão de.
III. Universidade Federal do Espírito Santo. Centro de Ciências Agrárias e Engenharias. IV. Título.

CDU: 630*38

CARACTERIZAÇÃO ESPECTRAL E FUSÃO DE DADOS LIDAR E HIPERESPECTRAIS COLETADOS POR DRONE PARA ESTIMAR A BIOMASSA ACIMA DO SOLO DE FLORESTAS SECUNDÁRIAS DA MATA ATLÂNTICA

Nívea Maria Mafra Rodrigues

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutora em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 28 de março de 2025.



Documento assinado digitalmente

CATHERINE TORRES DE ALMEIDA

Data: 26/05/2025 14:32:10-0300

Verifique em <https://validar.iti.gov.br>

Profa. Dra. Catherine Torres de Almeida (Examinadora externa)
Universidade Federal do Paraná



Documento assinado digitalmente

FABIO GUIMARAES GONCALVES

Data: 26/05/2025 15:12:47-0300

Verifique em <https://validar.iti.gov.br>

Dr. Fábio Guimarães Gonçalves (Examinador externo)
Canopy Remote Sensing Solutions



Documento assinado digitalmente

RORAI PEREIRA MARTINS NETO

Data: 26/05/2025 08:33:33-0300

Verifique em <https://validar.iti.gov.br>

Dr. Rorai Pereira Martins Neto (Examinador externo)
Czech University of Life Sciences Prague



Documento assinado digitalmente

Eric Bastos Gorgens

Data: 26/05/2025 19:02:08-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Eric Bastos Gorgens (Examinador externo)
Universidade Federal dos Vales do Jequitinhonha e Mucuri



Documento assinado digitalmente

GILSON FERNANDES DA SILVA

Data: 27/05/2025 09:06:15-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Gilson Fernandes da Silva (Orientador)
Universidade Federal do Espírito Santo

DEDICATÓRIA

À minha mãe, minha avó, minhas irmãs e Denyse, por todo amor, força e apoio incondicional.
Dedico.

AGRADECIMENTOS

Escrever esta tese foi uma jornada desafiadora, que não teria sido possível sem o apoio de tantas pessoas. Tento agora colocar em palavras minha gratidão a cada um que, de alguma forma, esteve presente nesta caminhada, seja com incentivo, companhia, amor ou simples gestos que tornaram os dias mais leves.

À Deus, minha primeira e eterna gratidão. Pela força nos momentos difíceis, pela esperança que nunca me deixou e pelas oportunidades que se abriram no momento certo. Por colocar em meu caminho pessoas incríveis e, principalmente, por me lembrar todos os dias que cada esforço vale a pena.

À minha família, meu porto seguro em todos os momentos. À minha mãe, exemplo de força e amor incondicional. Obrigada por ser meu alicerce, por me ensinar, desde sempre, que o conhecimento é uma das maiores riquezas que podemos ter. Às minhas irmãs, que sempre estiveram ao meu lado, vibrando com cada conquista. O amor de vocês me fortalece. À minha avó, que com sua sabedoria e ternura me ensinou tanto, mesmo sem precisar dizer muito. Seu amor, suas orações e seu olhar cheio de orgulho me acompanharam em cada passo dessa jornada. A vocês, minha base, minha razão, minha inspiração. Se cheguei até aqui, foi porque nunca caminhei sozinha. Obrigada por tudo.

À minha companheira de vida, Denyse, que esteve ao meu lado desde a graduação, sendo minha base e minha fortaleza. Obrigada por me levantar nos momentos difíceis, por ser minha alegria diária, por ter me aturado nos dias cinzas e por me fazer entender que tudo bem tê-los, que eu não preciso me cobrar demais. Te amo imensamente e sou grata todos os dias por dividir a vida com você.

Ao meu coorientador e amigo, André Quintão, não sei colocar em palavras o quanto você foi importante nessa caminhada. Você pegou na minha mão e disse 'vamos', e assim segui aprendendo e crescendo. Muito do que sei sobre sensoriamento remoto veio de você, mas o aprendizado foi muito além disso. Além de um professor excepcional, você é um amigo, alguém que sempre esteve presente, tanto na minha evolução profissional quanto no meu crescimento pessoal. Sempre digo que, se um dia eu for 10% do professor que você é, estarei satisfeita. Seu olhar vai além do profissional, sua empatia e dedicação fazem de você um dos meus maiores exemplos. Obrigada por tudo!

Agradeço ao meu orientador, Gilson Fernandes, com quem tenho a honra de caminhar desde 2019, desde o mestrado. Lembro exatamente do momento em que mencionei meu interesse em trabalhar com sensoriamento remoto e do seu imediato apoio, algo que fez toda a diferença no meu percurso. Sempre solícito, esteve presente nos

momentos decisivos, incentivando e abrindo portas. Sou muito grata por todo o aprendizado e pela confiança ao longo desses anos.

Ao Jeferson e à Taís, amigos que a vida acadêmica me deu. Jeferson, quase um irmão, sempre esteve ao meu lado desde 2019, me ajudou demais na qualificação e nunca hesitou em ser solícito. Taís, um exemplo de profissional e de pessoa, inteligente e cuidadosa, cuja amizade se tornou um presente nessa caminhada. Nossos momentos de descontração no Bar do Nicola, entre churrascos e cervejas, foram muito mais do que simples encontros; foram oportunidades para desestressar, compartilhar ideias e até mesmo planejar artigos, livros e soluções para a tese. Entre risadas e conversas, crescemos juntos.

À Quétilla, sou imensamente grata por todo o apoio, pela ajuda na qualificação e pelos convites para participar de artigos, sempre me incentivando a crescer. Além disso, agradeço pelas boas conversas e pelas risadas que tornaram os dias mais leves. Sua generosidade e parceria fizeram toda a diferença.

À Carem, a carioca mais enjoada da face da Terra, mas também uma amiga e tanto! Lembro perfeitamente da primeira vez que a vi, sentada no banquinho ao lado do auditório, me esperando. Depois daquele dia, ela simplesmente alugou uma mesa no laboratório de Mensuração e Manejo e nunca mais saiu — e, desde então, segue firme perturbando meu juízo! Mas a verdade é que sou imensamente grata por tudo: por tornar os dias mais leves, por ser parceira em todas as horas e por sempre estar por perto.

Agradeço imensamente a todos que participaram da coleta de dados, seja no inventário florestal ou no sensoriamento remoto. Cada um foi essencial para que tudo isso fosse possível. Em especial, meu muito obrigado ao Lucas Caldas, que comandou o inventário florestal com todo o capricho e profissionalismo, sendo peça-chave nesse processo. À Jéssica, que identificou quase todas as espécies com uma habilidade invejável — sem dúvidas, a melhor pessoa de campo que eu conheço! Agradeço também ao Lucas Batista, que pegou o bonde do projeto andando e mesmo assim ajudou demais na identificação das espécies. Ao seu Ademar, o escalador, que tornou possível a coleta das amostras para identificação. E ao Lucas Lobato, pela amizade e pela força (literalmente!) ao carregar a caixa do drone morro acima sem nem hesitar.

Ao Igor, meu grande amigo, não poderia deixar de agradecer. Esteve comigo lá no começo, quando tudo ainda era um grande ponto de interrogação. Juntos, quebramos a cabeça tentando entender como funcionava o sensor hiperespectral, e cada descoberta foi ainda mais especial porque foi compartilhada. Obrigada por toda a parceria, paciência e por fazer parte dessa caminhada desde o início!

Às minhas queridas amigas Tatiana e Alessandra, obrigada por, mesmo longe, sempre se fazerem presentes. A amizade de vocês tornou essa jornada mais leve.

Agradeço à Valéria, companheira de laboratório e a verdadeira “resolve tudo” do lab. Seu conhecimento, paciência e disposição para ajudar foram essenciais ao longo desse tempo. Além disso, seu apoio e parceria tornaram tudo mais fácil e leve.

Agradeço aos amigos de viagem da França, Thaís, Emerson e Eduarda, por terem tornado essa experiência ainda mais especial. Foram dias intensos, mas cheios de boas conversas, risadas e descobertas. Voyage, voyage... plus loin que la nuit et le jour!

Ao Instituto de Defesa Agropecuária e Florestal do Espírito Santo - IDAF responsável pela execução do Projeto "Proposição de um protocolo para identificação de estágios sucessionais com o uso de ferramentas de sensoriamento remoto", vinculado ao INOVAGRO com apoio financeiro da Secretaria de Estado de Agricultura, Abastecimento, Aquicultura e Pesca (SEAG) via FAPES - Processo 2020-4KK4L - Portaria 002-R/2020.

À FAPES - Fundação de Amparo à Pesquisa e Inovação do Espírito Santo, por meio do projeto “Aprimoramento da estimativa de biomassa florestal acima do solo do estado do Espírito Santo integrando dados LiDAR, imagens multiespectrais e hiperespectrais” - Processo 2022-TQ618, pelo apoio financeiro da pesquisa.

Ao Programa de Pós-Graduação pela oportunidade e à CAPES pelo apoio financeiro por meio da bolsa de estudo – código de financiamento 001.

Agradeço aos proprietários das áreas estudadas por abrirem as portas para a pesquisa e contribuírem com este trabalho. Um agradecimento especial à Floresta Nacional de Pacotuba, em nome da Augusta, pelo apoio e disponibilidade ao longo de todo o processo.

Agradeço ao Emanuel, coordenador de um dos projetos que financiou esta pesquisa, por não apenas viabilizar o estudo, mas também por colocar a mão na massa — indo a campo, participando do inventário e ajudando nos sobrevoos. E um obrigado especial ao Tobias, com quem compartilhei dados, áreas e, claro, muitos estresses. Nós dois sabemos o quanto foi desafiador trabalhar com esses dados, especialmente com o sensor hiperespectral e suas particularidades um tanto... peculiares.

Agradeço à equipe LaMFlor, uma equipe nota 1000, que mais do que colegas de trabalho, se tornou uma verdadeira família. André, Jeferson, Lucas Lobato, Klisman, Ricardo, Mikaely, Lais, Millena, Gabriel, Tobias, Luiz, Eloisa, Fernanda, Igor, Leon, Eduarda, Eduardo, Lucas Caldas, Carem, Valéria, João Vitor, Sayara e Arien – cada um de vocês contribuiu de alguma forma, seja com apoio técnico, boas conversas, cafezin,

parceria nas análises ou simplesmente tornando os dias mais leves. Foi um privilégio dividir essa etapa com vocês!

Com muito respeito e admiração, agradeço aos membros da banca examinadora na defesa de projeto, Carlos Boechat e Hassan Camil David, que contribuíram para o aprimoramento da pesquisa. Sou igualmente grata ao professor Diogo Cosenza, que integrou a banca de qualificação e desempenhou papel importante no delineamento da tese, oferecendo sugestões valiosas nas etapas iniciais. Agradeço ainda aos membros da banca examinadora da defesa de Tese, Catherine Almeida, Eric Gorgens, Fábio Gonçalves e Rorai Martins-Neto, pelas valiosas contribuições, que enriqueceram significativamente esse trabalho. Cada sugestão foi cuidadosamente analisada e incorporada à Tese.

A todos que contribuíram não só para a realização desse trabalho, mas também para o meu crescimento profissional e pessoal, meu mais sincero agradecimento. Cada conversa, incentivo, colaboração e momento compartilhado foram essenciais para que essa trajetória fosse possível. Obrigada por tudo!

“Todas as vitórias ocultam uma abdicação.”
Simone de Beauvoir

RESUMO

RODRIGUES, Nívea Maria Mafra. **Caracterização espectral e fusão de dados LiDAR e hiperespectrais coletados por drone para estimar a biomassa acima do solo de florestas secundárias da Mata Atlântica**. 2025. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Dr. Gilson Fernandes da Silva. Coorientador: Dr. André Quintão de Almeida.

As florestas tropicais desempenham um papel fundamental no ciclo global do carbono, na conservação da biodiversidade, do solo e da água e oferecem uma vasta gama de serviços ecossistêmicos. Portanto, aprimorar o monitoramento das florestas tropicais com dados coletados por aeronave remotamente pilotada (RPA) é de fundamental importância para assegurar esses serviços. Tendo em vista o exposto, este trabalho teve como objetivo avaliar a utilização de dados hiperespectrais coletados por RPA para caracterizar a vegetação de fragmentos de floresta secundária da Mata Atlântica em diferentes estágios sucessionais. Além disso, também foi um objetivo combinar dados LiDAR e hiperespectrais para aprimorar a estimativa da biomassa acima do solo (AGB) e espacializar as estimativas nestas áreas. Para tal, foram identificados e inventariados todos os indivíduos arbóreos com diâmetro à altura do peito (D , medido a 1,3 m do solo) > 5 cm de 30 parcelas de campo (30 m x 30 m cada) de cinco remanescentes florestais localizados no sul do estado do Espírito Santo. Nuvens de pontos aéreas de LiDAR e cubos de imagens hiperespectrais foram geradas para todos os fragmentos analisados. Em seguida, foram estimadas métricas tradicionais e derivadas da transformada de Fourier a partir das alturas da nuvem de pontos, bem como informações espectrais, incluindo valores de reflectância e índices de vegetação, para cada parcela. A AGB de campo foi estimada utilizando uma equação alométrica ajustada para floresta estacional semidecidual. Foi possível diferenciar os estágios sucessionais dos fragmentos florestais secundários analisados com os dados hiperespectrais coletados por RPA. No contexto de florestas tropicais secundárias, caracterizadas por alta variabilidade estrutural e diferentes estágios sucessionais, a integração de dados LiDAR e hiperespectrais resultou em ganhos mínimos na precisão da estimativa de AGB. Em alguns casos, a fusão dos dados não trouxe melhorias em relação aos modelos baseados exclusivamente em LiDAR, o que mostra que as informações espectrais não contribuíram de maneira expressiva para aprimorar as estimativas de AGB.

Palavras-chave: Florestas tropicais. Biomassa. Sensoriamento remoto. Métricas espectrais.

ABSTRACT

RODRIGUES, Nívea Maria Mafra. **Spectral characterization and fusion of LiDAR and hyperspectral data collected by drone to estimate aboveground biomass in secondary Atlantic Forests**. 2025. Thesis (Doctorate in Forestry Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Dr. Gilson Fernandes da Silva. Co-adviser: Dr. André Quintão de Almeida.

Tropical forests play a fundamental role in the global carbon cycle, biodiversity conservation, soil and water preservation, and provide a wide range of ecosystem services. Therefore, improving tropical forest monitoring using data collected by a remotely piloted aircraft (RPA) is crucial to ensuring these services. In this context, this study aimed to evaluate the use of hyperspectral data collected by an RPA to characterize the vegetation of secondary forest fragments of the Atlantic Forest at different successional stages. Additionally, another objective was to combine LiDAR and hyperspectral data to enhance the estimation of aboveground biomass (AGB) and to spatialize these estimates in the studied areas. To achieve this, all tree individuals ($D > 5$ cm) were identified and inventoried in 30 field plots (30 × 30 m each) across five forest remnants located in the southern region of Espírito Santo state. Aerial point clouds and hyperspectral image cubes were generated for all analyzed fragments simultaneously with the field forest inventory. Subsequently, traditional metrics and metrics derived from the Fourier transform of canopy height were estimated from the point clouds, along with spectral information, including reflectance values and vegetation indices, for each plot. The successional stages of the analyzed secondary forest fragments could be distinguished using hyperspectral data collected by RPA. In the context of secondary tropical forests, characterized by high structural variability and different successional stages, the integration of LiDAR and hyperspectral data resulted in minimal improvements in AGB estimation accuracy. In some cases, data fusion did not improve the results compared to models based solely on LiDAR, indicating that spectral information did not significantly contribute to enhancing AGB estimates.

Keywords: Tropical forests. AGB. Remote sensing. Spectral metrics.

LISTA DE FIGURAS

Figura 1.1. Fluxograma das etapas metodológicas de inventário florestal, georreferenciamento, processamento e análise de dados.....	29
Figura 1.2. Mapa de localização da área de estudo.....	31
Figura 1.3. Representação esquemática dos diferentes estágios sucessionais de floresta tropical secundária.....	33
Figura 1.4. Planejamento e aquisição de dados hiperespectrais por aeronave remotamente pilotada (RPA). (A) Esquema do plano de voo destacando as parcelas de inventário florestal (vermelho) e a área de cobertura hiperespectral (amarelo). (B) Sobreposição (10%) e lateral (40%) entre os cubos hiperespectrais adquiridos. (C) Representação tridimensional dos cubos hiperespectrais.....	35
Figura 1.5. Configuração do plano de voo para aquisição de dados hiperespectrais por aeronave remotamente pilotada (RPA). (A) Representação do trajeto do voo, destacando a borda entre o plano de voo da RPA (vermelho) e do HS (amarelo). (B) Ilustração da área de imageamento do sensor hiperespectral, onde a captura de dados ocorre apenas dentro da área delimitada pelo plano de voo HS (linha amarela)	36
Figura 1.6. Painel de calibração de campo do sensor hiperespectral.....	36
Figura 1.7. Aplicação da máscara de pixels sombreados com base no NDVI. (A) Imagem RGB da parcela de campo; (B) NDVI com pixels sombreados; (C) NDVI sem pixels sombreados.....	38
Figura 1.8. Composição RGB do mosaico de imagens hiperespectrais de uma floresta tropical secundária da Mata Atlântica. (A) Resolução espacial de 0,5 m. (B) Resolução espacial de 5 m.....	39
Figura 1.9. Relação entre o número de indivíduos, altura média e biomassa acima do solo em diferentes classes de diâmetro. (A) Distribuição do número de indivíduos e altura média (m) nas classes de diâmetro; (B) Distribuição da biomassa acima do solo ($Mg\ ha^{-1}$) nas classes de diâmetro. As linhas pontilhadas representam a tendência de altura e biomassa acima do solo, respectivamente, em diferentes estágios de sucessão florestal.....	41
Figura 1.10. Influência do deslocamento de 5 m das parcelas de campo na obtenção do valor de reflectância.....	42
Figura 1.11. Intervalo de confiança da reflectância por faixa espectral em diferentes estágios de sucessão florestal.....	44
Figura 1.12. Comportamento espectral dos diferentes estágios de sucessão florestal em duas resoluções espectrais. (A) Resolução de 0,5 m e sem a exclusão de pixels sombreados (No mask); (B) Resolução de 0,5 m e exclusão de pixels sombreados (Mask); (C) Resolução de 5 m e sem a exclusão de pixels sombreados (No mask); (D) Resolução de 5 m e exclusão de pixels sombreados (Mask).....	45
Figura 1.13. Efeito da máscara e da estatística de extração em quatro índices de vegetação em diferentes estágios de sucessão.....	47
Figura 1.14. Comparação de duas resoluções espaciais (0,5 m e 5 m, com máscara) em diferentes estágios de sucessão florestal.....	48
Figura 1.15. Comparação de duas resoluções espaciais (0,5 m e 5 m com máscara) considerando os índices de vegetação NDVI, SR, EVI E SAVI em diferentes estágios de sucessão florestal.....	49
Figura 1.16. Comparação dos estágios sucessionais considerando a resolução de 0,5 m com máscara e mediana.....	50
Figura 2.1. Fluxograma das etapas metodológicas de inventário florestal, georreferenciamento, processamento e análise de dados.....	73

Figura 2.2. Coeficientes de correlação entre a biomassa acima do solo (AGB) e as reflectâncias espectrais, considerando diferentes tamanhos de pixel (0,5 m e 5 m). Linhas verdes indicam dados de pixels iluminados (Mask), enquanto linhas cinzas representam pixels sombreados (No mask).

.....79

Figura 2.3. Importância das variáveis espectrais selecionadas pelo algoritmo Boruta nos quatro cenários. (A) Cenário 1 - com pixels sombreados e resolução de 0,5 m (*No mask0.5m*); (B) Cenário 2 - sem pixels sombreados e resolução de 0,5 m (*Mask0.5m*); (C) Cenário 3 - com pixels sombreados e resolução de 5 m (*No mask5m*); (D) Cenário 4 - sem pixels sombreados e resolução de 5 m (*Mask5m*).....81

Figura 2.4. Valores estimados da biomassa acima do solo de campo versus valores previstos por métricas hiperespectrais. (A, B) Cenário 1 - com pixels sombreados e resolução de 0,5 m (*No mask0.5m*); (C, D) Cenário 2 - sem pixels sombreados e resolução de 0,5 m (*Mask0.5m*); (E, F) Cenário 3 - com pixels sombreados e resolução de 5 m (*No mask5m*); (G, H) Cenário 4 - sem pixels sombreados e resolução de 5 m (*Mask5m*). Os histogramas mostram a distribuição dos valores de RMSE obtidos nas 1000 repetições no procedimento de validação cruzada.....84

Figura 2.5. Espacialização do melhor modelo de predição de biomassa acima do solo utilizando dados hiperespectrais.....85

Figura 3.1. Fluxograma das etapas metodológicas de inventário florestal, georreferenciamento, processamento e análise de dados.....107

Figura 3.2. Representação dos perfis verticais. (A) Perfil vertical de amostra representativa da pastagem permanente (PG); (B) Perfil vertical de amostra representativa do pasto sujo ralo (OSH); (C) Perfil vertical de amostra representativa do pasto sujo denso (CSH); (D) Perfil vertical de amostra representativa do estágio inicial de vegetação secundária (ISV); (E) Perfil vertical de amostra representativa do estágio médio de vegetação secundária (MSV); (F) Perfil vertical de amostra representativa do estágio avançado de vegetação secundária (ASV).....113

Figura 3.3. Seleção de métricas LiDAR com o algoritmo Boruta.....114

Figura 3.4. Valores estimados da biomassa acima do solo de campo versus valores previstos utilizando métricas LiDAR. (A, B) Modelo com 1 variável; (C, D) Modelo com 2 variáveis; (E, F) Modelo com 3 variáveis. Os histogramas mostram a distribuição dos valores de RMSE obtidos nas 1000 repetições no procedimento de validação.....116

Figura 3.5. Espacialização do melhor modelo de predição de biomassa acima do solo (AGB) utilizando dados LiDAR.....117

Figura 3.6. Valores estimados da biomassa acima do solo de campo versus valores previstos pela combinação de métricas LiDAR e hiperespectrais. (A, B) Modelo com duas variáveis; (C, D) Modelo com três variáveis. Os histogramas mostram a distribuição dos valores de RMSE obtidos nas 1000 repetições no procedimento de validação.....119

Figura 3.7. Espacialização do melhor modelo de predição de biomassa acima do solo (AGB) utilizando dados LiDAR e hiperespectral.....120

LISTA DE TABELAS

Tabela 1.1. Descrição dos estágios de vegetação incluídos no estudo.....	32
Tabela 2.1. Equações alométricas utilizadas para estimar AGB de cada árvore de floresta tropical secundária de Mata Atlântica.....	74
Tabela 2.2. Descrição da biomassa acima do solo (AGB) por parcela nas áreas de floresta tropical secundária de Mata Atlântica.....	78
Tabela 2.3. Incertezas em estimativas de campo da biomassa acima do solo.....	78
Tabela 2.4. Modelos selecionados para estimar a biomassa acima do solo (AGB) nos quatros cenários analisados utilizando dados hiperespectrais.....	82
Tabela 2.5. Estatísticas resumidas dos modelos selecionados para estimar a biomassa acima do solo (AGB) nos quatros cenários analisados utilizando dados hiperespectrais.....	82
Tabela 3.1. Descrição da área de varredura em cada estágio sucessional.....	108
Tabela 3.2. Métricas tradicionais e Fourier obtidas a partir de dados LiDAR.....	110
Tabela 3.3. Modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando dados LiDAR.....	115
Tabela 3.4. Estatísticas resumidas dos modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando dados LiDAR.....	115
Tabela 3.5. Modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando fusão de dados LiDAR e hiperespectral.....	117
Tabela 3.6. Estatísticas resumidas dos modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando fusão de dados LiDAR e hiperespectral.....	118

LISTA DE EQUAÇÕES

Equação 2.1.....	74
Equação 2.2.....	74
Equação 2.3.....	74
Equação 2.4.....	74
Equação 2.5.....	74
Equação 2.6.....	75
Equação 2.7.....	75
Equação 2.8.....	75
Equação 2.9.....	75
Equação 2.10.....	75
Equação 2.11.....	75
Equação 2.12.....	76
Equação 3.1.....	110

LISTA DE APÊNDICES

Apêndice A - Características topográficas das parcelas por estágio sucessional.....	133
Apêndice B - Índices de vegetação utilizados nas análises.....	134
Apêndice C - Comparação dos Valores de Reflectância e NDVI nas Diferentes Posições Cardeais.....	135

SUMÁRIO

1 INTRODUÇÃO GERAL	14
2 OBJETIVOS	17
2.1 Objetivo geral.....	17
2.2 Objetivos específicos	17
3 REFERÊNCIAS	18
CAPÍTULO I - CARACTERIZAÇÃO ESPECTRAL DE DIFERENTES ESTÁGIOS SUCCSSIONAIS DE UMA FLORESTA TROPICAL SECUNDÁRIA COM DADOS HIPERESPECTRAIS-RPA	23
1 INTRODUÇÃO	26
2 MATERIAL E MÉTODOS	28
2.1 Área de estudo.....	30
2.2 Inventário Florestal em campo	33
2.3 Sistema HS-RPA.....	34
2.3.1 Calibração radiométrica e ortorretificação	37
2.3.2 Impacto do erro de ortorretificação.....	37
2.4 Dados hiperespectrais	38
2.5 Influência dos pixels sombreados e da resolução espacial	38
3 RESULTADOS	40
3.1 Inventário Florestal.....	40
3.2 Erro da ortorretificação.....	42
3.3 Comportamento espectral	43
3.3.1 Efeito da máscara	43
3.3.2 Efeito da resolução espacial	48
3.3.3 Distinção de estágios sucessionais.....	50
4 DISCUSSÃO	51
4.1 Inventário florestal.....	51
4.2 Comportamento espectral	51
5 CONCLUSÕES	56
6 REFERÊNCIAS	57
CAPÍTULO II - ESTIMATIVA DE BIOMASSA ACIMA DO SOLO EM FRAGMENTOS FLORESTAIS DE MATA ATLÂNTICA COM DADOS HIPERESPECTRAIS-RPA: AVALIANDO O EFEITO DA RESOLUÇÃO ESPACIAL E DE PIXELS SOMBREADOS. 68	
1 INTRODUÇÃO	70
2 MATERIAL E MÉTODOS	72
2.1 Dados hiperespectrais	74
2.2 Estimativa de biomassa acima do solo e incerteza associada	74
2.3 Correlação	76
2.4 Modelagem da biomassa acima do solo	76
3 RESULTADOS	77
3.1 Biomassa acima do solo de campo.....	77
3.2 Análise do erro da AGB de campo.....	78
3.3 Análise da correlação entre AGB e bandas espectrais.....	79
3.4 Seleção de métricas espectrais.....	80
3.5 Modelagem de AGB.....	82

4 DISCUSSÃO	85
4.1 Análise do erro da AGB de campo	85
4.2 Análise da correlação entre AGB e bandas espectrais.....	86
4.3 Modelagem de AGB	88
5 CONCLUSÕES	91
6 REFERÊNCIAS	92
 CAPÍTULO III - ESTIMATIVA DE BIOMASSA ACIMA DO SOLO EM FRAGMENTOS FLORESTAIS DE MATA ATLÂNTICA POR MEIO DA COMBINAÇÃO DE DADOS HIPERESPECTRAIS E LIDAR OBTIDOS A PARTIR DE RPA	
100	
1 INTRODUÇÃO	104
2 MATERIAL E MÉTODOS	106
2.1 Aquisição e pré-processamento de dados LiDAR-RPA	108
2.2 Processamento de dados LiDAR-RPA	109
2.3 Métricas estruturais	109
2.4 Métodos estatísticos	111
3 RESULTADOS	112
3.1 Caracterização das áreas	112
3.2 Seleção de variáveis	113
3.3 Modelagem de AGB com dados LiDAR	115
3.4 Modelagem de AGB com a fusão de dados LiDAR e hiperespectrais	117
4 DISCUSSÃO	120
4.1 Seleção de variáveis	120
4.2 Modelagem de AGB com dados LiDAR	121
4.3 Modelagem de AGB com dados LiDAR e hiperespectrais.....	123
5 CONCLUSÕES	125
6 REFERÊNCIAS	126
7 CONSIDERAÇÕES FINAIS	131
8 APÊNDICES	133

1 INTRODUÇÃO GERAL

As florestas tropicais são essenciais por sua rica biodiversidade, seu papel como recurso de subsistência e como importantes reservatórios de carbono, armazenando aproximadamente 68% do carbono florestal global (Ranglong *et al.*, 2025). Deste total, estima-se que 45–55% estejam contidos na biomassa vegetal (Pan *et al.*, 2011; Ranglong *et al.*, 2025). No entanto, essas florestas estão sob crescente pressão antropogênica devido à expansão populacional e às atividades econômicas, resultando em fragmentação e degradação que alteram sua estrutura, dinâmica e funções ecológicas em escala global (Osuri *et al.*, 2017; Wright, 2005).

Dentre os biomas tropicais mais impactados, a Mata Atlântica destaca-se por sua importância ecológica e alto grau de fragmentação. Reconhecida como um hotspot de biodiversidade, combina alta riqueza de espécies endêmicas e ameaçadas (Mittermeier *et al.*, 2004) com um histórico de intensa exploração, que transformou sua paisagem em um mosaico de florestas secundárias remanescentes (Joly; Metzger; Tabarelli, 2014; MAPBIOMAS, 2021; Piffer *et al.*, 2022; Ribeiro *et al.*, 2009). Nesse contexto, as florestas secundárias vêm se expandindo rapidamente e desempenham um papel importante na conservação da biodiversidade e na mitigação das mudanças climáticas (Chazdon, 2014; Chazdon *et al.*, 2016; Locatelli *et al.*, 2015; Palma *et al.*, 2021; Vancutsem *et al.*, 2021).

A regeneração natural da Mata Atlântica representa uma oportunidade significativa para a restauração ecológica e o cumprimento de metas ambientais globais (Piffer *et al.*, 2022; Poorter *et al.*, 2016; Resende *et al.*, 2024; Shennan-Farpón *et al.*, 2024). Estima-se que esse bioma possua um potencial de regeneração de aproximadamente 2,8 milhões de hectares até 2035 (Crouzeilles *et al.*, 2020), reforçando a viabilidade da recuperação de paisagens degradadas e a promoção de serviços ecossistêmicos. Assim, compreender os processos de regeneração dessas florestas, caracterizar sua estrutura e composição (Mangueira *et al.*, 2021; Oliveira Filho *et al.*, 2004; Valente *et al.*, 2024) e avaliar seu papel no sequestro de carbono (Capellesso *et al.*, 2022; Ferreira *et al.*, 2023) são passos essenciais para fundamentar políticas públicas e estratégias de manejo sustentável (Cardoso *et al.*, 2022).

Todavia, estudar florestas secundárias impõe desafios logísticos e financeiros (Cabral *et al.*, 2023; Lima *et al.*, 2017), especialmente em biomas extensos e fragmentados como a Mata Atlântica. A maioria dos fragmentos remanescentes encontra-se em áreas de difícil acesso, muitas vezes situadas em terrenos declivosos ou no topo de montanhas, o

que dificulta a coleta de dados em campo (Silva *et al.*, 2007). Embora o inventário florestal seja essencial para obter informações detalhadas sobre composição florística e estrutura, sua abrangência espacial é limitada devido aos altos custos operacionais (Cabral *et al.*, 2023; Lima *et al.*, 2017; Picard *et al.*, 2024).

Nesse contexto, a utilização de dados de alta resolução espacial torna-se fundamental para compreender os processos ecológicos que ocorrem em florestas secundárias altamente fragmentadas (Brandt *et al.*, 2024; Pinon *et al.*, 2024). Embora existam imagens de satélite amplamente disponíveis, com acervos públicos gratuitos e boa resolução espectral, esses sensores operam geralmente com resoluções espaciais médias, o que pode dificultar a detecção de alterações em pequenos fragmentos florestais (Fynn; Campbell, 2019; Wickham; Riitters, 2019).

Dessa forma, a integração de tecnologias avançadas, como o sensoriamento remoto por LiDAR (*Light Detection and Ranging*) e imagens hiperespectrais (HSI), oferece uma alternativa eficiente e complementar (Almeida *et al.*, 2019; Almeida *et al.*, 2021). Esses sensores, quando acoplados a Aeronaves Remotamente Pilotadas (RPAs), possibilitam a coleta de dados com alta resolução espacial, com um menor esforço logístico (Almeida *et al.*, 2020; Almeida *et al.*, 2021; Ferreira *et al.*, 2020; Kotivuori *et al.*, 2020; Sankey *et al.*, 2018).

O LiDAR possibilita a estimativa precisa de diversos atributos do dossel florestal, incluindo a densidade da vegetação no sub-bosque, o índice de área foliar (LAI), a altura das árvores, além da identificação e medição de clareiras florestais, riqueza e diversidade de espécies e dos valores de biomassa acima do solo (AGB) (Almeida *et al.*, 2020; Almeida *et al.*, 2019, 2021; Barros *et al.*, 2024; Ferreira *et al.*, 2025; Mao *et al.*, 2018; Martins-Neto *et al.*, 2021). Além disso, estudos recentes demonstram seu potencial para identificar padrões florestais e até mesmo algumas espécies (Jacon *et al.*, 2024; Qian *et al.*, 2023; Scheeres *et al.*, 2023). Por sua vez, as HSI fornecem informações detalhadas sobre as características bioquímicas e composicionais da vegetação, com grande potencial para estimar e analisar a diversidade taxonômica e funcional de florestas tropicais (Pinon *et al.*, 2024; Laurin *et al.*, 2016), identificar espécies (Miyoshi *et al.*, 2019, 2020), discriminar tipos de florestas (Haneda *et al.*, 2023) e caracterizar florestas tropicais secundárias com maior precisão.

Apesar do potencial dessas tecnologias, são escassos os estudos que utilizam HSI para caracterizar a vegetação em florestas secundárias da Mata Atlântica. Haneda *et al.* (2023) analisaram o comportamento espectral e a diversidade de classes de cobertura arbórea em uma Estação Experimental na zona de transição entre o Cerrado e a Mata

Atlântica, utilizando imagens do satélite VEN μ S. No estudo, foram consideradas distintas classes de cobertura, incluindo monoculturas de eucalipto e pinus, florestas semidecíduais em estágios avançados de sucessão, formações secundárias de savana, áreas de restauração em estágio inicial e solos expostos. No entanto, a aplicação de HSI adquiridas por RPA para caracterizar e diferenciar estágios sucessionais na Mata Atlântica ainda não foi amplamente explorada, evidenciando uma lacuna na literatura.

O emprego de dados LiDAR adquiridos por RPA na caracterização estrutural de florestas tropicais também está em expansão, mas seu uso na Mata Atlântica ainda é limitado. Almeida *et al.* (2019a) utilizaram essa tecnologia para analisar atributos estruturais de florestas em restauração na Estação Experimental de São Paulo, enquanto Almeida *et al.* (2019b) monitoraram a estrutura da vegetação na mesma área, reforçando a aplicabilidade dessa abordagem no acompanhamento de processos ecológicos.

A fusão de LiDAR e HSI permite análises mais integradas, combinando informações estruturais e bioquímicas para uma caracterização mais abrangente dos ecossistemas florestais. Quando combinadas com inventários de campo, essas tecnologias possibilitam análises mais abrangentes e precisas, ampliando o alcance espacial do estudo (Almeida *et al.*, 2024; Almeida *et al.*, 2019; Zhao *et al.*, 2018). Embora essa abordagem tenha sido aplicada em estudos voltados para a classificação de espécies em florestas tropicais complexas (Khodadadzadeh *et al.*, 2015; Martins-Neto *et al.*, 2023), sua utilização para estimar AGB de florestas secundárias ainda é incipiente. Almeida *et al.* (2021) demonstraram o potencial da fusão dessas tecnologias na caracterização da diversidade e estrutura de florestas tropicais em restauração. No entanto, a combinação dessas abordagens para a estimativa de variáveis estruturais em florestas secundárias permanece pouco investigada, ressaltando a necessidade de estudos mais aprofundados nessa área.

Deste modo, este trabalho foi estruturado em três capítulos. No primeiro, foi analisado o comportamento espectral de florestas secundárias em diferentes estágios sucessionais, considerando critérios como resolução espacial, método de extração estatística e influência de pixels sombreados. No segundo, esses mesmos critérios foram aplicados para a estimativa da biomassa acima do solo (AGB) com base em dados hiperespectrais. No terceiro, foi realizada a integração de dados LiDAR e hiperespectrais para aprimorar a estimativa de AGB.

Essa abordagem busca preencher lacunas na literatura, contribuindo para o avanço do conhecimento sobre as dinâmicas de regeneração florestal e para o desenvolvimento de estratégias de conservação na Mata Atlântica.

2 OBJETIVOS

2.1 Objetivo geral

Caracterizar a vegetação de florestas secundárias em diferentes estágios sucessionais utilizando dados hiperespectrais e estimar a biomassa acima do solo a partir da integração de dados LiDAR e hiperespectrais obtidos por meio de aeronave remotamente pilotada.

2.2 Objetivos específicos

- Analisar o comportamento espectral em diferentes estágios de vegetação;
- Avaliar a influência de fatores como pixels sombreados e resolução espacial na reflectância das imagens hiperespectrais;
- Correlacionar a AGB com métricas espectrais e estruturais;
- Estimar a AGB utilizando métricas espectrais e estruturais individualmente e combinadas.

3 REFERÊNCIAS

ALMEIDA, C. T. de *et al.* Advancing Forest Degradation and Regeneration Assessment Through Light Detection and Ranging and Hyperspectral Imaging Integration. **Remote Sensing**, v. 16, n. 21, p. 3935, 2024. Disponível em: <https://www.mdpi.com/2072-4292/16/21/3935>.

ALMEIDA, C. T. de *et al.* Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, p. 111323, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425719303426>.

ALMEIDA, D. R. A. de *et al.* Detecting successional changes in tropical forest structure using GatorEye drone-borne lidar. **Biotropica**, v. 52, n. 6, p. 1155–1167, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/btp.12814>.

ALMEIDA, D. R. A. de *et al.* Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. **Remote Sensing of Environment**, v. 264, p. 112582, 2021. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425721003023>.

ALMEIDA, D. R. A. *et al.* The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. **Forest Ecology and Management**, v. 438, p. 34–43, 2019a. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S037811271831819X>.

ALMEIDA, D. R. A. *et al.* Monitoring the structure of forest restoration plantations with a drone-lidar system. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, p. 192–198, 2019b. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243418311954>.

BARROS, Q. S. *et al.* Indicators for monitoring reduced impact logging in the Brazilian amazon derived from airborne laser scanning technology. **Ecological Informatics**, v. 82, p. 102654, 2024. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1574954124001961>.

BRANDT, M. *et al.* High-resolution sensors and deep learning models for tree resource monitoring. **Nature Reviews Electrical Engineering**, v. 2, p. 13–26, 2025. Disponível em: <https://doi.org/10.1038/s44287-024-00116-8>.

CABRAL, R. P. *et al.* Mapping of the Successional Stage of a Secondary Forest Using Point Clouds Derived from UAV Photogrammetry. **Remote Sensing**, v. 15, n. 2, p. 509, 2023. Disponível em: <https://www.mdpi.com/2072-4292/15/2/509>.

CAPELLESSO, E. S. *et al.* Habitat amount is a driver for biodiversity, but not for the carbon stock in post-logging natural regenerating areas in Tropical Atlantic Forest. **Biological Conservation**, v. 273, p. 109673, 2022. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0006320722002269>.

CARDOSO, F. C. G. *et al.* Landscape conservation as a strategy for recovering biodiversity: Lessons from a long-term program of pasture restoration in the southern Atlantic Forest. **Journal of Applied Ecology**, v. 59, n. 9, p. 2309–2321, 2022.

Disponível em: <https://besjournals.onlinelibrary.wiley.com/doi/10.1111/1365-2664.14240>.

CHAZDON, R. L. *et al.* Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, v. 2, n. 5, 2016. Disponível em: <https://www.science.org/doi/10.1126/sciadv.1501639>.

CHAZDON, R. L. **Second Growth: The Promise of Tropical Forest Regeneration in an Age of Deforestation**. London, UK: University of Chicago Press, 2014.

CROUZEILLES, R. *et al.* Achieving cost-effective landscape-scale forest restoration through targeted natural regeneration. **Conservation Letters**, v. 13, n. 3, 2020. Disponível em: <https://conbio.onlinelibrary.wiley.com/doi/10.1111/conl.12709>.

FERREIRA, L. *et al.* Assessing the Impacts of Selective Logging on the Forest Understory in the Amazon Using Airborne LiDAR. **Forests**, v. 16, n. 1, p. 130, 2025. Disponível em: <https://www.mdpi.com/1999-4907/16/1/130>.

FERREIRA, M. P. *et al.* Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. **Forest Ecology and Management**, v. 475, p. 118397, 2020.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S037811272031166X>.

FERREIRA, I. J. M. *et al.* Potential aboveground biomass increase in Brazilian Atlantic Forest fragments with climate change. **Global Change Biology**, v. 29, n. 11, p. 3098–3113, 2023. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/gcb.16670>.

FYNN, I. E. M.; CAMPBELL, J.. Forest fragmentation analysis from multiple imaging formats. **Journal of Landscape Ecology**, v. 12, n. 1, p. 1-15, 2019. Disponível em: <https://doi.org/10.2478/jlecol-2019-0001>

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.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352938522001902>.

JACON, A. D. *et al.* Characterizing Canopy Structure Variability in Amazonian Secondary Successions with Full-Waveform Airborne LiDAR. **Remote Sensing**, v. 16, n. 12, p. 2085, 2024. Disponível em: <https://www.mdpi.com/2072-4292/16/12/2085>.

JOLY, C. A.; METZGER, J. P.; TABARELLI, M. Experiences from the Brazilian Atlantic Forest: ecological findings and conservation initiatives. **New Phytologist**, v. 204, n. 3, p. 459–473, 2014. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/nph.12989>.

KHODADADZADEH, M. *et al.* Fusion of Hyperspectral and LiDAR Remote Sensing Data Using Multiple Feature Learning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 6, p. 2971–2983, 2015. Disponível em: <https://ieeexplore.ieee.org/document/7115053/>.

KOTIVUORI, E. *et al.* Forest inventories for small areas using drone imagery without in-situ field measurements. **Remote Sensing of Environment**, v. 237, p. 111404, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425719304237>.

LIMA, M. B. de O. *et al.* Comparison of sampling methods for description of floristic-structure in woody vegetation. **Australian Journal of Crop Science**, v. 11, n. 12, p. 1573–1578, 2017. Disponível em: http://www.cropj.com/lima_11_12_2017_1573_1578.pdf.

LOCATELLI, B. *et al.* Tropical reforestation and climate change: beyond carbon. **Restoration Ecology**, v. 23, n. 4, p. 337–343, 2015. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/rec.12209>.

MANGUEIRA, J. R. S. A. *et al.* Plant diversity conservation in highly deforested landscapes of the Brazilian Atlantic Forest. **Perspectives in Ecology and Conservation**, v. 19, n. 1, p. 69–80, 2021. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S253006442030081X>.

MAO, L. *et al.* Using airborne laser scanning to predict plant species richness and assess conservation threats in the oil sands region of Alberta's boreal forest. **Forest Ecology and Management**, v. 409, p. 29–37, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378112717310484>.

MAPBIOMAS. **57% dos municípios da Mata Atlântica têm menos de 30% de vegetação natural**. 2021. Disponível em: <https://mapbiomas.org/57-dos-municipios-da-mata-atlantica-tem-menos-de-30-de-vegetacao-natural>. Acesso em: 17 jul. 2023.

MARTINS-NETO, R. P. *et al.* Identification of Significant LiDAR Metrics and Comparison of Machine Learning Approaches for Estimating Stand and Diversity Variables in Heterogeneous Brazilian Atlantic Forest. **Remote Sensing**, v. 13, n. 13, p. 2444, 2021. Disponível em: <https://www.mdpi.com/2072-4292/13/13/2444>.

MARTINS-NETO, R. P. *et al.* Tree Species Classification in a Complex Brazilian Tropical Forest Using Hyperspectral and LiDAR Data. **Forests**, v. 14, n. 5, p. 945, 2023. Disponível em: <https://www.mdpi.com/1999-4907/14/5/945>.

MITTERMEIER, R. A. *et al.* **Hotspots Revisited: Earth's Biologically Richest and Most Endangered Ecoregions**. 1 ed. Mexico: Conservation International, 2004.

MIYOSHI, G. T. *et al.* Comparison of pixel and region-based approaches for tree species mapping in Atlantic Forest using hyperspectral images acquired by uav. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [s. l.], v. XLII-2/W13, p. 1875–1880, 2019. Disponível em: <https://isprs-archives.copernicus.org/articles/XLII-2-W13/1875/2019/>.

MIYOSHI, G. T. *et al.* Spectral Differences Of Tree Species Belonging To Atlantic Forest Obtained From Uav Hyperspectral Images. *In:* , 2020. **2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)**. IEEE, 2020. p. 60–65. Disponível em: <https://ieeexplore.ieee.org/document/9165616/>.

OLIVEIRA FILHO, A. T. *et al.* Diversity and structure of the tree community of a fragment of tropical secondary forest of the brazilian Atlantic Forest domain 15 and 40 years after logging. **Revista Brasileira de Botânica**, v. 27, n. 4, p. 685–701, 2004. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-840420040004000009&lng=en&nrm=iso&tlng=en.

OSURI, A. M. *et al.* Successional status, seed dispersal mode and overstorey species

influence tree regeneration in tropical rain-forest fragments in Western Ghats, India. **Journal of Tropical Ecology**, v. 33, n. 4, p. 270–284, 2017. Disponível em: https://www.cambridge.org/core/product/identifier/S0266467417000219/type/journal_article.

PALMA, A. C. *et al.* Dispersal and recruitment limitations in secondary forests. **Journal of Vegetation Science**, v. 32, n. 1, 2021. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/jvs.12975>.

PAN, Y. *et al.* A Large and Persistent Carbon Sink in the World's Forests. **Science**, v. 333, n. 6045, p. 988–993, 2011. Disponível em: <https://www.science.org/doi/10.1126/science.1201609>.

PICARD, J. *et al.* Combining satellite and field data reveals Congo's forest types structure, functioning and composition. **Remote Sensing in Ecology and Conservation**, p. 1–21, 2024. Disponível em: <https://zslpublications.onlinelibrary.wiley.com/doi/10.1002/rse2.419>.

PIFFER, P. R. *et al.* Turnover rates of regenerated forests challenge restoration efforts in the Brazilian Atlantic forest. **Environmental Research Letters**, v. 17, n. 4, p. 045009, 2022. Disponível em: <https://iopscience.iop.org/article/10.1088/1748-9326/ac5ae1>.

PINON, T. B. M. *et al.* Biodiversity from the Sky: Testing the Spectral Variation Hypothesis in the Brazilian Atlantic Forest. **Remote Sensing**, v. 16, n. 23, p. 4363, 2024. Disponível em: <https://www.mdpi.com/2072-4292/16/23/4363>.

POORTER, L. *et al.* Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, n. 7589, p. 211–214, 2016. Disponível em: <https://www.nature.com/articles/nature16512>.

QIAN, C. *et al.* Tree Species Classification Using Airborne LiDAR Data Based on Individual Tree Segmentation and Shape Fitting. **Remote Sensing**, v. 15, n. 2, p. 406, 2023. Disponível em: <https://www.mdpi.com/2072-4292/15/2/406>.

RANGLONG, A. *et al.* Estimating aboveground biomass and biodiversity of a protected area in moist tropical forest ecosystem using remote sensing application. **Journal for Nature Conservation**, v. 84, p. 126823, 2025. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1617138124002723>.

RESENDE, A. F. *et al.* How to enhance Atlantic Forest protection? Dealing with the shortcomings of successional stages classification. **Perspectives in Ecology and Conservation**, v. 22, n. 2, p. 101–111, 2024. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2530064424000221>.

RIBEIRO, M. C. *et al.* The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. **Biological Conservation**, v. 142, n. 6, p. 1141–1153, 2009. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0006320709000974>.

SANKEY, T. T. *et al.* UAV hyperspectral and lidar data and their fusion for arid and semi-arid land vegetation monitoring. **Remote Sensing in Ecology and Conservation**, v. 4, n. 1, p. 20–33, 2018. Disponível em: <https://zslpublications.onlinelibrary.wiley.com/doi/10.1002/rse2.44>.

SCHEERES, J. *et al.* Distinguishing forest types in restored tropical landscapes with UAV-borne LIDAR. **Remote Sensing of Environment**, v. 290, p. 113533, 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425723000846>.

SHENNAN-FARPÓN, Y. *et al.* Using policy scenarios to assess challenges and opportunities for reaching restoration targets in Brazil's Atlantic Forest. **Environmental Research Letters**, v. 19, n. 8, p. 084036, 2024. Disponível em: <https://iopscience.iop.org/article/10.1088/1748-9326/ad5ab2>.

SILVA, W. *et al.* Relief influence on the spatial distribution of the Atlantic Forest cover on the Ibiúna Plateau, SP. **Brazilian Journal of Biology**, v. 67, n. 3, p. 403–411, 2007. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1519-69842007000300004&lng=en&tlng=en.

VAGLIO LAURIN, G. *et al.* Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. **Remote Sensing of Environment**, v. 176, p. 163–176, 2016. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425716300189>.

VALENTE, C. *et al.* Diversity and structure of tree and regenerating strata in fragments at different successional stages in the Atlantic Forest of Brazil. **Phytocoenologia**, v. 52, n. 1, p. 71–85, 2024. Disponível em: http://www.schweizerbart.de/papers/phyto/detail/52/104825/Diversity_and_structure_of_tree_and_regenerating_s?af=crossref.

VANCUTSEM, C. *et al.* Long-term (1990–2019) monitoring of forest cover changes in the humid tropics. **Science Advances**, v. 7, n. 10, 2021. Disponível em: <https://www.science.org/doi/10.1126/sciadv.abe1603>.

WICKHAM, J.; RIITERS, K. H. Influence of high-resolution data on the assessment of forest fragmentation. **Landscape Ecology**, v. 34, p. 2169–2182, 2019. Disponível em: <https://doi.org/10.1007/s10980-019-00820-z>

WRIGHT, S. J. Tropical forests in a changing environment. **Trends in Ecology & Evolution**, v. 20, n. 10, p. 553–560, 2005. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S016953470500251X>.

ZHAO, Y. *et al.* Forest species diversity mapping using airborne LiDAR and hyperspectral data in a subtropical forest in China. **Remote Sensing of Environment**, v. 213, p. 104–114, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425718302359>.

CAPÍTULO I - CARACTERIZAÇÃO ESPECTRAL DE DIFERENTES ESTÁGIOS SUCESSIONAIS DE UMA FLORESTA TROPICAL SECUNDÁRIA COM DADOS HIPERESPECTRAIS-RPA

RESUMO

As florestas tropicais secundárias remanescentes desempenham um papel fundamental na conservação da biodiversidade e na manutenção de serviços ecossistêmicos, como o sequestro de carbono e a conservação do solo e da água. Sendo assim, caracterizar, diferenciar e monitorar de forma rápida, acurada e detalhada os diferentes estágios desses remanescentes são de extrema importância para assegurar os benefícios e serviços oferecidos por estas florestas. Considerando o exposto, foi objetivo deste estudo a utilização de dados hiperespectrais de alta resolução espacial coletados por uma aeronave remotamente pilotada (HS-RPA) para caracterizar e diferenciar a resposta espectral de diferentes estágios sucessionais de fragmentos de floresta tropical secundária da Mata Atlântica. Além disso, investigou-se como o efeito do sombreamento e da resolução espacial influenciam a resposta espectral da vegetação. Para isso, foram instaladas 30 parcelas permanentes (30 m × 30 m) em cinco remanescentes florestais localizadas no sul do estado do Espírito Santo, Brasil. Em cada parcela, todos os indivíduos arbóreos com diâmetro à altura do peito (D , medido a 1,3 m do solo) ≥ 5 cm foram identificados e mensurados. A aquisição de dados espectrais foi realizada com um sensor hiperespectral embarcado em RPA, cobrindo a faixa espectral de 397–1002 nm com resolução espacial de 0,11 m, posteriormente reamostrada para 0,5 m e 5 m. As análises incluíram a influência das sombras e da resolução espacial na reflectância. Foram analisados os intervalos de confiança considerando todas as bandas espectrais e quatro índices de vegetação. Todo o processamento e análise estatística foram conduzidos em ambiente de programação R. Os resultados destacaram a importância dos comprimentos de onda das regiões do vermelho (601 – 689 nm), borda do vermelho (690 – 740 nm) e do infravermelho próximo (NIR, 741 – 1002 nm) na caracterização da vegetação. A resposta espectral variou entre os estágios sucessionais, sendo mais distinta nessas faixas espectrais. A presença de sombra reduziu a reflectância, especialmente nos estágios médio e avançado de sucessão. Além disso, a diminuição da resolução espacial reduziu a capacidade de distinção entre os estágios devido à perda de heterogeneidade espacial. O estudo reforça a relevância do sensoriamento remoto hiperespectral na caracterização de florestas tropicais secundárias, demonstrando a influência de fatores como sombreamento e resolução espacial na análise

espectral da vegetação. Como perspectiva futura, recomenda-se a integração de dados LiDAR para aprimorar a caracterização espectral e estrutural da vegetação ao longo do gradiente sucessional.

Palavras-chave: Sucessão ecológica; reflectância espectral; resolução espacial; pixels sombreados.

ABSTRACT

Remaining secondary tropical forests play a fundamental role in biodiversity conservation and the maintenance of ecosystem services, such as carbon sequestration and soil and water conservation. Thus, the rapid, accurate, and detailed characterization, differentiation, and monitoring of the different successional stages of these remnants are crucial to ensuring the benefits and services provided by these forests. Considering this, the objective of this study was to use high-spatial-resolution hyperspectral data collected by a remotely piloted aircraft (HS-RPA) to characterize and differentiate the spectral response of different successional stages in secondary tropical forest fragments in Brazil. Additionally, this study investigated how the effects of shading and spatial resolution influence the spectral response of vegetation. To achieve this, 30 permanent plots (30 × 30 m) were established in five forest remnants located in the southern region of Espírito Santo state, Brazil. In each plot, all tree individuals with a diameter at breast height (D) \geq 5 cm were identified and measured, allowing the estimation of aboveground biomass (AGB). Spectral data acquisition was performed using a hyperspectral sensor mounted on an RPA, covering the spectral range of 397–1002 nm with a spatial resolution of 0.11 m, later resampled to 0.5 m and 5 m. Analyses included evaluating the influence of shading and spatial resolution on reflectance and its correlation with AGB. Clustering analyses (hierarchical and non-hierarchical), principal component analysis (PCA), and Pearson correlations were applied, considering all spectral bands and four vegetation indices. All data processing and statistical analyses were conducted in the R programming environment. The results highlighted the importance of red edge wavelengths (669–760 nm) and near-infrared (NIR, 761–1002 nm) in vegetation characterization, showing a strong correlation with AGB. The spectral response varied among successional stages, being more distinct within these spectral ranges. The presence of shading reduced reflectance and weakened the correlation with AGB, especially in the intermediate and advanced successional stages. Moreover, increasing pixel size reduced the ability to distinguish between stages due to the loss of spatial heterogeneity. This study reinforces the relevance of hyperspectral remote sensing in characterizing secondary tropical forests, demonstrating the influence of factors such as shading and spatial resolution on the spectral analysis of vegetation. As a future perspective, the integration of LiDAR data is recommended to enhance spectral and structural characterization of vegetation along the successional gradient.

Keywords: Ecological succession; spectral reflectance; spatial resolution; shaded pixels.

1 INTRODUÇÃO

As florestas tropicais desempenham um papel fundamental no ciclo global do carbono, na conservação da biodiversidade, do solo e da água e oferecem uma vasta gama de serviços ecossistêmicos (Artaxo *et al.*, 2022; Borma *et al.*, 2022; Chazdon, 2014; IPCC, 2023). Em regiões tropicais, as florestas secundárias têm ganhado destaque, pois representam uma fração significativa da cobertura terrestre e fornecem subsídios essenciais para compreender os processos de recuperação ecológica e a resiliência funcional dos ecossistemas frente a distúrbios naturais e antrópicos (Aryal *et al.*, 2024; Chen *et al.*, 2024; Nytch *et al.*, 2023).

Na Mata Atlântica, o histórico de desmatamento extensivo resultou em uma paisagem altamente fragmentada, composta por remanescentes florestais isolados em diferentes estágios sucessionais (Molinez *et al.*, 2024; Santos *et al.*, 2020). Esses fragmentos são essenciais para a conservação da biodiversidade e para a manutenção de serviços ecossistêmicos, como o sequestro de carbono e a regulação climática (Chazdon, 2014; Matos *et al.*, 2020; Williams *et al.*, 2024). A regeneração natural é vista como uma oportunidade para restaurar parcialmente a integridade ecológica da região, com florestas secundárias desempenhando um papel fundamental na recuperação da cobertura vegetal e na reconexão das paisagens fragmentadas (Chazdon; Guariguata, 2016; Lapin *et al.*, 2024). Esses processos de recuperação estão relacionados à sucessão ecológica, que promove mudanças graduais na composição de espécies e na estrutura das comunidades ao longo do tempo (He *et al.*, 2023; Poorter *et al.*, 2024; Poorter *et al.*, 2023).

Nesse contexto, a compreensão detalhada e o monitoramento desses processos sucessionais ao longo do tempo e em extensas áreas pode ser realizada e/ou aprimorada por meio de dados de sensoriamento remoto com resoluções mais finas (Almeida *et al.*, 2021; Pinon *et al.*, 2024). Além disso, o uso de aeronave remotamente pilotada (RPA) na coleta de informações da floresta aumenta a flexibilidade no monitoramento e contribui para a efetivação de compromissos globais relacionados à restauração e conservação florestal (Almeida *et al.*, 2021; Ecke *et al.*, 2024; Sinegalia; Santoro; Molin, 2023; Sun *et al.*, 2023). Além das vantagens proporcionadas pelas RPAs, o uso de sensores hiperespectrais (HS) embarcados nessas plataformas potencializa o estudo de florestas tropicais. Essa tecnologia permite a caracterização detalhada das propriedades biofísicas e bioquímicas da vegetação, fornecendo informações sobre saúde, composição e comportamento estrutural das florestas em alta resolução (Shrama *et al.*, 2022; Verma *et al.*, 2023). Com uma ampla faixa espectral, os HS possibilitam a identificação de padrões complexos e sutis,

como variações fisiológicas relacionadas à dinâmica sucessional (Im; Jensen, 2008; Kayet, 2020; Verma *et al.*, 2023), sendo, portanto, uma ferramenta relevante para compreender e monitorar ecossistemas tropicais secundários.

No entanto, a coleta e o processamento de dados de HS são influenciados pela presença de sombras nos pixels das imagens, que podem impactar a qualidade das estimativas (Lu *et al.*, 2020; Pinon *et al.*, 2024). As sombras, causadas pela obstrução da luz solar por árvores altas, reduzem a reflectância e, em alguns casos, podem levar à perda completa do sinal espectral dentro do dossel florestal (Lopatin *et al.*, 2019; Zhang *et al.*, 2015). Além disso, imagens de altíssima resolução espacial, embora ofereçam maior detalhamento espacial, também aumentam a variabilidade espectral devido à estrutura do dossel e à presença de sombras (Lopatin *et al.*, 2017).

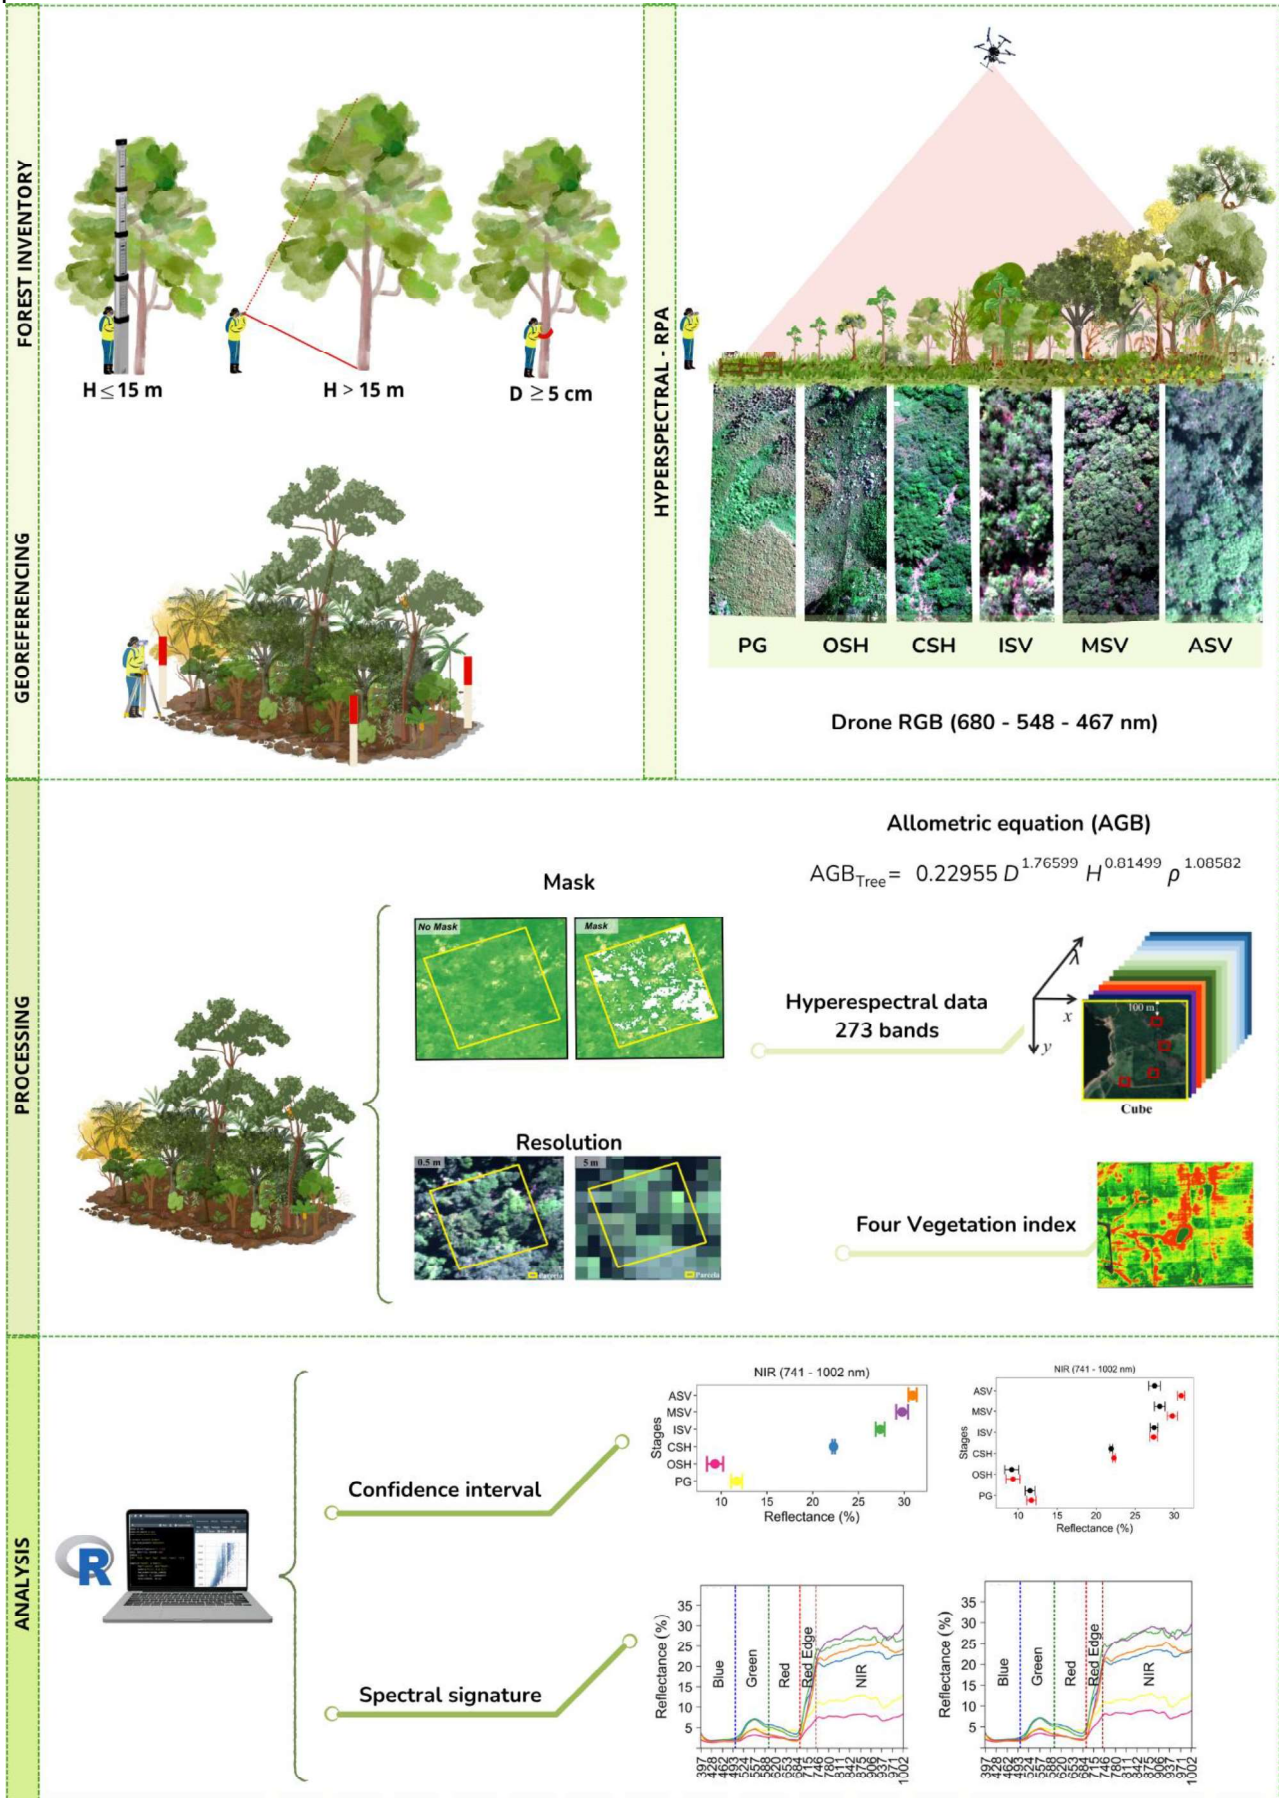
Apesar das vantagens dos sistemas HS-RPA, escassos são os trabalhos que se dedicam a investigar as diferentes formações de florestas tropicais secundárias localizadas no Brasil (Silva *et al.*, 2024). Entre as poucas exceções está o trabalho de Pinon *et al.* (2024), que utilizou dados hiperespectrais obtidos por RPA para analisar a biodiversidade em florestas tropicais secundárias no Brasil. Essa lacuna no conhecimento científico reforça a necessidade de avanços, particularmente no que se refere ao desenvolvimento de métodos de coleta, processamento e análise de dados hiperespectrais coletados por RPA aplicados a florestas tropicais secundárias em desenvolvimento.

Neste contexto, este estudo busca analisar o comportamento espectral de fragmentos florestais secundários da Mata Atlântica em diferentes estágios sucessionais, utilizando dados hiperespectrais obtidos por RPA (HS-RPA). Com base nessa abordagem, este estudo teve como objetivos avaliar as seguintes hipóteses: (1) o comportamento espectral da vegetação varia entre diferentes estágios sucessionais; (2) a presença de sombras reduz a reflectância; e (3) a redução da resolução espacial (aumento do tamanho do pixel) diminui a capacidade de discriminar entre diferentes estágios sucessionais devido à perda de heterogeneidade espacial.

2 MATERIAL E MÉTODOS

O fluxograma metodológico das etapas necessárias para a realização do presente capítulo é apresentado na Figura 1.1. A figura sintetiza o encadeamento das atividades, desde o inventário florestal e o georreferenciamento, até a aquisição de dados hiperespectrais, processamento e análise dos dados. Cada uma dessas etapas está descrita em detalhes nas subseções a seguir.

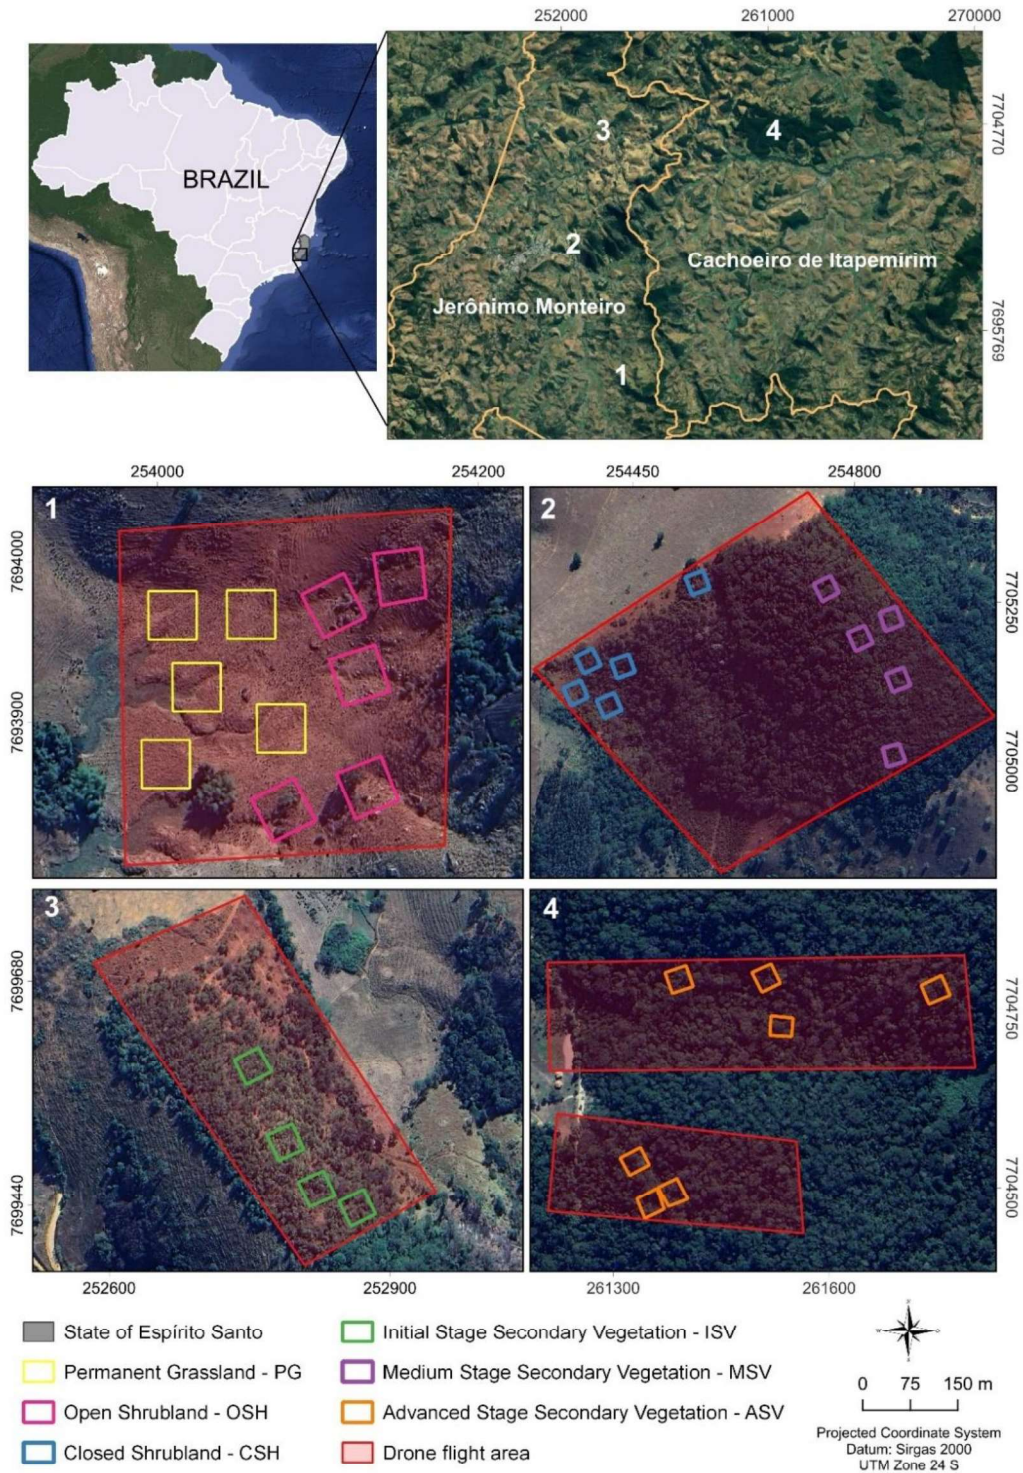
Figura 1.1. Fluxograma das etapas metodológicas de inventário florestal, georreferenciamento, processamento e análise de dados.



2.1 Área de estudo

O estudo foi realizado no sul do estado do Espírito Santo, Brasil, em quatro diferentes áreas de domínio original da Mata Atlântica, sendo áreas cobertas com floresta tropical secundária e com espécies de forragem (Figura 1.2). De acordo com a classificação climática de Köppen, no geral, o clima da região é do tipo “Aw” (Alvares *et al.*, 2014), isto é, tropical chuvoso, com estação seca no inverno (maio a agosto) e chuvosa no verão, entre os meses de novembro a março (Incaper, 2020). O sul do estado do Espírito Santo é caracterizado por um relevo acidentado, com a ocorrência de montanhas e serras (Coelho *et al.*, 2012). Os solos característicos são o argissolo vermelho eutrófico e latossolo amarelo distrófico (Cunha *et al.*, 2016).

Figura 1.2. Mapa de localização da área de estudo.



Fonte: A autora.

Neste estudo, foram considerados seis estágios de vegetação: pastagem permanente (PG – *Permanent Grassland*), pasto sujo ralo (OSH – *Open Shrublands*), pasto sujo denso (CSH – *Closed Shrublands*), estágio inicial de vegetação secundária (ISV - *Initial Stage Secondary Vegetation*, 10 a 25 anos), estágio médio de vegetação secundária (MSV - *Medium Stage Secondary Vegetation*, > 35 anos) e estágio avançado de vegetação

secundária (ASV - *Advanced Stage Secondary Vegetation*, > 100 anos sem evidências de impactos em larga escala) (Tabela 1.1.). Para a caracterização topográfica das áreas de estudo, foram utilizados dados do modelo digital de elevação oriundo da missão SRTM (*Shuttle Radar Topography Mission*). Com base nesses dados, foram obtidas a altitude média e a declividade média de cada área amostral.

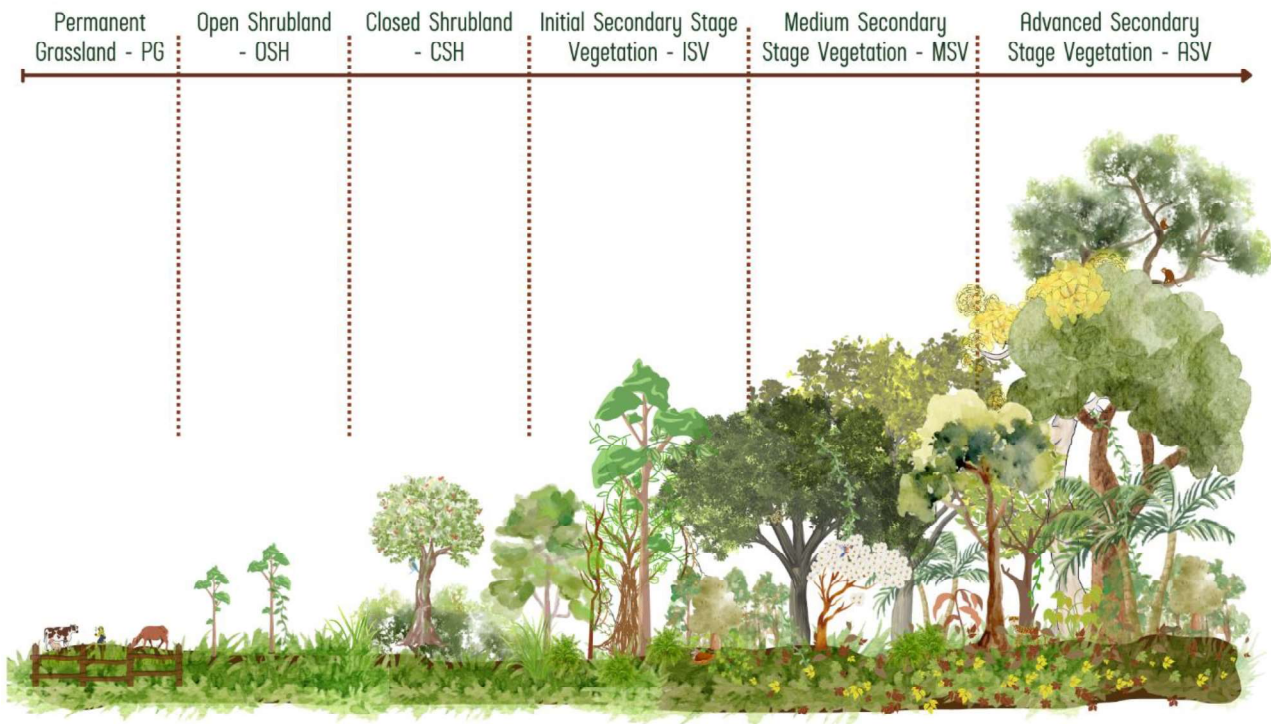
Tabela 1.1. Descrição dos estágios de vegetação incluídos no estudo.

Classes	Descrição
PG	Áreas cultivadas com forrageiras (<i>Brachiaria</i> sp. e <i>Panicum maximum</i>) sob diferentes condições de manejo e tratos culturais. Essas pastagens são destinadas à alimentação de bovinos leiteiros e apresentam manejo contínuo. A vegetação apresenta presença esparsa de indivíduos arbóreos das espécies <i>Guarea guidonia</i> (L.) Sleumer e <i>Tabernaemontana hystrix</i> Steud. As áreas situam-se a uma altitude média de 156 metros e apresentam declividade média de 23,57%.
OSH	Área cultivada com forrageiras (<i>Brachiaria</i> sp. e <i>Panicum maximum</i>) para alimentação de bovinos leiteiros, porém manejado com menor intensidade quanto aos tratos culturais. A vegetação é caracterizada por um grande número de indivíduos arbóreos de pequeno porte, além da presença de árvores bem desenvolvidas. As espécies mais frequentes incluem <i>Schinus terebinthifolius</i> Raddi, <i>Cecropia pachystachya</i> Trécul, <i>Psidium guajava</i> L. e <i>Vernonanthura ferruginea</i> (Less.) H.Rob. Esta área situa-se a uma altitude média de 202 metros e apresenta declividade média de 31,66%.
CSH	A área é caracterizada por fragmento de Floresta Estacional Semidecidual, em estágio inicial de vegetação secundária. As espécies arbóreas mais representativas registradas foram <i>Tabernaemontana hystrix</i> , <i>Zeyheria tuberculosa</i> (Vell.) Bureau ex Verl. e <i>Balfourodendron riedelianum</i> (Engl.) Engl. Em termos topográficos, a área apresenta altitude média de 190 metros e declividade média de 35,69%.
ISV	A área é composta por fragmento de Floresta Estacional Semidecidual, em estágio médio de vegetação secundária. As espécies arbóreas com maior ocorrência foram <i>Anadenanthera peregrina</i> (L.) Speg., <i>Xylopia frutescens</i> Aubl. e <i>Casearia sylvestris</i> Sw. A área apresenta altitude média de 237 metros e declividade média de 26,63%.
MSV	A área corresponde a um fragmento de Floresta Estacional Semidecidual em estágio avançado de vegetação secundária. As principais espécies arbóreas identificadas foram <i>Actinostemon verticillatus</i> (Klotzsch) Baill., <i>Cordia acutifolia</i> Fresen., <i>Neoraputia alba</i> (Nees & Mart.) Emmerich ex Kallunki e <i>Senefeldera verticillata</i> (Vell.) Croizat. A área apresenta altitude média de 138,41 metros e declividade média de 21,77%.
ASV	

Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

A determinação da idade da vegetação foi realizada a partir da análise das séries temporais dos mapas anuais de uso e cobertura do solo disponibilizados pelo MapBiomias (MapBiomias, 2024), abrangendo o período de 1985 a 2022. Para as áreas em estágio avançado de vegetação secundária, recorreu-se às informações técnicas disponíveis no Plano de manejo da Floresta Nacional de Pacotuba (ICMBio, 2011). A Figura 1.3 apresenta uma representação esquemática das diferenças na estrutura da vegetação.

Figura 1.3. Representação esquemática dos diferentes estágios sucessionais de floresta tropical secundária.



Fonte: A autora.

2.2 Inventário Florestal em campo

A coleta de dados em campo foi realizada entre agosto e dezembro de 2022, utilizando processo de amostragem aleatória com parcelas de área fixa. Nas áreas de estudo, foram distribuídas 30 parcelas com dimensões de 30 m x 30 m (0,09 ha) (Apêndice A). Os vértices de cada parcela foram georreferenciados com um *Global Navigation Satellite System* (GNSS), modelo GEOMAX Zenith-16, no modo *Real Time Kinematic* (RTK) e pós-processado nas áreas com vegetação mais densa. O tempo decorrido para registrar as coordenadas de cada vértice no modo pós-processado foi de cinco minutos. A raiz do erro médio quadrático (RMSE) final em X e Y foi menor que um (1,00) m.

O diâmetro à altura do peito (D , medido a 1,3 m do solo) das árvores vivas com diâmetro ≥ 5 cm e a altura total (H) foram medidas utilizando uma fita métrica e régua

telescópica de 15 m, respectivamente. Foi utilizado um clinômetro Suunto PM-5/360PC (www.suunto.com) nos indivíduos com $H > 15$ m. Ao final do inventário de cada parcela, foram escolhidas aleatoriamente 10 árvores e repetidas as medidas do D e H para estimativa e propagação dos erros de mensuração. As medidas foram realizadas sempre pelo mesmo técnico.

Além disso, todos os indivíduos foram identificados ao nível de gênero ou espécie por meio de consultas à coleção física do Herbário Capixaba, às imagens do Herbário Virtual Re flora e ao taxonomista vinculado ao Herbário da Reserva Natural Vale (CVRD). O sistema de classificação *Angiosperm Phylogeny Group IV* (APG IV, 2016) foi utilizado na identificação, e a padronização da nomenclatura dos indivíduos foi feita por meio da Lista de Espécies da Flora do Brasil (Flora do Brasil, 2023).

2.3 Sistema HS-RPA

Os dados foram coletados utilizando um sistema composto por aeronave remotamente pilotada (RPA) modelo DJI Matrice 600 PRO (www.dji.com), com seis rotores, equipada com um sensor hiperespectral (HS) modelo Headwall Nano-hyperspec VNIR (headwallphotonics.com). Esta RPA é equipada com seis baterias e possui autonomia de voo entre 20 a 25 minutos. O HS possui sistema de escaneamento do tipo “push-broom”, uma distância focal de 12 mm e uma taxa de varredura de linha de 100 hertz (Headwall Photonics, 2024). O sensor capta espectros em cada pixel, operando entre 397 e 1002 nm, originando um cubo de dados hiperespectrais.


Os voos nas áreas foram realizados nos dias 13, 14 e 15 de abril de 2023, entre as 11:00 AM e 14:00 PM, horário local. Apesar de não coincidir com o período de tempo do inventário de campo (agosto a dezembro de 2022), nesta época do ano (final do período chuvoso na região), a espécies caducifólias se encontravam totalmente com folhas. Além disso, procurou-se confirmar que a vegetação não passou por nenhum processo de degradação (i.e., fogo, corte seletivo de árvores ou a ocorrência de intempéries climáticas) entre o período de tempo de realização do inventário florestal e os sobrevoos. Nas áreas de pastagem permanente (PG), pasto sujo denso (CSH) e estágio inicial de vegetação secundária (ISV) foi realizado apenas um voo, já nos demais, foram necessários dois voos para cobrir toda área.

Durante os sobrevoos, as condições climáticas consistiam em céu predominantemente limpo, com cobertura de nuvens inferior a 5%, e velocidade do vento abaixo de 10 m.s^{-1} , conforme recomendado por Dandois *et al.* (2015). Os voos foram

conduzidos no modo *visual line of sight* (VLOS), seguindo os padrões brasileiros de pilotagem de RPA (<https://www.anac.gov.br>). As condições de iluminação se mantiveram constantes durante os sobrevoos em todas as áreas.

Para iniciar a aquisição dos dados, o HS requer a definição prévia de um polígono de imageamento, dentro do qual a captura é automaticamente ativada. Assim, o polígono de aquisição do HS foi configurado para capturar os cubos de dados a uma altura de 120 m e velocidade constante de cruzeiro de $5 \text{ m}\cdot\text{s}^{-1}$ (Figura 1.4A). A sobreposição frontal foi de 10% e a sobreposição lateral foi de 40% (Figura 1.4B). Com essa relação entre altura e velocidade, a taxa de frequência de aquisição foi de 12,33 ms com 2000 frames por cubo, gerando uma imagem com resolução espacial de aproximadamente 0,11 m (Figura 1.4C).

Figura 1.4. Planejamento e aquisição de dados hiperespectrais por aeronave remotamente pilotada (RPA). (A) Esquema do plano de voo destacando as parcelas de inventário florestal (vermelho) e a área de cobertura hiperespectral (amarelo). (B) Sobreposição frontal (10%) e lateral (40%) entre os cubos hiperespectrais adquiridos. (C) Representação tridimensional dos cubos hiperespectrais.



Fonte: A autora.

O plano de voo da RPA foi construído a partir do polígono de captura de imagens do HS (Figura 1.5). Para minimizar o efeito de borda, o polígono de voo RPA foi construído com um buffer de 50 m a partir da linha do polígono de imagem do HS (Figura 1.5A), assegurando assim, que a RPA estivesse sempre com uma velocidade constante de cruzeiro de $5 \text{ m}\cdot\text{s}^{-1}$ ao entrar no polígono do HS (Figura 1.5B).

2.3.1 Calibração radiométrica e ortorretificação

A calibração radiométrica e a ortorretificação foram realizadas conforme manual de especificação do fabricante do sensor (Headwall, 2018). Inicialmente, os valores dos pixels dos cubos brutos foram convertidos para radiância ($W \cdot m^{-2} \cdot str^{-1} \cdot nm^{-1}$) utilizando o *software* SpectralView (Headwall Photonics, Inc.). Durante essa fase, a amostra de referência escura (*dark*) foi utilizada como ponto de referência de objeto escuro.

Em seguida, os cubos de radiância foram convertidos em fator de reflectância de superfície, utilizando como referência a faixa central do painel de calibração com reflectância difusa (30% de reflectância) (Figura 1.6). A reflectância de cada pixel é calculada pela razão entre a radiância e a radiância média dos pixels do painel de calibração.

No processo de ortorretificação, os cubos de reflectância de superfície foram ortorretificados empregando um Modelo Digital de Elevação (MDE) com resolução espacial de 30 m, obtido do *Shuttle Radar Topography Mission* (SRTM). O RMSE da ortorretificação em X e Y foi inferior a dois metros. A ortorretificação teve início com o cálculo dos arquivos de geometria de entrada para cada linha de voo, os quais contêm informações fundamentais de georreferenciamento para cada pixel bruto da imagem original. Por fim, a partir dos cubos ortorretificados, foram criados mosaicos das imagens de reflectância para cada área amostrada.

2.3.2 Impacto do erro de ortorretificação

Conforme mencionado na seção 2.3.1, foi identificado um RMSE de aproximadamente dois metros em X e Y. Para avaliar o impacto desse erro na extração dos valores de reflectância, foi realizada uma simulação com deslocamentos de cinco metros do centro das parcelas de campo nas quatro direções cardeais. O valor de cinco metros foi adotado por representar uma situação mais conservadora, ampliando a margem de deslocamento além do erro identificado.

Após cada deslocamento, foram extraídos os valores médios para as bandas do Green (501-600 nm), Red Edge (690-740 nm) e Near Infra-Red (NIR, 741-1002 nm), bem como valores de índice de vegetação da diferença normalizada (NDVI, Red = 674 nm; NIR = 830 nm). Estas bandas foram criadas pela média dos valores de reflectância de cada intervalo descrito dentro dos parênteses. Por fim, foi realizado um teste *t* de *Student* para dados pareados para verificar a existência de diferenças significativas entre os valores

médios de reflectância extraídos para a posição original da parcela e as quatro direções cardeais.

2.4 Dados hiperespectrais


Foram utilizadas 273 bandas espectrais com largura de 2 nm cada (entre as faixas de 397 a 1002 nm) e resolução espacial de 0,11 m. Inicialmente, as imagens foram reamostradas para a resolução espacial de 0,50 m, considerando a mediana para uma janela de 4 x 4 pixels, visando minimizar a relação sinal-ruído.

Adicionalmente, foram calculados quatro índices de vegetação: *Normalized Difference Vegetation Index* (NDVI), *Enhanced Vegetation Index* (EVI), *Soil-Adjusted Vegetation Index* (SAVI) e *Simple Ratio* (SR), conforme detalhado no Apêndice B. A escolha dos índices NDVI, EVI, SAVI e SR baseou-se em sua recorrência na literatura e na capacidade de representar diferentes condições de vegetação. Por fim, foram extraídos os valores medianos de reflectância (%) e dos IVs para cada uma das parcelas de inventário, totalizando 277 métricas hiperespectrais.

2.5 Influência dos pixels sombreados e da resolução espacial

Para avaliar o efeito dos pixels sombreados durante a extração dos valores de reflectância, foi criada uma máscara no software QGIS (QGIS Development Team). A máscara foi baseada no NDVI, calculado a partir das bandas Red (670 nm) e NIR (800 nm) (Figura 1.7). Para eliminar os pixels sombreados, aplicou-se um limiar de NDVI < 0,84, removendo todos os pixels com valores abaixo deste limite (Pinon *et al.*, 2024).

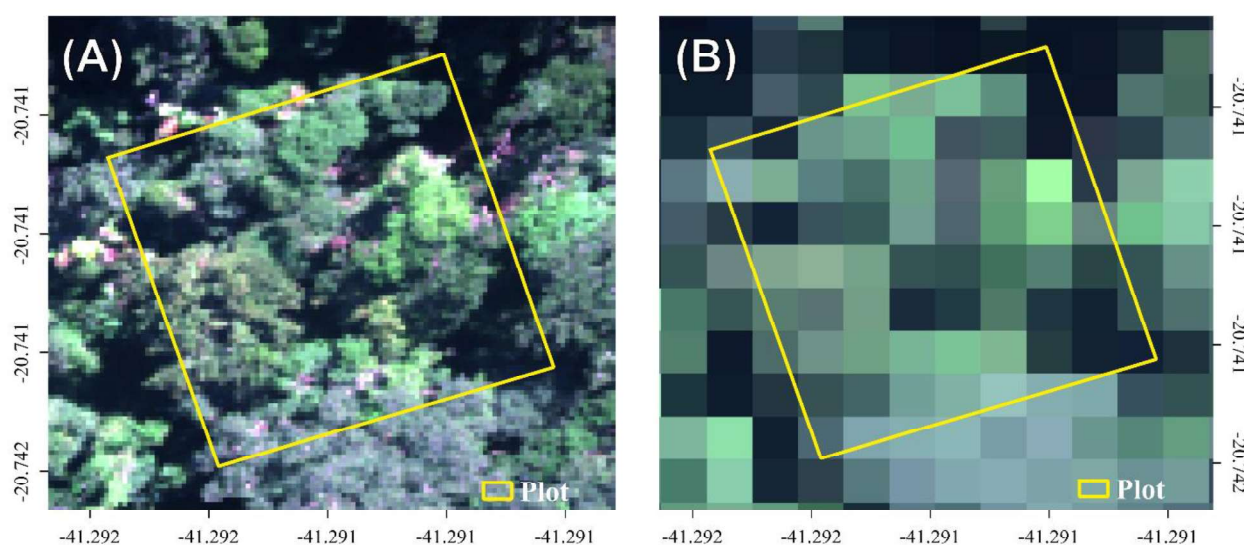
Figura 1.7. Aplicação da máscara de pixels sombreados com base no NDVI. (A) Imagem RGB da parcela de campo; (B) NDVI com pixels sombreados; (C) NDVI sem pixels sombreados.



Fonte: A autora.

Para avaliar a influência da resolução espacial no momento da extração das informações espectrais das parcelas, as imagens foram reamostradas para resoluções espaciais de 0,5 m e 5 m (Figura 1.8). A resolução de 0,5 m foi adotada a partir da resolução original da imagem (0,11 m), com o objetivo de reduzir os efeitos da relação sinal-ruído. A resolução de 5 m, por sua vez, foi selecionada para simular as características de sensores orbitais com média a alta resolução espacial, permitindo análises comparativas com dados provenientes de plataformas satelitais.

Figura 1.8. Composição RGB do mosaico de imagens hiperespectrais de uma floresta tropical secundária da Mata Atlântica. (A) Resolução espacial de 0,5 m. (B) Resolução espacial de 5 m.



Fonte: A autora.

A extração dos valores de reflectância foi realizada ponderando a área do pixel que se encontrava dentro do limite da parcela. Por fim, foram removidos possíveis ruídos aplicando o filtro Savitzky-Golay com polinômio de segunda ordem e tamanho de janela de 15 vizinhos.

Para avaliar o efeito da (i) presença de sombra e (ii) resolução espacial no momento da extração dos valores de reflectância das parcelas de inventário, foram estimados o valor médio a partir das séries de mediana de cada parcela, considerando intervalos específicos do espectro eletromagnético. Os intervalos considerados correspondem aos valores médios das faixas do Blue (397 – 500 nm), Green (501 – 600 nm), Red (601 – 689 nm), Red Edge (690 – 740 nm) e Near Infra-Red (741 – 1002 nm). Além destes intervalos, foram analisados também os efeitos na extração dos valores do NDVI, EVI, SAVI e SR.

A existência de diferença estatística entre os valores estimados por estágio foi analisada pelos valores de intervalo de confiança. Se os intervalos de confiança de cada

estágio se sobrepuseram, foi indicativo de uma relação forte entre os valores estimados por estágio. Por outro lado, nenhuma ou pouca sobreposição entre os intervalos de confiança, sugeriu uma relação fraca entre os valores estimados por estágio. Essa análise permitiu uma compreensão mais aprofundada da distribuição dos dados em cada estágio e das possíveis diferenças estatísticas entre eles. Por fim, foi realizada a caracterização espectral dos diferentes estágios sucessionais, analisando assinaturas de valores de reflectância. Todo processamento e análise estatística dos dados foi realizado em ambiente R (R Core Team, 2023).

3 RESULTADOS

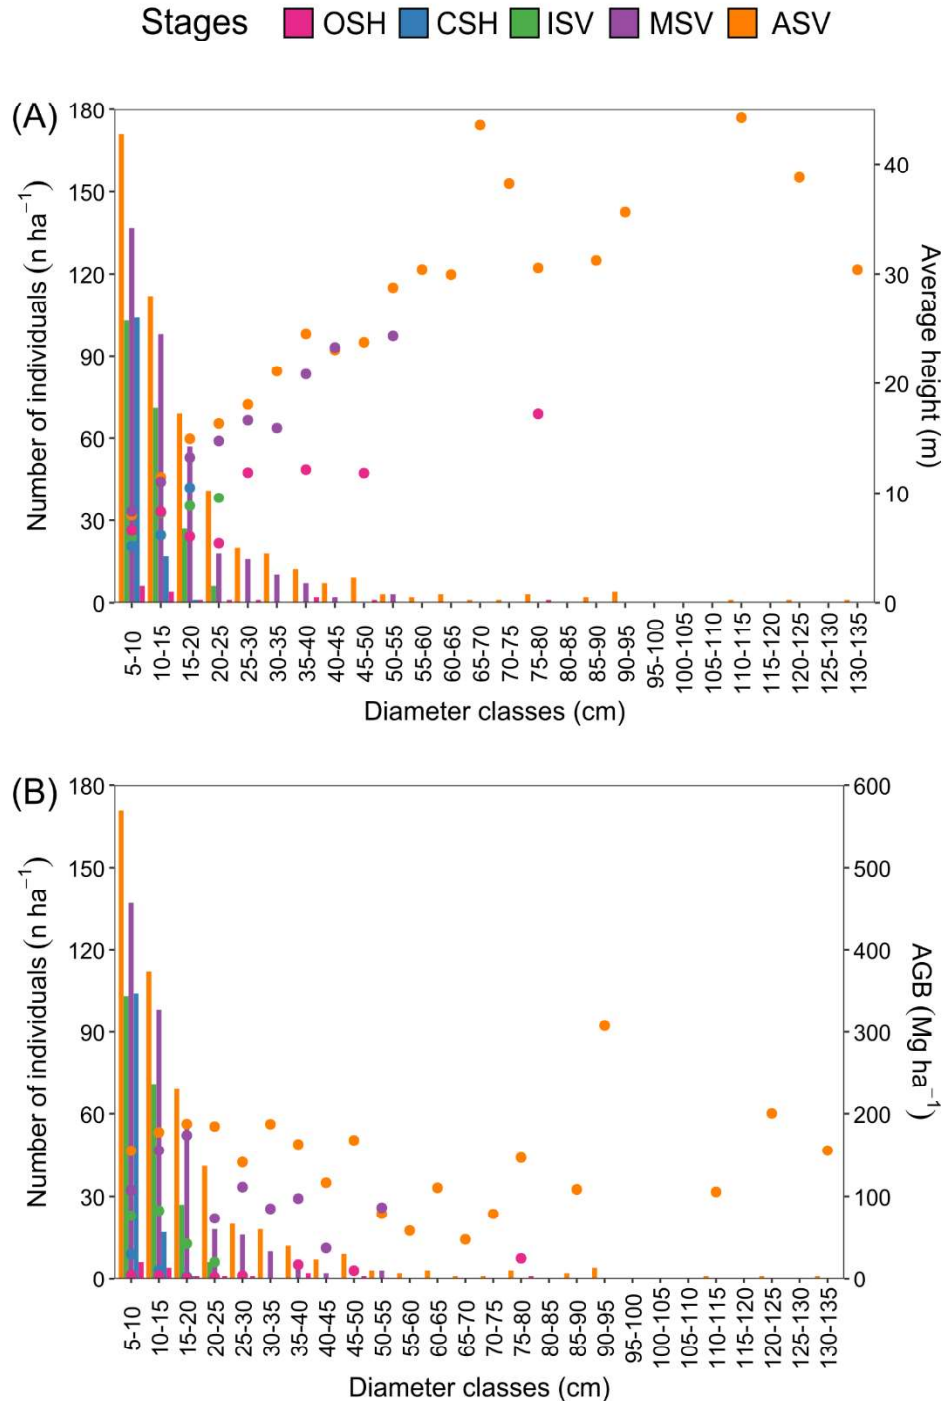
3.1 Inventário Florestal

Foram mensurados 2.355 indivíduos distribuídos em 151 espécies pertencentes a 47 famílias. A Figura 1.9 ilustra a relação entre a distribuição da altura média e a biomassa acima do solo em distintas classes de diâmetros. Observa-se que a maioria dos indivíduos está concentrada nas classes de menor diâmetro (5-10 cm e 10-15 cm), com redução no número de indivíduos à medida que o diâmetro aumenta. Esse padrão de distribuição segue a forma característica de 'J-invertido'.

Além disso, é possível observar que a altura média tende a aumentar com o diâmetro das árvores, o que é esperado em florestas em sucessão. No estágio avançado de vegetação secundária (ASV), as árvores atingem maiores alturas e diâmetros. Por outro lado, os demais estágios apresentam maior quantidade de indivíduos em classes de menores diâmetro, com alturas médias mais baixas (Figura 1.9A).

Na Figura 1.9B, o estágio avançado de vegetação secundária (ASV) apresenta os maiores valores de biomassa acima do solo, com um aumento expressivo nas classes de diâmetro mais elevadas, indicando maior acúmulo de biomassa em árvores de maior porte. Nos demais estágios, a biomassa é distribuída de maneira mais uniforme entre as classes de diâmetro, porém com valores absolutos inferiores.

Figura 1.9. Relação entre o número de indivíduos, altura média e biomassa acima do solo em diferentes classes de diâmetro. (A) Distribuição do número de indivíduos e altura média (m) nas classes de diâmetro; (B) Distribuição da biomassa acima do solo (Mg ha^{-1}) nas classes de diâmetro. As linhas pontilhadas representam a tendência de altura e biomassa acima do solo, respectivamente, em diferentes estágios de sucessão florestal.




Legenda: Números de indivíduos (barras); altura e AGB das árvores (pontos) por classe de diâmetro para diferentes estágios de sucessão florestal; PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

Fonte: A autora.

3.2 Erro da ortorretificação

Em todas as quatro direções cardeais, a uma distância de 5 metros das parcelas de campo, os valores de reflectância nas bandas Green, Red Edge, NIR e no NDVI não apresentaram diferenças estatisticamente significativas ($p > 0,05$) de acordo com o teste t de Student para dados pareados, considerando um nível de significância de 5% (Figura 1.10, Apêndice C). Dessa forma, o erro de co-registro de até 5 metros na localização das parcelas de campo não impactou significativamente os valores de reflectância.

Figura 1.10. Influência do deslocamento de 5 m das parcelas de campo na obtenção do valor de reflectância média.



Legenda: N = Norte, S = Sul, E = Leste, W = Oeste, ns = não significativo. Os valores correspondem às médias de reflectância obtidas para cada banda espectral, bem como aos valores médios do NDVI.

Fonte: A autora.

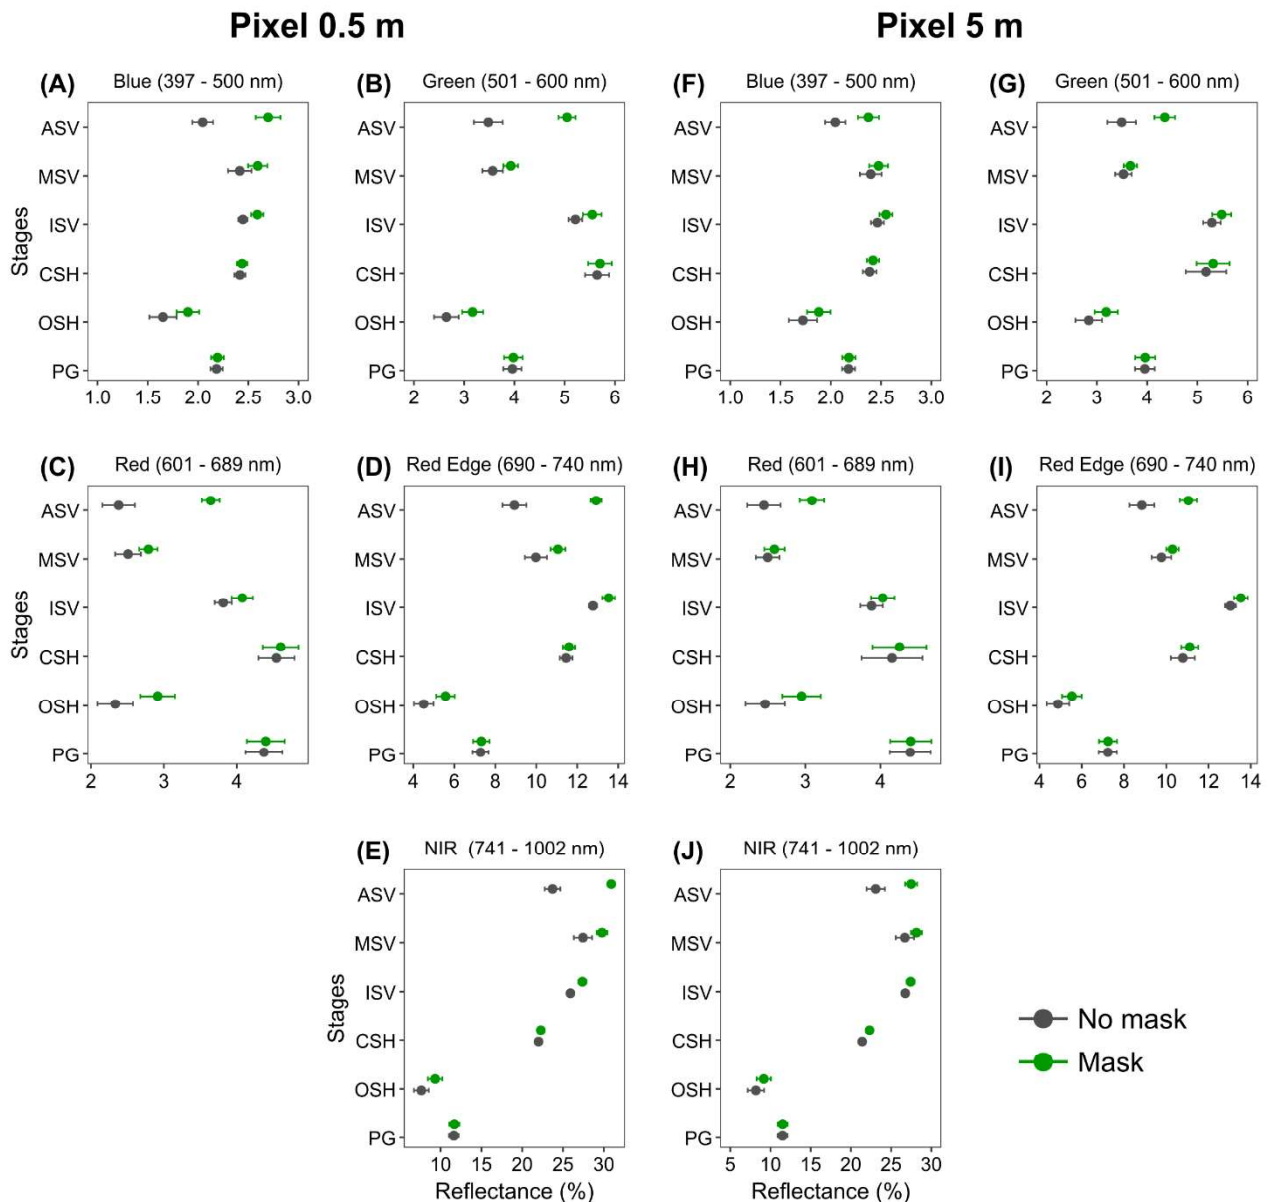
3.3 Comportamento espectral

3.3.1 Efeito da máscara

Foi identificada uma diferença estatisticamente significativa da reflectância média entre os cenários sem a exclusão de pixels sombreados (*No mask*) e com a exclusão de pixels sombreados (*Mask*) no estágio avançado de vegetação secundária (ASV), independentemente do tamanho do pixel (0,5 m ou 5 m), uma vez que os intervalos de confiança não se sobrepõem. Essa diferença é evidente em todas as bandas espectrais analisadas (Figura 1.11).

Foi possível observar diferenças significativas entre os cenários sem a exclusão de pixels sombreados (*No mask*) e com a exclusão de pixels sombreados (*Mask*) a partir da banda Red Edge. Para a resolução de 0,5 m, essas diferenças foram identificadas nos estágios inicial (ISV) e médio (MSV) de vegetação secundária (Figuras 1.11D-E). Na resolução de 5 m, as diferenças na banda Red Edge foram menos destacadas, sendo evidentes apenas no estágio avançado de vegetação secundária (ASV) (Figuras 1.11I).

Figura 1.11. Intervalo de confiança da reflectância por faixa espectral em diferentes estágios de sucessão florestal.



Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).
 Fonte: A autora.

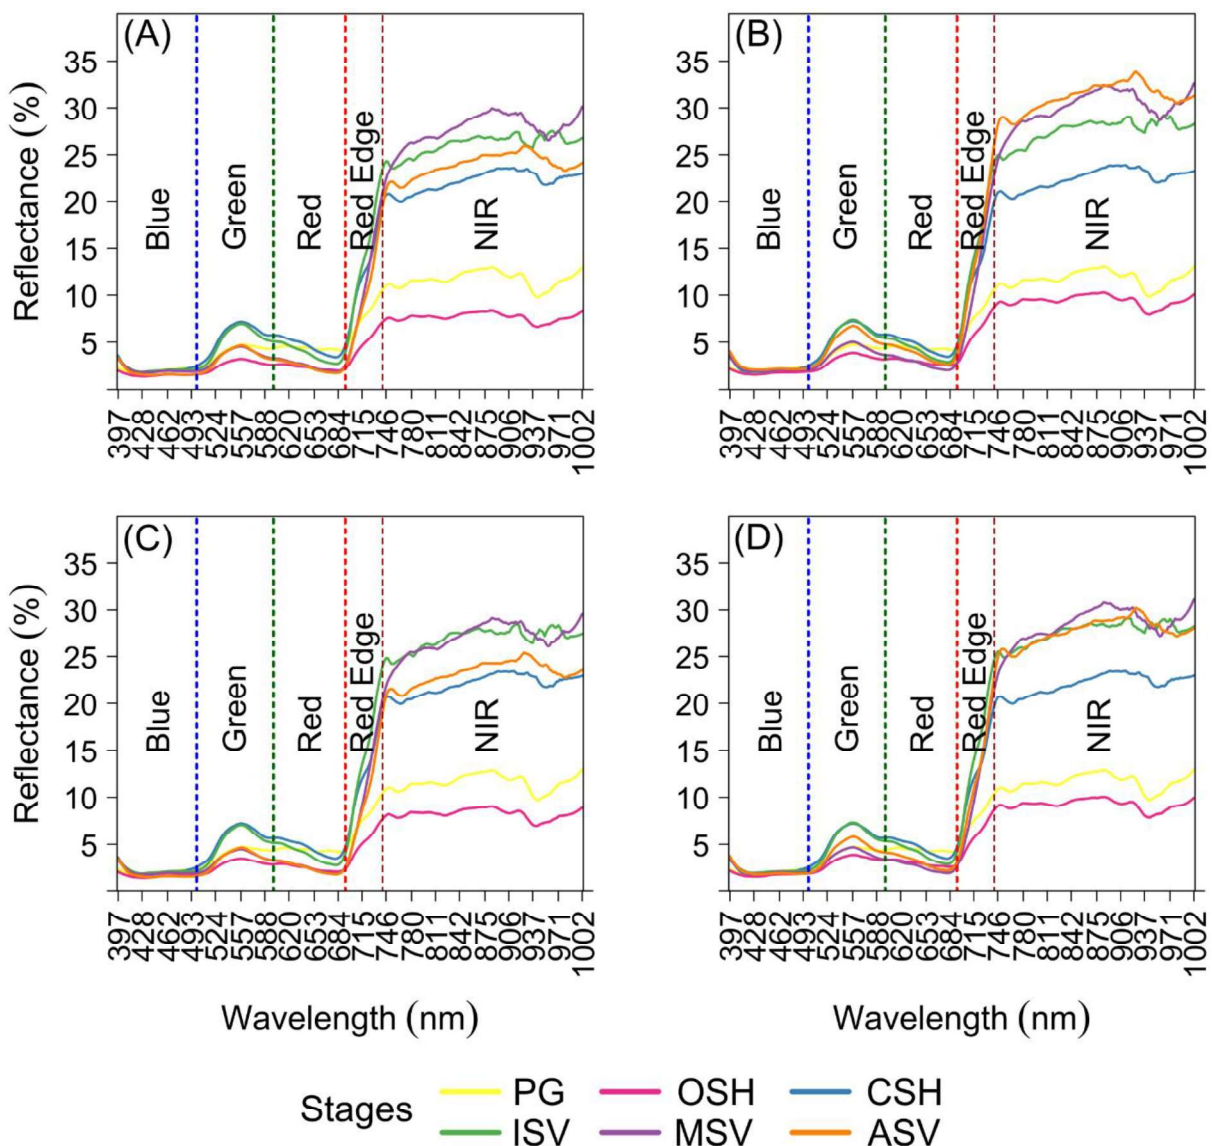
A Figura 1.12 apresenta o comportamento espectral dos diferentes estágios sucessionais de florestas tropicais. De modo geral, observa-se que, em ambas as resoluções espaciais, os pixels sombreados impactam mais intensamente o estágio avançado de vegetação secundária (ASV) (Figura 1.12).

Nas regiões do Red Edge e do NIR, o estágio inicial (ISV), médio (MSV) e avançado (ASV) de vegetação secundária apresentaram padrões espectrais semelhantes. Ao

considerar a resolução de 0,5 m com exclusão de pixels sombreados (*Mask*), o estágio avançado (ASV) destacou-se por apresentar maior reflectância (Figura 1.12B).

Entretanto, esse padrão foi menos evidente na resolução de 5 m sob as mesmas condições (Figura 1.12D). Além disso, na resolução de 0,5 m sem pixels sombreados (*Mask*) (Figura 1.12B), observou-se um aumento gradual na reflectância com o avanço dos estágios de sucessão florestal.

Figura 1.12. Comportamento espectral dos diferentes estágios de sucessão florestal em duas resoluções espectrais. (A) Resolução de 0,5 m e sem a exclusão de pixels sombreados (*No mask*); (B) Resolução de 0,5 m e exclusão de pixels sombreados (*Mask*); (C) Resolução de 5 m e sem a exclusão de pixels sombreados (*No mask*); (D) Resolução de 5 m e exclusão de pixels sombreados (*Mask*).



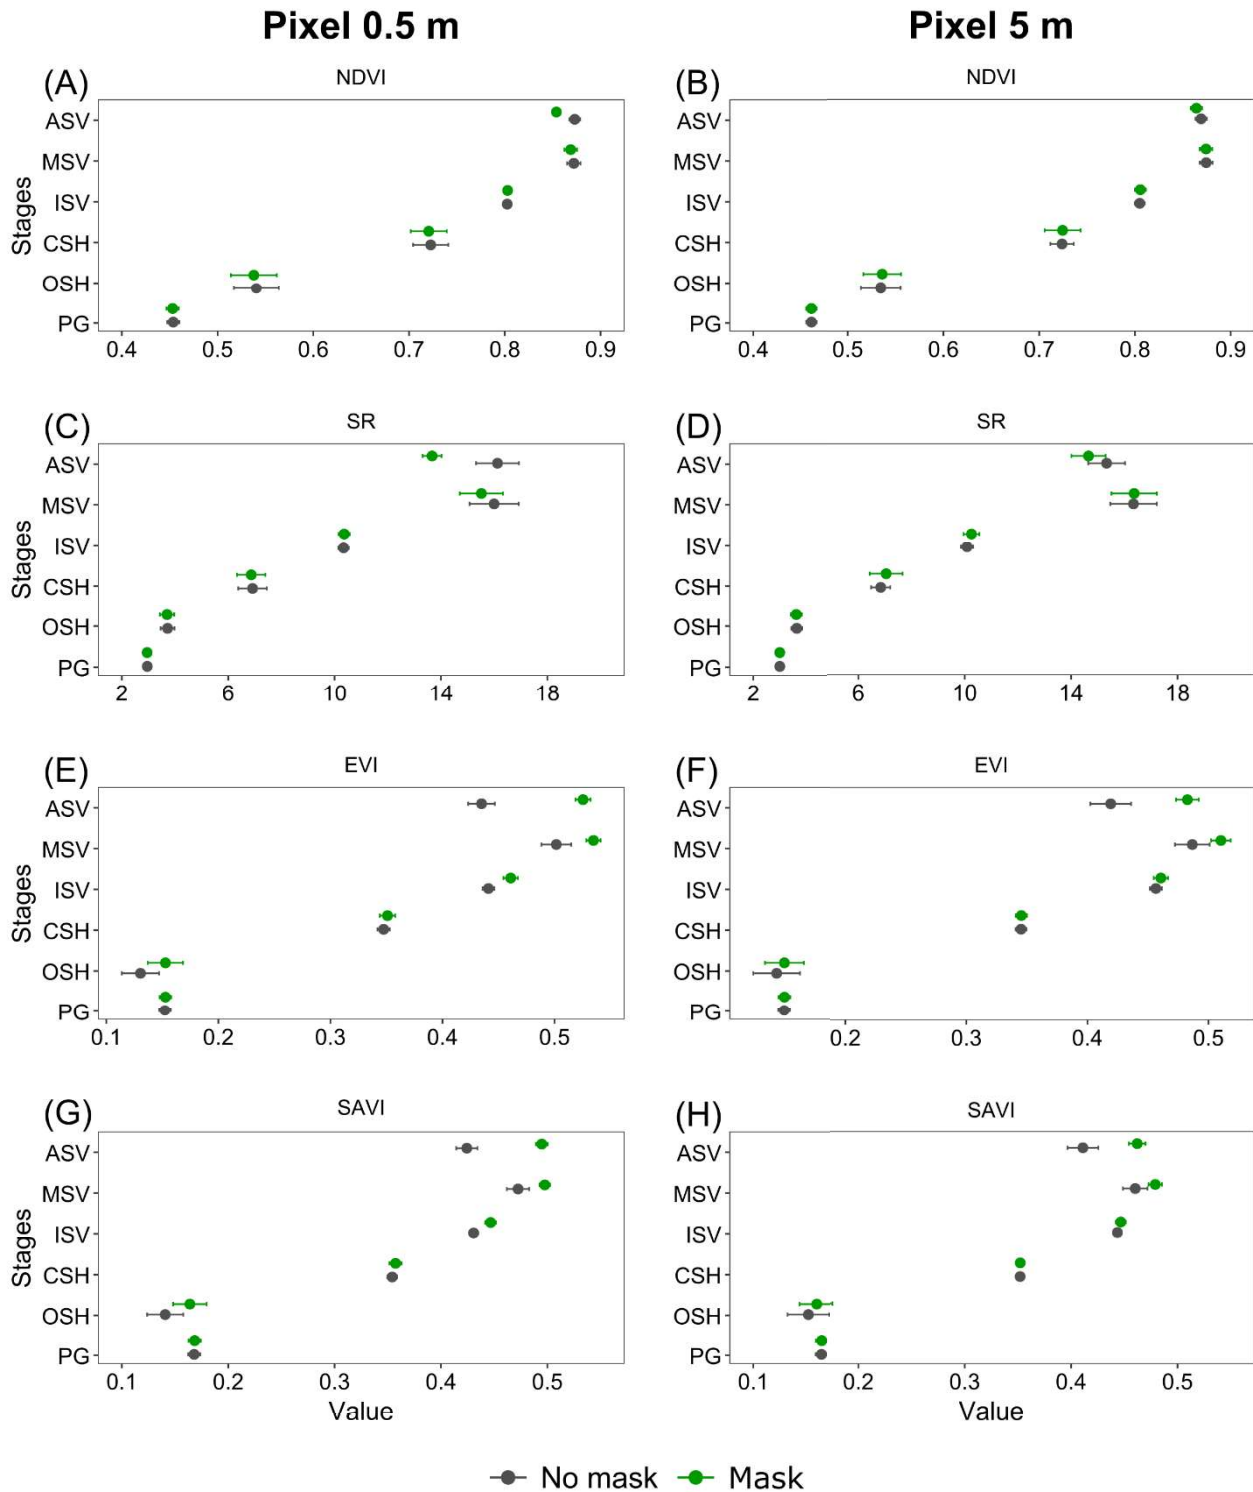
Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

Fonte: A autora.

Ao analisar os índices de vegetação, observou-se que os valores de NDVI e SR foram maiores considerando o cenário sem a exclusão de pixels sombreados (*No mask*) em quase todos os estágios sucessionais (Figuras 13A-D). No entanto, diferenças estatisticamente significativas entre os cenários *No mask* e *Mask* foram identificadas apenas na resolução de 0,5 m, especificamente no estágio avançado de vegetação secundária (ASV) (Figuras 1.13A e 1.13C).

Por outro lado, ao analisar EVI e SAVI, observa-se um comportamento oposto, com os valores obtidos para o cenário *Mask* (exclusão de pixels sombreados) superiores aos valores do cenário *No mask* (sem exclusão de pixels sombreados) em ambas as resoluções avaliadas (Figuras 13E-H). Esse padrão se mantém consistente ao longo dos estágios sucessionais inicial (ISV), médio (MSV) e avançado (ASV), sendo mais evidente na resolução de 0,5 m (Figuras 1.13E e 1.13G). Adicionalmente, evidências de diferenças estatisticamente significativas entre os cenários são corroboradas pela ausência de sobreposição dos intervalos de confiança.

Figura 1.13. Efeito da máscara e da estatística de extração em quatro índices de vegetação em diferentes estágios de sucessão.



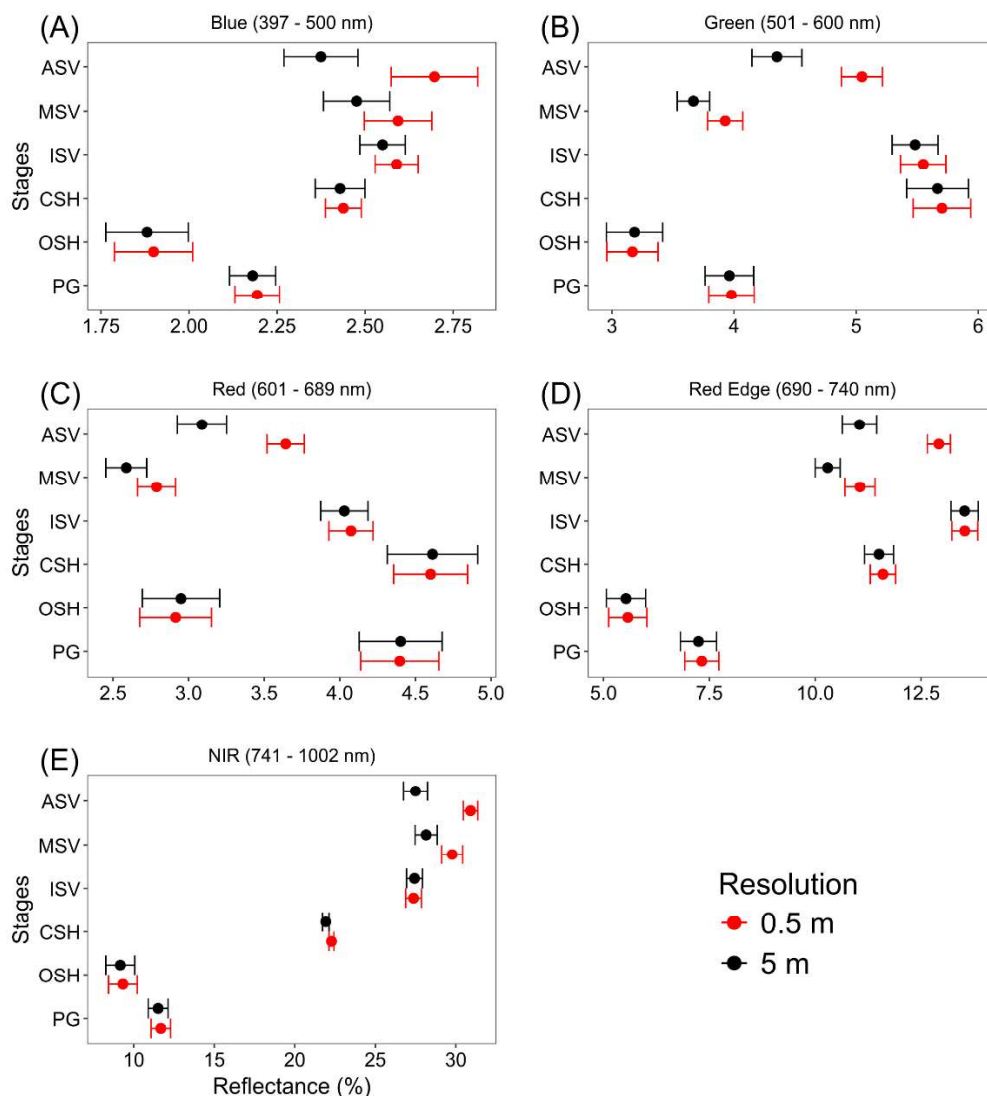
Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

Fonte: A autora.

3.3.2 Efeito da resolução espacial

A resolução de 0,5 m foi estatisticamente diferente da resolução de 5 m em todas as bandas espectrais analisadas para o estágio avançado (ASV) (Figura 1.14). Essa diferença é corroborada pela ausência de sobreposição entre os intervalos de confiança associados às duas resoluções espaciais. No estágio médio (MSV), também foram identificadas diferenças estatisticamente significativas entre as resoluções de 0,5 m e 5 m, particularmente nas regiões do Red Edge e NIR (Figuras 1.14D-E). Nos demais estágios (PG, OSH, CSH e ISV), não há evidências de diferenças estatísticas entre as resoluções de 0,5 m e 5 m.

Figura 1.14. Comparação de duas resoluções espaciais (0,5 m e 5 m, com máscara) em diferentes estágios de sucessão florestal.



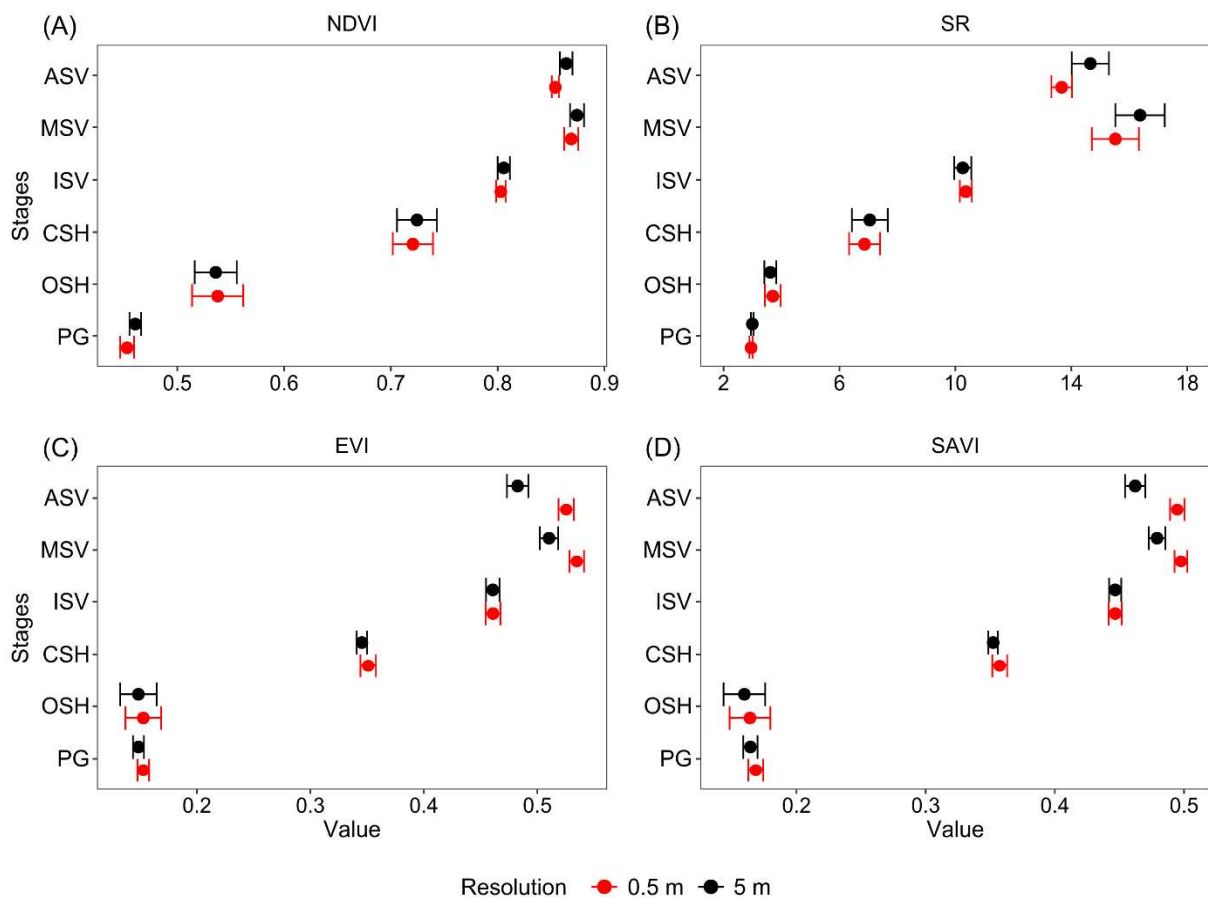
Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

Fonte: A autora.

Na Figura 1.15A e 1.15B, observou-se que a resolução de 5 m frequentemente apresentou valores mais elevados para NDVI e SR. Especificamente no estágio avançado (ASV), foi identificada uma diferença estatisticamente significativa entre as duas resoluções para ambos os índices, com destaque para a resolução de 5 m, que apresentou valores superiores. Nos demais estágios sucessionais (PG, OSH, CSH, ISV e MSV), não foram observadas diferenças estatisticamente significativas entre as resoluções de 0,5 m e 5 m (Figura 1.15A-B).

Em contraste, os padrões observados para EVI e SAVI divergiram daqueles verificados para NDVI e SR (Figuras 1.15C-D). Nesse caso, a resolução de 0,5 m demonstrou valores mais elevados para ambos os índices. Nos estágios médio (MSV) e avançado (ASV), constatou-se uma diferença estatisticamente significativa entre as resoluções, com a resolução de 0,5 m apresentando valores superiores para EVI e SAVI.

Figura 1.15. Comparação de duas resoluções espaciais (0.5 m e 5 m com máscara) considerando os índices de vegetação NDVI, SR, EVI E SAVI em diferentes estágios de sucessão florestal.



Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

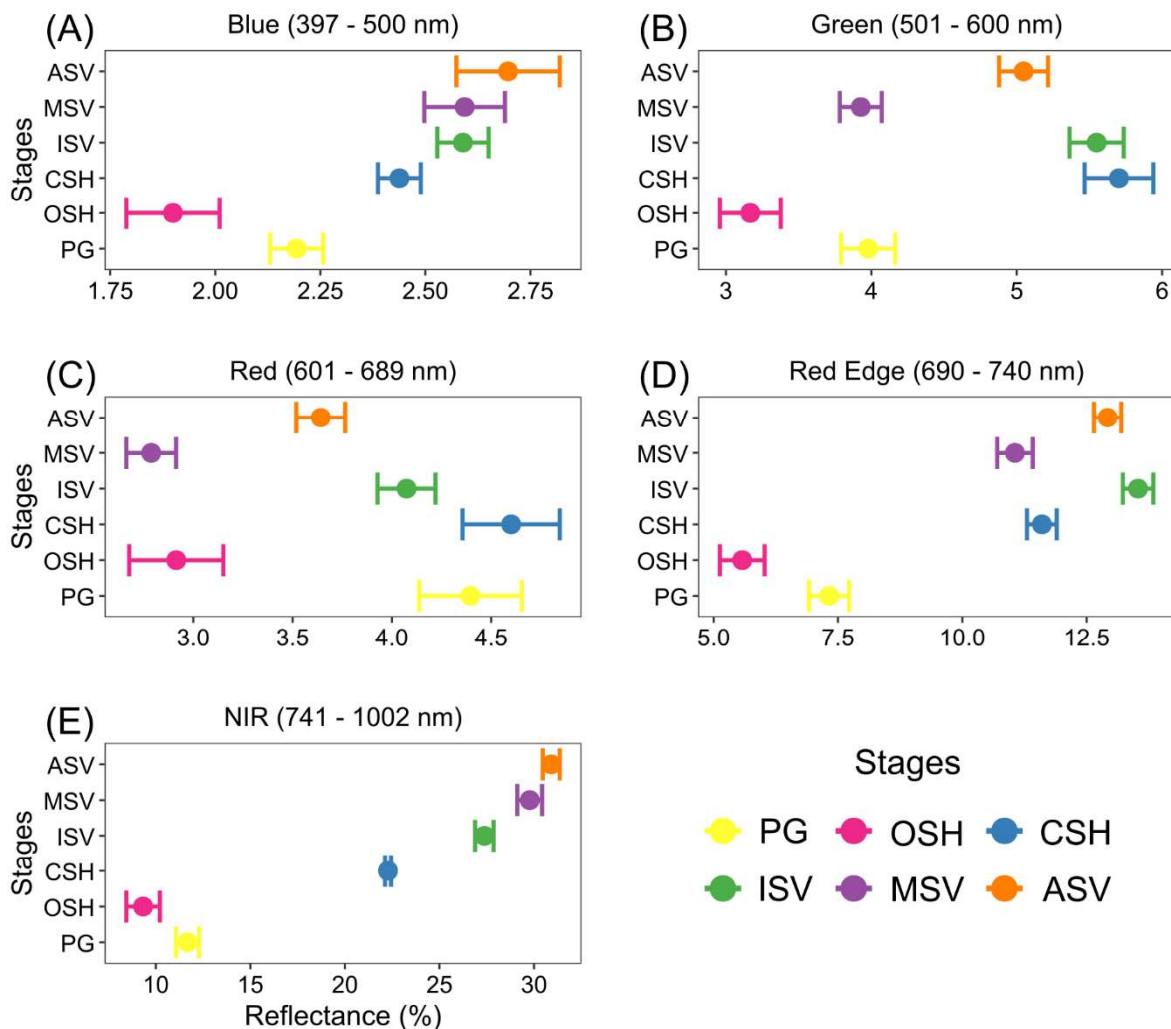
Fonte: A autora.

3.3.3 Distinção de estágios sucessionais

Foi possível observar o comportamento distinto nas respostas de reflectância em diferentes bandas espectrais, conforme ilustrado na Figura 1.16. De modo geral, os intervalos de confiança analisados mostram uma clara distinção entre os estágios de vegetação nas regiões do Red Edge e NIR (Figura 1.16D-E).

Por outro lado, nos comprimentos de onda do espectro visível observa-se uma maior sobreposição dos intervalos de confiança (Figura 1.16A-C). Na Figura 1.16E, é possível notar uma diferenciação desde os estágios de pastagem (PG, OSH e CSH) até o estágio médio (MSV), com apenas uma pequena sobreposição entre os intervalos de confiança do estágio médio (MSV) e estágio avançado (ASV).

Figura 1.16. Comparação dos estágios sucessionais considerando a resolução de 0,5 m com máscara e mediana.



Legenda: PG – pastagem permanente (*Permanent Grassland*); OSH – pasto sujo ralo (*Open Shrublands*); CSH – pasto sujo denso (*Closed Shrublands*); ISV – estágio inicial de vegetação secundária (*Initial Stage Secondary Vegetation*); MSV – estágio médio de vegetação secundária (*Medium Stage Secondary Vegetation*); ASV – estágio avançado de vegetação secundária (*Advanced Stage Secondary Vegetation*).

Fonte: A autora.

4 DISCUSSÃO

4.1 Inventário florestal

Os resultados apresentados refletem padrões estruturais típicos de florestas tropicais em diferentes estágios sucessionais. A predominância de indivíduos nas menores classes diamétricas (5-10 cm e 10-15 cm), resultando em uma distribuição em 'J-invertido', é característica de florestas naturais. Esse padrão indica uma regeneração contínua e um balanço entre mortalidade e recrutamento de indivíduos (Li *et al.*, 2023; Memiaghe *et al.*, 2016).

Conforme a floresta avança no processo de sucessão, observa-se um aumento significativo na complexidade estrutural. Áreas em estágios avançados de sucessão são marcadas por árvores de maior diâmetro e altura (Figura 1.9A), características de florestas mais maduras. Em contraste, áreas em estágios iniciais de regeneração apresentam maior abundância de indivíduos com menores diâmetros, refletindo uma estrutura florestal menos complexa (Montgomery; Frelich, 2024).

As árvores mais altas além de oferecerem maior acúmulo de biomassa, também promovem complexidade estrutural por meio da formação de um dossel fechado e de múltiplos estratos verticais. A relação entre o tamanho médio e a densidade das árvores indica que, à medida que as florestas amadurecem, as taxas de acúmulo de biomassa aumentam, correlacionando-se com tamanhos maiores de árvores (Yu *et al.*, 2023; Gamboa-Blanco *et al.*, 2024). Essa tendência, refletida pelos maiores valores de biomassa observados no estágio avançado (ASV) em nossa área de estudo, destaca o papel das florestas tropicais em estágios avançados de sucessão na regulação do ciclo do carbono e na manutenção da complexidade estrutural local.

4.2 Comportamento espectral

Os resultados deste estudo confirmam que o comportamento espectral da vegetação varia significativamente entre diferentes estágios sucessionais. Foram observadas diferenças estatisticamente significativas nas reflectâncias dos fragmentos florestais ao longo do gradiente de sucessão, com variações mais evidentes ao considerar apenas pixels iluminados (*Mask*).

Além disso, a resolução espacial de 0,5 m mostrou-se mais adequada para capturar essas variações espectrais, destacando a relevância de resoluções altas em estudos que

demandam maior detalhamento na análise dos padrões de reflectância. Em resoluções espaciais menores, é comum a ocorrência de pixels mistos, os quais podem agregar informações de diferentes classes adjacentes, comprometendo a caracterização espectral.

4.2.1. Efeito da máscara

As diferenças observadas entre os valores de reflectância com e sem a exclusão de pixels sombreados destacam que o uso de máscara pode aprimorar a detecção de características espectrais, especialmente em estágios avançados de vegetação secundária (ASV) (Figura 1.11). A presença de sombra é amplamente reconhecida como um dos maiores desafios em imagens de sensoriamento remoto, por comprometer a extração precisa de informações e dificultar a detecção de mudanças (Shahtahmassebi *et al.*, 2013; Pons; Padro, 2019).

Os pixels sombreados correspondem a áreas radiometricamente alteradas, onde a reflectância aparente da superfície é modificada pela ausência de iluminação direta (Adler-Golden *et al.*, 2002; Gu; Robles-Kelly, 2014). Essa interferência resulta em variações significativas nos valores espectrais, como observado neste estudo. O problema se intensifica em imagens de alta resolução espacial, como as adquiridas por RPAs (Alavipanah *et al.*, 2022; Pons; Padro, 2019; Lopatin *et al.*, 2017; Lopatin *et al.*, 2019; Pinon *et al.*, 2024), podendo levar à redução parcial ou total de informações (Wu; Zhang; Huang, 2015; Kempeneers *et al.*, 2013).

As duas resoluções espaciais analisadas (0,5 m e 5 m) são consideradas altas e, por isso, mais suscetíveis aos efeitos de sombreamento. A aplicação de máscaras torna-se, portanto, uma estratégia relevante para mitigar tais efeitos e aumentar a confiabilidade das análises espectrais.

Uma limitação associada a resoluções espaciais ultrafinas é o aumento da variabilidade espectral intraclasses, decorrente da complexidade do dossel e da presença de sombras, o que dificulta a separação espectral entre classes (Lopatin *et al.*, 2017; Gonçalves *et al.*, 2024). A escolha cuidadosa do horário de aquisição das imagens também é um fator essencial, uma vez que em determinados períodos do dia, as sombras podem cobrir uma porção significativa da área de interesse, prejudicando a qualidade da análise (Milas *et al.*, 2017).

No presente estudo, verificou-se uma alta incidência de sombras no estágio avançado (ASV), diretamente relacionada à complexidade do dossel, típica de florestas maduras. Dosséis mais heterogêneos, com variação na altura e densidade da copa,

favorecem a projeção de sombras (Tian *et al.* 2024). Essa estrutura é mais pronunciada em florestas em estágios avançados de sucessão, em comparação àquelas em estágios iniciais ou intermediários (Franklin; Van Pelt, 2004; Zenner, 2004; Marques *et al.*, 2014; Toda *et al.*, 2023; Valente *et al.*, 2024).

A influência de pixels sombreados sobre os índices de vegetação foi distinta entre os cenários avaliados (*No mask* e *Mask*). No estágio avançado (ASV), NDVI e SR apresentaram valores superiores no cenário sem exclusão de pixels sombreados (*No mask*), enquanto SAVI e EVI foram mais elevados quando os pixels sombreados foram removidos (*Mask*) (Figuras 1.13A–H).

Resultados semelhantes foram relatados por Zhang *et al.* (2015), que observaram valores mais altos de NDVI e SR em áreas sombreadas utilizando espectrômetro terrestre NIR, enquanto o SAVI apresentou redução, possivelmente devido à sua correção do fundo do solo. De forma semelhante, Galvão *et al.* (2013) observaram um aumento nos valores de EVI com a redução da sombra. Esses resultados estão alinhados com as observações do presente estudo, destacando que as sombras podem influenciar de forma distinta os índices de vegetação, dependendo de suas características, levando à amplificação ou redução dos valores espectrais.

4.2.2. Efeito da resolução espacial

A influência da resolução espacial na resposta espectral variou conforme o estágio sucessional, sendo mais evidente nas fases intermediárias e avançadas de desenvolvimento da vegetação (Figura 1.14). Essa variação está relacionada à maior complexidade estrutural (Marques *et al.*, 2014; Toda *et al.*, 2023) e heterogeneidade espectral características desses estágios. Devido às interações complexas de estrutura e bioquímica foliar, arquitetura da copa e estrutura do dossel, a separabilidade espectral é diretamente afetada pela escala de observação (Liu *et al.*, 2020).

A resolução espacial de 0,5 m demonstrou maior capacidade de capturar essas variações, sobretudo nas regiões espectrais do Red Edge e do NIR, reforçando a importância de imagens de alta resolução espacial para análises florestais mais detalhadas (Figura 1.14). Resoluções espaciais submétricas, como as fornecidas por RPAs, permitem detectar variações sutis na estrutura do dossel que seriam suprimidas em resoluções espaciais mais grosseiras (Lucieer *et al.*, 2014; Räsänen; Virtanen, 2019). Essas resoluções espaciais são importantes para mapear paisagens heterogêneas e caracterizar gradientes associados aos diferentes estágios sucessionais.

Nesse contexto, Pinon *et al.* (2024) destacaram que a resolução espacial influencia significativamente a correlação entre métricas de diversidade espectral e diversidade de espécies em florestas secundárias de Mata Atlântica. Além disso, Tanhuanpää *et al.* (2023) verificaram que a redução da resolução espacial compromete a precisão na estimativa de variáveis estruturais, como altura máxima e volume.

Os efeitos da resolução espacial também foram evidentes na resposta dos índices de vegetação (Figura 1.15). Índices como NDVI e SR apresentaram valores mais elevados na resolução de 5 m, enquanto EVI e SAVI responderam melhor à resolução de 0,5 m. Esse comportamento reflete como diferentes índices reagem à escala de observação, e como a resolução espacial pode afetar tanto a sensibilidade espectral quanto a interpretação biofísica dos dados.

Jasinski (1990) destacou que índices simples, como o NDVI, são sensíveis ao tamanho do pixel: enquanto pixels maiores reduzem a variabilidade devido ao efeito de agregação, pixels menores permitem melhor detecção de variações locais na cobertura vegetal e no solo. Complementarmente, observa-se que, além do tamanho do pixel, a influência do fundo do solo nas imagens também pode interferir na resposta espectral, especialmente em áreas com vegetação esparsa (Chen *et al.*, 2019; Kammerud, 1996). Além disso, Végh e Tsuyuzaki (2021) reforçam que índices simples são mais afetados por resoluções mais finas, destacando a importância de considerar o índice e a escala de análise ao interpretar dados de sensoriamento remoto.

A relação entre resolução espacial e desempenho dos índices de vegetação tem sido amplamente discutida na literatura. Psomiadis *et al.* (2016), ao compararem imagens do WorldView-2 (2 m) e Landsat-8 (15 m), observaram que a resolução mais fina ofereceu maior precisão na detecção de variações sutis na cobertura vegetal, minimizando os efeitos da mistura espectral. Em contraste, a resolução mais grosseira do L8 apresentou limitações em ambientes heterogêneos, devido à agregação espacial.

Por outro lado, resoluções mais finas, apesar de mais detalhadas, tendem a introduzir maior variabilidade espectral em função da complexidade estrutural local (Li *et al.*, 2023; Végh; Tsuyuzaki, 2021; Liu *et al.*, 2020). Resoluções mais grosseiras, por sua vez, suavizam essas variações, reduzindo a sensibilidade às características locais (Tanhuanpää *et al.*, 2023).

De modo geral, a resolução espacial desempenhou um papel central neste estudo ao influenciar a análise das bandas espectrais e dos índices de vegetação. Essa influência impactou os valores de reflectância de acordo com as características das classes de vegetação e as métricas avaliadas.

A escolha da resolução ideal deve considerar não apenas a natureza da vegetação e os objetivos do estudo, mas também o equilíbrio entre variabilidade espectral intraclasse e separabilidade entre classes (Liu *et al.*, 2020; Woodcock; Strahler, 1987; Atkinson; Aplin, 2004; Peña; Cruz; Roig, 2013). Para mapeamentos gerais, resoluções mais grosseiras podem ser adequadas, mas para análises detalhadas e ambientes complexos resoluções submétricas são indispensáveis (Räsänen; Virtanen, 2019).

4.2.3. Distinção de estágios sucessionais

As variações espectrais observadas ao longo dos comprimentos de onda analisados evidenciam o papel de faixas específicas na diferenciação dos estágios sucessionais da vegetação (Figura 1.16). Dentre essas faixas, as regiões do Red Edge e do NIR se destacam pela sensibilidade na distinção entre os diferentes estágios de vegetação secundária avaliados neste estudo, reforçando a aplicabilidade na caracterização da vegetação secundária ao longo do gradiente sucessional.

O Red Edge, em particular, é reconhecido por sua capacidade de detectar alterações estruturais sutis, como variações no dossel, no teor de clorofila e no índice de área foliar, estando diretamente associado ao conteúdo de clorofila (Pradhan; Tiwari; Dhar, 2020; Zhang *et al.*, 2022; Schuster; Förster; Kleinschmit, 2012). Em consonância com os resultados encontrados, Chen *et al.* (2022), utilizando dados do sensor RapidEye, demonstraram que a banda Red Edge apresenta contribuição superior à das bandas do espectro visível na classificação de uso e cobertura do solo, com destaque para áreas vegetadas.

No presente estudo, a faixa do NIR também apresentou bom desempenho, permitindo uma separação nítida entre os estágios sucessionais, desde áreas de pastagem até o estágio médio de vegetação secundária (MSV), conforme ilustrado na Figura 1.16E. Essa resposta espectral está associada a variações no dossel, como mudanças na densidade, arranjo foliar e composição da vegetação.

Estudos anteriores corroboram esses resultados. Hallik *et al.* (2020) identificaram a reflectância do NIR como o melhor preditor da idade da floresta, destacando sua eficácia em estudos de sucessão florestal. Além disso, essa faixa é conhecida por minimizar a interferência do fundo do solo e por captar variações na área foliar e na capacidade fotossintética do dossel (Badgley; Field; Berry, 2017). Almalki *et al.* (2022) também demonstraram que o NIR é sensível ao tipo e à densidade da vegetação.

Do ponto de vista biofísico, esse comportamento pode ser explicado pela influência da arquitetura do dossel na reflectância, uma vez que o arranjo das folhas nas camadas superiores modula o sinal espectral refletido (Béland; Kobayashi, 2024). Complementarmente, Wu *et al.* (2022) mostraram que a densidade foliar e a presença de lacunas alteram o espalhamento e a transmissão da luz, intensificando o papel da estrutura do dossel nas variações espectrais observadas na faixa do NIR.

5 CONCLUSÕES

A análise dos padrões espectrais ao longo do gradiente sucessional demonstrou que as variações espectrais refletem mudanças significativas na vegetação. Embora tenham sido utilizados dados hiperespectrais, a estratégia metodológica adotada — baseada no agrupamento das bandas por faixas espectrais amplas (como médias do Blue, Green, Red, Red Edge e NIR) — limitou a exploração da alta resolução espectral disponível. Como consequência, os padrões observados foram compatíveis com aqueles que poderiam ser obtidos por sensores multiespectrais.

As regiões espectrais do Red Edge e do NIR destacaram-se na discriminação dos estágios sucessionais, indicando que sensores multiespectrais com cobertura adequada nessas faixas e resolução espacial apropriada são tecnicamente capazes de produzir resultados equivalentes. Logo, há a necessidade de abordagens analíticas mais refinadas que permitam explorar plenamente o potencial dos dados hiperespectrais em estudos futuros.

A presença de sombras alterou a reflectância, especialmente nos estágios médio e avançado de sucessão, devido à maior complexidade estrutural do dossel. Essa condição intensificou a ocorrência de áreas sombreadas, afetando a resposta espectral e limitando a precisão das análises. No entanto, o método de eliminação de sombras adotado mostrou-se eficaz na mitigação desses efeitos, permitindo uma representação mais precisa das características espectrais da vegetação.

A resolução espacial também influenciou a capacidade de discriminação dos estágios sucessionais. Enquanto a resolução de 0,5 m permitiu distinguir com clareza desde áreas de pasto limpo até estágios médios de sucessão, a resolução de 5 m foi eficaz na diferenciação entre classes iniciais, como pasto limpo, pasto ralo, pasto denso e estágio inicial. A redução da resolução espacial comprometeu a detecção de variações espectrais mais sutis, suavizando as diferenças espectrais entre os estágios.

Este estudo destaca a necessidade de abordagens integradas que combinem métricas espectrais e estruturais para aprimorar a distinção entre estágios. Como perspectiva futura, recomenda-se a integração de dados LiDAR para complementar as informações espectrais, viabilizando uma caracterização mais robusta da estrutura do dossel e dos processos sucessionais em florestas tropicais secundárias.

6 REFERÊNCIAS

ADLER-GOLDEN, S. M. *et al.* Algorithm for de-shadowing spectral imagery. **Proceedings of SPIE - The International Society for Optical Engineering.**, 2002. p. 203. Disponível em: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.451691>.

ALAVIPANAH, S. K. *et al.* The Shadow Effect on Surface Biophysical Variables Derived from Remote Sensing: A Review. **Land**, v. 11, n. 11, p. 2025, 2022. Disponível em: <https://www.mdpi.com/2073-445X/11/11/2025>.

ALMALKI, R. *et al.* Monitoring and Mapping Vegetation Cover Changes in Arid and Semi-Arid Areas Using Remote Sensing Technology: A Review. **Remote Sensing**, v. 14, n. 20, p. 5143, 2022. Disponível em: <https://www.mdpi.com/2072-4292/14/20/5143>.

ALMEIDA, C. T. de *et al.* Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, p. 111323, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425719303426>.

ALMEIDA, D. R. A. de *et al.* Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. **Remote Sensing of Environment**, v. 264, p. 112582, 2021. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425721003023>.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. Disponível em: http://www.schweizerbart.de/papers/metz/detail/22/82078/Koppen_s_climate_classification_map_for_Brazil?af=crossref.

APG IV. An update of the Angiosperm Phylogeny Group classification for the orders and families of flowering plants: APG IV. **Botanical Journal of the Linnean Society**, v. 181, n. 1, p. 1–20, 2016. Disponível em: <https://academic.oup.com/botlinnean/article-lookup/doi/10.1111/boj.12385>.

ARTAXO, P. *et al.* Tropical forests are crucial in regulating the climate on Earth. **PLOS Climate**, v. 1, n. 8, p. e0000054, 2022. Disponível em: <https://dx.plos.org/10.1371/journal.pclm.0000054>.

ARYAL, D. R. *et al.* Biomass recovery along a tropical forest succession: Trends on tree diversity, wood traits and stand structure. **Forest Ecology and Management**, v. 555, p. 121709, 2024. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378112724000215>.

ATKINSON, P. M.; APLIN, P. Spatial variation in land cover and choice of spatial resolution for remote sensing. **International Journal of Remote Sensing**, v. 25, n. 18, p. 3687–3702, 2004.

Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431160310001654383>.

BADGLEY, G.; FIELD, C. B.; BERRY, J. A. Canopy near-infrared reflectance and terrestrial photosynthesis. **Science Advances**, v. 3, n. 3, 2017. Disponível em: <https://www.science.org/doi/10.1126/sciadv.1602244>.

BARBOSA, J. M. *et al.* Remotely sensed biomass over steep slopes: An evaluation among successional stands of the Atlantic Forest, Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 91–100, 2014. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271613002815>.

BÉLAND, M.; KOBAYASHI, H. Drivers of deciduous forest near-infrared reflectance: A 3D radiative transfer modeling exercise based on ground lidar. **Remote Sensing of Environment**, v. 302, p. 113951, 2024.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425723005035>.

BLACKBURN, G.A. Quantifying chlorophylls and carotenoids at leaf and canopy scales: an evaluation of some hyperspectral approaches. *Remote Sensing of Environment*, v. 66, p. 273–285, 1998. Disponível em: [http://dx.doi.org/10.1016/S0034-4257\(98\)00059-5](http://dx.doi.org/10.1016/S0034-4257(98)00059-5).

BORMA, L. S. *et al.* Beyond Carbon: The Contributions of South American Tropical Humid and Subhumid Forests to Ecosystem Services. **Reviews of Geophysics**, v. 60, n. 4, 2022. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2021RG000766>.

CARTER, G.A.; MILLER, R.L. Early detection of plant stress by digital imaging within narrow stress-sensitive wavebands. *Remote Sensing of Environment*, v. 50, p. 295–302, 1994. Disponível em: [http://dx.doi.org/10.1016/0034-4257\(94\)90079-5](http://dx.doi.org/10.1016/0034-4257(94)90079-5).

CHAVE, J. *et al.* Towards a worldwide wood economics spectrum. **Ecology Letters**, v. 12, n. 4, p. 351–366, 2009. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/j.1461-0248.2009.01285.x>.

CHAZDON, R. L. **Second Growth: The Promise of Tropical Forest Regeneration in an Age of Deforestation**. London, UK: University of Chicago Press, 2014.

CHAZDON, R. L.; GUARIGUATA, M. R. Natural regeneration as a tool for large-scale forest restoration in the tropics: prospects and challenges. **Biotropica**, v. 48, n. 6, p. 716–730, 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/btp.12381>.

CHEN, X. *et al.* Replacing the Red Band with the Red-SWIR Band (0.74pred+0.26pswir) Can Reduce the Sensitivity of Vegetation Indices to Soil Background. **Remote sensing**, v. 11, n. 7, p. 851, 2019. Disponível em: <https://doi.org/10.3390/rs11070851>.

CHEN, T.-Y. *et al.* Effectiveness of the red-edge band of RapidEye in land cover classification. **Journal of the Chinese Institute of Engineers**, v. 46, n. 1, p. 21–30, 2023. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/02533839.2022.2141339>.

CHEN, N. *et al.* Revealing the spatial variation in biomass uptake rates of Brazil's secondary

forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 208, p. 233–244, 2024. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271624000169>.

COELHO, A. L. N. *et al.* **Mapeamento geomorfológico do estado do Espírito Santo**. Vitória - ES: IJSN, 2012. Disponível em: https://ijsn.es.gov.br/Media/IJSN/PublicacoesAnexos/notatecnica/1310_ijsn_nt28-.pdf.

COOLEY, J. H.; COOLEY, T. W. Combining structural and spectral information for discrimination using pulse coupled neural networks in multispectral and hyperspectral data. *In:* , 1997. **IGARSS'97. 1997 IEEE International Geoscience and Remote Sensing Symposium Proceedings. Remote Sensing - A Scientific Vision for Sustainable Development**. IEEE, 1997. p. 1666–1668. Disponível em: <http://ieeexplore.ieee.org/document/609015/>.

CUI, S. *et al.* SiamC Transformer: Siamese coupling swin transformer Multi-Scale semantic segmentation network for vegetation extraction under shadow conditions. **Computers and Electronics in Agriculture**, v. 213, p. 108245, 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169923006336>.

CUNHA, A. de M. *et al.* Atualização da legenda do mapa de reconhecimento de solos do estado do Espírito Santo e implementação de interface no geobases para uso dos dados em SIG. **Geografares**, v. 2, n. 22, p. 32–65, 2021. Disponível em: <https://periodicos.ufes.br/geografares/article/view/30205>.

CUSACK, D. F. *et al.* Tropical forests and global change: biogeochemical responses and opportunities for cross-site comparisons, an organized session at the 108th Annual Meeting, Ecological Society of America, Portland, Oregon, <scp>USA</scp> , A. **New Phytologist**, v. 241, n. 5, p. 1922–1926, 2024. Disponível em: <https://nph.onlinelibrary.wiley.com/doi/10.1111/nph.19511>.

DANDOIS, J.; OLANO, M.; ELLIS, E. Optimal Altitude, Overlap, and Weather Conditions for Computer Vision UAV Estimates of Forest Structure. **Remote Sensing**, v. 7, n. 10, p. 13895–13920, 2015. Disponível em: <https://www.mdpi.com/2072-4292/7/10/13895>.

DATT, B. Visible/near infrared reflectance and chlorophyll content in Eucalyptus leaves. *International Journal of Remote Sensing*, v. 20, p. 2741–2759, 1999. Disponível em: <http://dx.doi.org/10.1080/014311699211778>.

ECKE, S. *et al.* Towards operational UAV-based forest health monitoring: Species identification and crown condition assessment by means of deep learning. **Computers and Electronics in Agriculture**, v. 219, p. 108785, 2024. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169924001765>.

FLORA E FUNGA DO BRASIL. **Flora e Funga do Brasil**. 2023. Disponível em: <https://floradobrasil.jbrj.gov.br/consulta/#CondicaoTaxonCP>. Acesso em: 11 maio 2023.

FRANKLIN, J. F.; VAN PELT, R. Spatial Aspects of Structural Complexity in Old-Growth Forests. **Journal of Forestry**, v. 102, n. 3, p. 22–28, 2004. Disponível em: <https://academic.oup.com/jof/article/102/3/22/4613153>.

GALVÃO, L. S. *et al.* View-illumination effects on hyperspectral vegetation indices in the Amazonian tropical forest. **International Journal of Applied Earth Observation and**

Geoinformation, v. 21, p. 291–300, 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243412001432>.

GAMBOA-BLANCO, E. A. *et al.* Effects of successional age, plot size, and tree size on the relationship between diversity and aboveground biomass in tropical dry forests. **Plant Ecology**, v. 225, n. 8, p. 803–817, 2024. Disponível em: <https://link.springer.com/10.1007/s11258-024-01435-4>.

GAMON, J.A.; PEÑUELAS, J.; FIELD, C.B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of Environment*, v. 41, p. 35–44, 1992. Disponível em: [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S).

GAMON, J.A.; SERRANO, L.; SURFUS, J.S. The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels. *Oecologia*, v. 112, p. 492–501, 1997.

GAMON, J.A.; SURFUS, J.S. Assessing leaf pigment content and activity with a reflectometer. *New Phytologist*, v. 143, p. 105–117, 1999. Disponível em: <http://dx.doi.org/10.1046/j.1469-8137.1999.00424.x>.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, v. 80, p. 76–87, 2002. Disponível em: [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9).

GITELSON, A. A.; KEYDAN, G. P.; MERZLYAK, M. N. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophysical Research Letters*, v. 33, p. 2–6, 2006. Disponível em: <https://doi.org/10.1029/2006GL026457>.

GITELSON, A.A.; ZUR, Y.; CHIVKUNOVA, O.B.; MERZLYAK, M.N. Assessing carotenoid content in plant leaves with reflectance spectroscopy. *Photochemistry and Photobiology*, v. 75, p. 272–281, 2007.

GODFROY, J. *et al.* Combining Hyperspectral, LiDAR, and Forestry Data to Characterize Riparian Forests along Age and Hydrological Gradients. **Remote Sensing**, v. 15, n. 1, p. 17, 2022. Disponível em: <https://www.mdpi.com/2072-4292/15/1/17>.

GONCALVES, N. B. *et al.* Cloud shadow and uneven illumination detection and correction using the U-net architecture in near-surface images of complex forest canopies. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLVIII-3-2, p. 191–196, 2024. Disponível em: <https://isprs-archives.copernicus.org/articles/XLVIII-3-2024/191/2024/>.

GONÇALVES, S. D. N. C. *et al.* Dynamics of natural regeneration in a fragment of a Mixed Ombrophilous Forest in the upland region of Santa Catarina, Brazil. **Ciência Florestal**, v. 32, n. 2, p. 812–828, 2022. Disponível em: <http://periodicos.ufsm.br/cienciaflorestal/article/view/53272>.

GONG, X.; SHEN, L.; LU, T. Refining Training Samples Using Median Absolute Deviation for Supervised Classification of Remote Sensing Images. **Journal of the Indian Society of Remote Sensing**, v. 47, n. 4, p. 647–659, 2019. Disponível em: <http://link.springer.com/10.1007/s12524-018-0887-7>.

GU, L.; ROBLES-KELLY, A. Shadow modelling based upon Rayleigh scattering and Mie theory. **Pattern Recognition Letters**, v. 43, p. 89–97, 2014. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0167865513004121>.

HALLIK, L. *et al.* Reflectance Properties of Hemiboreal Mixed Forest Canopies with Focus on Red Edge and Near Infrared Spectral Regions. **Remote Sensing**, [s. l.], v. 11, n. 14, p. 1717, 2019. Disponível em: <https://www.mdpi.com/2072-4292/11/14/1717>.

HANEDA, L. E. *et al.* Forest landscape restoration: Spectral behavior and diversity of tropical tree cover classes. **Remote Sensing Applications: Society and Environment**, [s. l.], v. 29, p. 100882, 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352938522001902>.

HE, X. *et al.* Tracking succession by means of 3D scans of plant communities in a glacier forefield to infer assembly processes. **Oikos**, [s. l.], v. 2023, n. 12, 2023. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/oik.10095>.

HEADWALL. **Airborne sensor ground calibration panel**. Bolton, Massachusetts: [s. n.], 2017.

HEADWALL. **Nano HP (400-1000nm) Hyperspectral Imaging Package**. [S. l.], 2023. Disponível em: <https://headwallphotonics.com/products/remote-sensing/nano-hp-400-1000nm-hyperspectral-imaging-package/>. Acesso em: 10 jan. 2023.

HIJMANS, R. J. *et al.* **Terra: Spatial Data Analysis**. [S. l.]: CRAN, 2025. Disponível em: <https://rspatial.org/>.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, v. 25, n. 3, p. 295–309, ago. 1988. Disponível em: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.; GAO, X.; FERREIRA, L. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, v. 83, p. 195–213, 2002. Disponível em: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2).

ICMBIO. **Plano de Manejo da Floresta Nacional de Pacotuba**. ICMBIO: Brasília, Brasil, 2011. Disponível em: https://www.gov.br/icmbio/pt-br/assuntos/biodiversidade/unidade-de-conservacao/unidades-de-biomas/mata-atlantica/lista-de-ucs/flona-de-pacotuba/arquivos/volume_i_pacotuba_junho_2011.pdf. Acesso em: 25 abr. 2025.

IM, J.; JENSEN, J. R. Hyperspectral Remote Sensing of Vegetation. **Geography Compass**, [s. l.], v. 2, n. 6, p. 1943–1961, 2008. Disponível em: <https://compass.onlinelibrary.wiley.com/doi/10.1111/j.1749-8198.2008.00182.x>.

INCAPER. **Programa de Assistência Técnica e Extensão Rural, Proater 2020–2023**. São Mateus - ES: [s. n.], 2020. Disponível em: https://incaper.es.gov.br/media/incaper/proater/municipios/Jeronimo_Monteiro.pdf.

IPCC. Technical Summary. *In: CLIMATE CHANGE 2022 – IMPACTS, ADAPTATION AND VULNERABILITY*. [S. l.]: Cambridge University Press, 2023. p. 37–118. Disponível em:

- https://www.cambridge.org/core/product/identifier/9781009325844%23pre3/type/book_part
- JACON, A. D. *et al.* Aboveground biomass estimates over Brazilian savannas using hyperspectral metrics and machine learning models: experiences with Hyperion/EO-1. **GIScience & Remote Sensing**, [s. l.], v. 58, n. 7, p. 1112–1129, 2021. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/15481603.2021.1969630>.
- JASINSKI, M. F. Sensitivity of the normalized difference vegetation index to subpixel canopy cover, soil albedo, and pixel scale. **Remote Sensing of Environment**, v. 32, n. 2–3, p. 169–187, 1990. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/003442579090016F>.
- JORDAN, C. F. Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, v. 50, p. 663–666, 1969. Disponível em: <https://doi.org/10.2307/1936256>.
- KAMMERUD, T. A. Soil Impact on Satellite Based Vegetation Monitoring in Sahelian Mali. **Geografiska Annaler: Series A, Physical Geography**, v. 78, n. 4, p. 247-259, 1996. Disponível em: <https://doi.org/10.1080/04353676.1996.11880471>.
- KAYET, N. Forest Health Monitoring using Hyperspectral Remote Sensing Techniques. *In: SPATIAL MODELING IN FOREST RESOURCES MANAGEMENT*. [S. l.]: Springer Cham, 2021. p. 239–257. Disponível em: https://link.springer.com/10.1007/978-3-030-56542-8_10.
- KEMPENEERS, P. *et al.* Propagation of shadow effects on typical remote sensing applications in forestry. *In: , 2013. 2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. [S. l.]: IEEE, 2013. p. 1–5. Disponível em: <http://ieeexplore.ieee.org/document/8080613/>.
- KIM, M.S. The Use of Narrow Spectral Bands for Improving Remote Sensing Estimations of Fractionally Absorbed Photosynthetically Active Radiation. Digital Repository at the University of Maryland, 1994.
- LAPIN, K. *et al.* Identification and prioritization of stepping stones for biodiversity conservation in forest ecosystems. **Conservation Science and Practice**, v. 6, n. 7, 2024. Disponível em: <https://conbio.onlinelibrary.wiley.com/doi/10.1111/csp2.13161>.
- LI, Y. *et al.* Relationship between species diversity and tree size in natural forests around the Tropic of Cancer. **Journal of Forestry Research**, v. 34, n. 6, p. 1735–1745, 2023. Disponível em: <https://link.springer.com/10.1007/s11676-023-01616-3>.
- LIU, M. *et al.* The Impact of Spatial Resolution on the Classification of Vegetation Types in Highly Fragmented Planting Areas Based on Unmanned Aerial Vehicle Hyperspectral Images. **Remote Sensing**, v. 12, n. 1, p. 146, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/1/146>.
- LOPATIN, J. *et al.* How canopy shadow affects invasive plant species classification in high spatial resolution remote sensing. **Remote Sensing in Ecology and Conservation**, v. 5, n. 4, p. 302–317, 2019. Disponível em: <https://zslpublications.onlinelibrary.wiley.com/doi/10.1002/rse2.109>.
- LOPATIN, J. *et al.* Mapping plant species in mixed grassland communities using close range imaging spectroscopy. **Remote Sensing of Environment**, v. 201, p. 12–23, 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425717303966>.

LU, B. *et al.* Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture. **Remote Sensing**, v. 12, n. 16, p. 2659, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/16/2659>.

LUCIEER, A. *et al.* HyperUAS—Imaging Spectroscopy from a Multirotor Unmanned Aircraft System. **Journal of Field Robotics**, v. 31, n. 4, p. 571–590, 2014. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/rob.21508>.

MAGPANTAY, A. T.; FERNANDEZ, P. L. Improving the Classification of Landsat-8 OLI Images using Neighborhood Median Pixel Values. *In:* , 2020. **2020 International Conference on Communication and Signal Processing (ICCSP)**. IEEE, 2020. p. 1054–1058. Disponível em: <https://ieeexplore.ieee.org/document/9182359/>.

MAPBIOMAS. **Uso e cobertura (1985-2023)**. 2024. Disponível em: <https://brasil.mapbiomas.org/colecoes-mapbiomas/>. Acesso em: 25 de abr. 2025.

MARQUES, M. C. M. *et al.* Forest structure and species composition along a successional gradient of Lowland Atlantic Forest in Southern Brazil. **Biota Neotropica**, v. 14, n. 3, p. e20140094, 2014. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1676-06032014000300118&lng=en&tlng=en.

MATOS, F. A. R. *et al.* Secondary forest fragments offer important carbon and biodiversity cobenefits. **Global Change Biology**, v. 26, n. 2, p. 509–522, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/gcb.14824>.

MEMIAGHE, H. R. *et al.* Ecological Importance of Small-Diameter Trees to the Structure, Diversity and Biomass of a Tropical Evergreen Forest at Rabi, Gabon. **PLOS ONE**, v. 11, n. 5, p. e0154988, 2016. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0154988>.

MERTON, R.N. Multi-temporal Analysis of Community Scale Vegetation Stress With Imaging Spectroscopy. ResearchSpace@Auckland, 1999.

MERTON, R.; HUNTINGTON, J. Early simulation results of the ARIES-1 satellite sensor for multi-temporal vegetation research derived from AVIRIS. NASA Jet Propulsion Lab., Pasadena, CA, 1999. Disponível em: https://aviris.jpl.nasa.gov/proceedings/workshops/99_docs/41.pdf.

MILAS, A. S. *et al.* Different colours of shadows: classification of UAV images. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 3084–3100, 2017. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431161.2016.1274449>.

MOHAMAD, W. N. W. Conservation of Tropical Forest for the Well-Being of Community. *In:* Tropical forest ecosystem services in improving livelihoods for local communities. Singapore: Springer Nature Singapore, 2023. p. 1–14. Disponível em: https://link.springer.com/10.1007/978-981-19-3342-4_1.

MOLINEZ, R. Z. *et al.* Historical and recent deforestation patterns in the Atlantic Forest from satellite monitoring system - PRODES. **Revista Brasileira de Cartografia**, v. 76, 2024. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/72589>.

MONTGOMERY, R. A.; FRELICH, L. E. Forest succession and gap dynamics. *In: Routledge handbook of forest ecology*. Abingdon, UK: Routledge Press, 2024. p. 16.

Disponível em: <https://www.taylorfrancis.com/chapters/edit/10.4324/9781003324072-12/forest-succession-gap-dynamics-rebecca-montgomery-lee-frelich>.

NYTCH, C. J. *et al.* Effects of historical land use and recovery pathways on composition, structure, ecological function, and ecosystem services in a Caribbean secondary forest.

Forest Ecology and Management, v. 546, p. 121311, 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378112723005455>.

PEÑA, M. A.; CRUZ, P.; ROIG, M. The effect of spectral and spatial degradation of hyperspectral imagery for the Sclerophyll tree species classification. **International Journal of Remote Sensing**, v. 34, n. 20, p. 7113–7130, 2013. Disponível em:

<https://www.tandfonline.com/doi/full/10.1080/01431161.2013.817712>.

PEÑUELAS, J.; BARET, F.; FILELLA, I. Semiempirical indexes to assess carotenoids chlorophyll-a ratio from leaf spectral reflectance. *Photosynthetica*, v. 31, p. 221–230, 1995.

PEÑUELAS, J.; FILELLA, I.; BIEL, C.; SERRANO, L. The reflectance at the 950–970 nm region as an indicator of plant water status. *International Journal of Remote Sensing*, v. 14, p. 1887–1905, 1993.

PINON, T. B. M. *et al.* Biodiversity from the Sky: Testing the Spectral Variation Hypothesis in the Brazilian Atlantic Forest. **Remote Sensing**, v. 16, n. 23, p. 4363, 2024. Disponível em: <https://www.mdpi.com/2072-4292/16/23/4363>.

PONS, X.; PADRO, J.-C. An Empirical Approach on Shadow Reduction of UAV Imagery in Forests. *In:* , 2019. **IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2019. p. 2463–2466. Disponível em: <https://ieeexplore.ieee.org/document/8899872/>.

POORTER, L. *et al.* A comprehensive framework for vegetation succession. **Ecosphere**, v. 15, n. 4, 2024.

Disponível em: <https://esajournals.onlinelibrary.wiley.com/doi/10.1002/ecs2.4794>.

POORTER, L. *et al.* Successional theories. **Biological Reviews**, v. 98, n. 6, p. 2049–2077, 2023. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/brv.12995>.

PRADHAN, S.; TIWARI, K. N.; DHAR, A. Evaluation of Sentinel 2 Red Edge Channel for Enhancing Land Use Classification. *In: Water management and water governance*. Springer Cham, 2021. p. 79–89. Disponível em: http://link.springer.com/10.1007/978-3-030-58051-3_6.

PSOMIADIS, E. *et al.* The role of spatial and spectral resolution on the effectiveness of satellite-based vegetation indices. **SPIE Remote Sensing**. 2016. p. 99981L. Disponível em: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2241316>.

R CORE TEAM. **RStudio: Integrated Development Environment for R**. Boston, MA: RStudio, PBC, 2023. Disponível em: <http://www.rstudio.com/>.

RÄSÄNEN, A.; VIRTANEN, T. Data and resolution requirements in mapping vegetation in spatially heterogeneous landscapes. **Remote Sensing of Environment**, v. 230, p. 111207,

2019.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425719302202>.

RÉJOU-MÉCHAIN, M. *et al.* biomass : an package for estimating above-ground biomass and its uncertainty in tropical forests. **Methods in Ecology and Evolution**, v. 8, n. 9, p. 1163–1167, 2017.

Disponível em: <https://besjournals.onlinelibrary.wiley.com/doi/10.1111/2041-210X.12753>.

ROUSE, W.; HAAS, R.H.; DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS. NASA Special Publication, v. 351, p. 309, 1974.

SANTOS, A. R. *et al.* Fuzzy concept applied in determining potential forest fragments for deployment of a network of ecological corridors in the Brazilian Atlantic Forest. **Ecological Indicators**, v. 115, p. 106423, 2020.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1470160X20303605>.

SCHUSTER, C.; FÖRSTER, M.; KLEINSCHMIT, B. Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5583–5599, 2012. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431161.2012.666812>.

SHAHTAHMASSEBI, A. *et al.* Review of shadow detection and de-shadowing methods in remote sensing. **Chinese Geographical Science**, v. 23, n. 4, p. 403–420, 2013. Disponível em: <http://link.springer.com/10.1007/s11769-013-0613-x>.

SHRAMA, L.; GUPTA, R.; VERMA, R. K. Efficacy of Advanced Remote Sensing (Hyperspectral and LIDAR) in Enhancing Forest Resources Management. *In: Research anthology on ecosystem conservation and preserving biodiversity*. IGI Global, 2022. p. 1714–1733.

Disponível em: <https://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/978-1-6684-5678-1.ch083>.

SILVA, L. D. C. da. **Mudança em volume, biomassa e carbono do fuste em uma floresta estacional semidecidual da Mata Atlântica, ES**. 2020. 149 f. - Universidade Federal do Espírito Santo, 2020.

SILVA, B. R. F. da *et al.* Using Drones for Dendrometric Estimations in Forests: A Bibliometric Analysis. **Forests**, v. 15, n. 11, p. 1993, 2024. Disponível em: <https://www.mdpi.com/1999-4907/15/11/1993>.

SINEGALIA, M. K. S. D.; SANTORO, G. B.; MOLIN, P. G. How have RPAS helped monitor forests and what can we apply in forest restoration monitoring?. **Restoration Ecology**, v. 32, n. 1, 2024. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/rec.14061>.

SINGH, A. Spectral separability of tropical forest cover classes. **International Journal of Remote Sensing**, v. 8, n. 7, p. 971–979, 1987. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431168708954741>.

SUH, H. K.; HOFSTEE, J. W.; VAN HENTEN, E. J. Improved vegetation segmentation with ground shadow removal using an HDR camera. **Precision Agriculture**, v. 19, n. 2, p. 218–237, 2018. Disponível em: <http://link.springer.com/10.1007/s11119-017-9511-z>.

SUN, H. *et al.* UAV Platforms for Data Acquisition and Intervention Practices in Forestry: Towards More Intelligent Applications. **Aerospace**, v. 10, n. 3, p. 317, 2023. Disponível em: <https://www.mdpi.com/2226-4310/10/3/317>.

TANHUANPÄÄ, T. *et al.* Input data resolution affects the conservation prioritization outcome of spatially sparse biodiversity features. **Ambio**, v. 52, n. 11, p. 1793–1803, 2023. Disponível em: <https://link.springer.com/10.1007/s13280-023-01885-6>.

THESSLER, S. *et al.* Using k-nn and discriminant analyses to classify rain forest types in a Landsat TM image over northern Costa Rica. **Remote Sensing of Environment**, v. 112, n. 5, p. 2485–2494, 2008. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425708000126>.

TIAN, J. *et al.* Quasi-HSL color space and its application: Sunlit and shaded component fractional cover estimation in vegetated ecosystem. **International Journal of Applied Earth Observation and Geoinformation**, v. 135, p. 104298, 2024. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S156984322400654X>.

TODA, M. *et al.* Simulated effects of canopy structural complexity on forest productivity. **Forest Ecology and Management**, v. 538, p. 120978, 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378112723002128>.

VALENTE, C. *et al.* Diversity and structure of tree and regenerating strata in fragments at different successional stages in the Atlantic Forest of Brazil. **Phytocoenologia**, v. 52, n. 1, p. 71–85, 2024. Disponível em: http://www.schweizerbart.de/papers/phyto/detail/52/104825/Diversity_and_structure_of_tree_and_regenerating_s?af=crossref.

VAN DEN BERG, A.K.; PERKINS, T.D. Nondestructive estimation of anthocyanin content in autumn sugar maple leaves. *HortScience*, v. 40, p. 685–686, 2005.

VÉGH, L.; TSUYUZAKI, S. Remote sensing of forest diversities: the effect of image resolution and spectral plot extent. **International Journal of Remote Sensing**, v. 42, n. 15, p. 5985–6002, 2021. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431161.2021.1934596>.

VERMA, R. K.; SHARMA, L. K.; LELE, N. AVIRIS-NG hyperspectral data for biomass modeling: from ground plot selection to forest species recognition. **Journal of Applied Remote Sensing**, v. 17, n. 01, 2023. Disponível em: <https://www.spiedigitallibrary.org/journals/journal-of-applied-remote-sensing/volume-17/issue-01/014522/AVIRIS-NG-hyperspectral-data-for-biomass-modeling--from-ground/10.1117/1.JRS.17.014522.full>.

WILLIAMS, B. A. *et al.* Global potential for natural regeneration in deforested tropical regions. **Nature**, v. 636, n. 8041, p. 131–137, 2024. Disponível em: <https://www.nature.com/articles/s41586-024-08106-4>.

WOODCOCK, C. E.; STRAHLER, A. H. The factor of scale in remote sensing. **Remote Sensing of Environment**, v. 21, n. 3, p. 311–332, 1987. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/0034425787900150>.

WU, Q.; YANG, S.; JIANG, J. Canopy structural effects on bidirectional reflectance simulated by the less model: a case study of *Picea crassifolia* forests. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. X-3/W2-202, p. 51–57, 2022. Disponível em: <https://isprs-annals.copernicus.org/articles/X-3-W2-2022/51/2022/>.

WU, T.; ZHANG, L.; HUANG, C. An analysis of shadow effects on spectral vegetation indices using a ground-based imaging spectrometer. *In:* , 2015, Tokyo, Japan. **2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)**. 2015. p. 1–4.

YU, K. *et al.* Forest demography and biomass accumulation rates are associated with transient mean tree size vs. density scaling relations. **PNAS Nexus**, v. 3, n. 2, 2024. Disponível em: <https://academic.oup.com/pnasnexus/article/doi/10.1093/pnasnexus/pgae008/7609807>.

ZENNER, E. K. Does old-growth condition imply high live-tree structural complexity?. **Forest Ecology and Management**, v. 195, n. 1–2, p. 243–258, 2004. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378112704002221>.

ZHANG, H. *et al.* A novel red-edge spectral index for retrieving the leaf chlorophyll content. **Methods in Ecology and Evolution**, v. 13, n. 12, p. 2771–2787, 2022. Disponível em: <https://besjournals.onlinelibrary.wiley.com/doi/10.1111/2041-210X.13994>.

ZHANG, L. *et al.* An Analysis of Shadow Effects on Spectral Vegetation Indexes Using a Ground-Based Imaging Spectrometer. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 11, p. 2188–2192, 2015. Disponível em: <http://ieeexplore.ieee.org/document/7180331/>.

ZHAO, Y. *et al.* Forest species diversity mapping using airborne LiDAR and hyperspectral data in a subtropical forest in China. **Remote Sensing of Environment**, v. 213, p. 104–114, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425718302359>.

ТЕРЕХИН, Э. А. SPECTRAL RESPONSE OF ABANDONED AGRICULTURAL LANDS IN THE ASSESSMENT OF THEIR VEGETATION COVER AND REFORESTATION. *In:* , 2022. **Лесные экосистемы в условиях изменения климата: биологическая продуктивность и дистанционный мониторинг**. Crossref, 2022. p. 65–75. Disponível em: https://inter.volgatech.net/upload/ums/forecos-2022/FORECO_2022_Terekhin_ru.pdf.

CAPÍTULO II - ESTIMATIVA DE BIOMASSA ACIMA DO SOLO EM FRAGMENTOS FLORESTAIS DE MATA ATLÂNTICA COM DADOS HIPERESPECTRAIS-RPA: AVALIANDO O EFEITO DA RESOLUÇÃO ESPACIAL E DE PIXELS SOMBREADOS

RESUMO

Florestas tropicais secundárias são fundamentais para a conservação da biodiversidade e o sequestro de carbono, mas a estimativa da biomassa acima do solo (AGB) nessas áreas ainda é desafiadora, dada a complexidade estrutural e os efeitos de sombreamento. O sensoriamento hiperespectral destaca-se como ferramenta promissora, ao possibilitar a análise detalhada da resposta espectral da vegetação e sua relação com a biomassa ao longo do gradiente sucessional. Este estudo investigou a relação entre AGB e métricas espectrais derivadas de sensor hiperespectral obtidas com aeronave remotamente pilotada (HS-RPA). Além disso, avaliou-se como a resolução espacial e a presença de sombras afetam a precisão das estimativas de biomassa. Foram instaladas 30 parcelas permanentes (30 × 30 m) em quatro remanescentes florestais no sul do estado do Espírito Santo, Brasil. Em cada parcela, todos os indivíduos arbóreos com Diâmetro à altura do peito (D , medido a 1,3 m do solo) ≥ 5 cm foram identificados e mensurados para estimar a biomassa acima do solo (AGB). Os dados espectrais foram adquiridos com um sensor hiperespectral operando na faixa 397–1002 nm e resolução de 0,11 m, posteriormente reamostrada para 0,5 m e 5 m. Foram avaliados quatro cenários: (i) com pixels sombreados e resolução de 0,5 m, (ii) sem pixels sombreados e resolução de 0,5 m, (iii) com pixels sombreados e resolução de 5 m e (iv) sem pixels sombreados e resolução de 5 m. Para identificar as métricas espectrais mais relevantes, foi utilizado o algoritmo Boruta, seguido pelo método de busca exaustiva para selecionar os melhores subconjuntos de variáveis. A modelagem da biomassa foi realizada por meio de regressão linear. Os melhores resultados foram obtidos nos cenários com presença de pixels sombreados, tanto para a resolução de 5 m quanto para 0,5 m, indicando que a remoção desses pixels não resultou em ganhos de precisão. Além disso, o modelo mais preciso foi gerado com resolução de 5 m ($R^2_{aj} = 0,78$; $RMSE = 50,50\%$), sugerindo que, em determinados contextos, resoluções ligeiramente mais baixas podem contribuir para maior estabilidade espectral ao suavizar variações estruturais do dossel. Os resultados obtidos fornecem subsídios relevantes para o desenvolvimento de metodologias mais precisas voltadas à estimativa de biomassa, contribuindo para o aprimoramento de estratégias de monitoramento florestal.

Palavras-chave: Sensoriamento remoto. Métricas hiperespectrais. Floresta Tropical.

ABSTRACT

Secondary tropical forests play a key role in biodiversity conservation and carbon sequestration, yet estimating aboveground biomass (AGB) in these ecosystems remains challenging due to high structural complexity and spectral interference caused by canopy shading. Hyperspectral remote sensing emerges as a promising tool for this purpose, as it enables detailed analysis of vegetation spectral response and its relationship with biomass along the successional gradient. This study investigated the relationship between AGB and spectral metrics derived from hyperspectral sensors onboard a remotely piloted aircraft (HS-RPA). Additionally, it assessed how spatial resolution and the presence of shadows affect biomass estimation accuracy. A total of 30 permanent plots (30 m × 30 m) were established in four forest remnants in southern Espírito Santo, Brazil. Within each plot, all trees with diameter at breast height (DBH, measured at 1.3 m) \geq 5 cm were identified and measured to estimate AGB. Spectral data were acquired using a hyperspectral sensor operating in the 397–1002 nm range, with a native spatial resolution of 0.11 m, later resampled to 0.5 m and 5 m. Four scenarios were evaluated: (i) with shaded pixels at 0.5 m resolution, (ii) without shaded pixels at 0.5 m resolution, (iii) with shaded pixels at 5 m resolution, and (iv) without shaded pixels at 5 m resolution. The Boruta algorithm was used to identify the most relevant spectral metrics, followed by an exhaustive search method to select the best subsets of variables. Biomass modeling was performed using linear regression. The best results were obtained in scenarios that included shaded pixels, at both 0.5 m and 5 m resolutions, indicating that shadow removal did not improve estimation accuracy. Furthermore, the most accurate model was generated at 5 m resolution (adjusted $R^2 = 0.78$; RMSE = 50.50%), suggesting that, in certain contexts, slightly lower resolutions may enhance spectral stability by smoothing structural variations in the canopy. The findings provide valuable input for the development of more accurate biomass estimation methodologies and contribute to the advancement of forest monitoring strategies.

Keywords: Remote sensing. Hyperspectral metrics. Tropical forest.

1 INTRODUÇÃO

As florestas tropicais são sistemas fundamentais responsáveis por atenuar os efeitos extremos das mudanças climáticas (Santoro *et al.*, 2021; Mo *et al.*, 2023), sendo responsáveis por armazenar aproximadamente 68% do carbono global (IPCC, 2019). Além disso, são fundamentais para a conservação da biodiversidade do planeta (Aide *et al.*, 2013; Rocha *et al.*, 2018; Chazdon *et al.*, 2009; Wright; Muller-Landau, 2006).

No entanto, estas florestas vêm passando por um acelerado processo de desmatamento e degradação (Kunte; Bhat, 2024; Smith; Baker; Spracklen, 2023), resultando no aumento de áreas com florestas tropicais secundárias (Aide *et al.*, 2013; Lamb, 2011). Nesse contexto, compreender a capacidade dessas florestas secundárias em armazenar carbono e sustentar processos ecológicos é essencial para a formulação de estratégias de conservação e manejo florestal sustentável (Treitz; Howarth, 1999).

A biomassa acima do solo (AGB) é um dos principais indicadores ecológicos da estrutura e funcionalidade ecológica das florestas tropicais, pois está diretamente relacionada ao estoque de carbono (Higa *et al.*, 2014; Guimarães *et al.*, 2022). No entanto, a quantificação precisa da AGB exige métodos destrutivos que são logisticamente inviáveis em larga escala (Clark; Kellner, 2012). Como alternativa, utilizam-se modelos alométricos, os quais estimam a biomassa com base em atributos como diâmetro, altura e densidade da madeira (Chen *et al.*, 2019). Ainda assim, tais modelos estão sujeitos a incertezas decorrentes da variação intraespecífica, extrapolações regionais e limitações no levantamento de dados de campo (Chave *et al.*, 2004; Roxburgh; Paul, 2024).

Geralmente, campanhas de campo de inventário florestal são realizadas para caracterizar os parâmetros das florestas. No entanto, esta abordagem acaba representando apenas pequenas áreas (Almeida *et al.*, 2020; White *et al.*, 2016), o que dificulta escalar os resultados encontrados para outras partes da floresta. Além disso, apresenta alto custo de execução (Cabral *et al.*, 2023) e um elevado tempo necessário para realizar a coleta das informações da vegetação (Arıcak; Wing; Akay, 2023; Papa *et al.*, 2020; White *et al.*, 2016).

Esse desafio torna-se ainda mais crítico diante da crescente frequência e intensidade dos eventos climáticos, que afetam extensas áreas de floresta dentro de um curto intervalo de tempo (Colangelo *et al.*, 2021; Rosan *et al.*, 2024; Vacek; Vacek; Cukor, 2023). Assim, as campanhas tradicionais de inventário florestal podem não oferecer resposta espacial e temporal adequada para o monitoramento efetivo (Corte *et al.*, 2020; Kershaw Jr. *et al.*, 2017; White *et al.*, 2013).

Nesse cenário, o sensoriamento remoto tem se consolidado como ferramenta promissora para auxiliar e aprimorar o inventário florestal (Almeida *et al.*, 2019; Almeida *et al.*, 2020; Fisher, 2024; Lalechère *et al.*, 2024). Em particular, sensores hiperespectrais (HS) destacam-se por sua alta resolução espectral e permitem detectar características bioquímicas da vegetação (Almeida *et al.*, 2020; Ferreira *et al.*, 2020; Upadhyay; Kumar, 2018).

Essa capacidade possibilita identificar, caracterizar e modelar as características físicas dos ecossistemas (Kumar *et al.*, 2001; Debacker *et al.*, 2005). As imagens hiperespectrais (HSI) possibilitam a análise dos pigmentos fotossintéticos na região do visível (400–700 nm), da estrutura da parede celular no infravermelho próximo (700–1400 nm) e do conteúdo de água na folha na região do infravermelho de ondas curtas (1400–2700 nm) (Govender; Chetty; Bulcock, 2012; Harrison; Rivard; Sánchez-Azofeifa, 2018; Zarco-Tejada *et al.*, 2001).

Diversos estudos vêm demonstrando o potencial dos dados hiperespectrais para estimativas de biomassa em diferentes tipos de florestas tropicais (Almeida *et al.*, 2021; Almeida *et al.*, 2019; Aneece; Epstein; Lerda, 2017; Darko *et al.*, 2021; Ferreira *et al.*, 2016; Laporte-Fauret *et al.*, 2020; Merrick *et al.*, 2021; Miyoshi *et al.*, 2020). No entanto, o potencial dos dados hiperespectrais ainda foi pouco explorado em florestas tropicais secundárias brasileiras (Almeida *et al.*, 2019; Miyoshi *et al.*, 2020; Souza *et al.*, 2012; Garcia Millan; Sanchez-Azofeifa; Malvarez, 2015), em parte pela carência de dados gratuitos disponíveis no Brasil e pelo elevado custo operacional das plataformas de aquisição, na grande maioria das vezes, coletado por aeronave tripulada ou sensores orbitais.

Nesse contexto, o uso de HS embarcados em aeronave remotamente pilotada (RPA) representa uma alternativa viável, permitindo a aquisição de imagens de alta resolução espacial, com maior frequência temporal e cobertura de áreas específicas de interesse (Almeida *et al.*, 2021). Apesar dos avanços proporcionados pelos sistemas HS-RPA, ainda são escassos os estudos dedicados à investigação das florestas tropicais secundárias no Brasil.

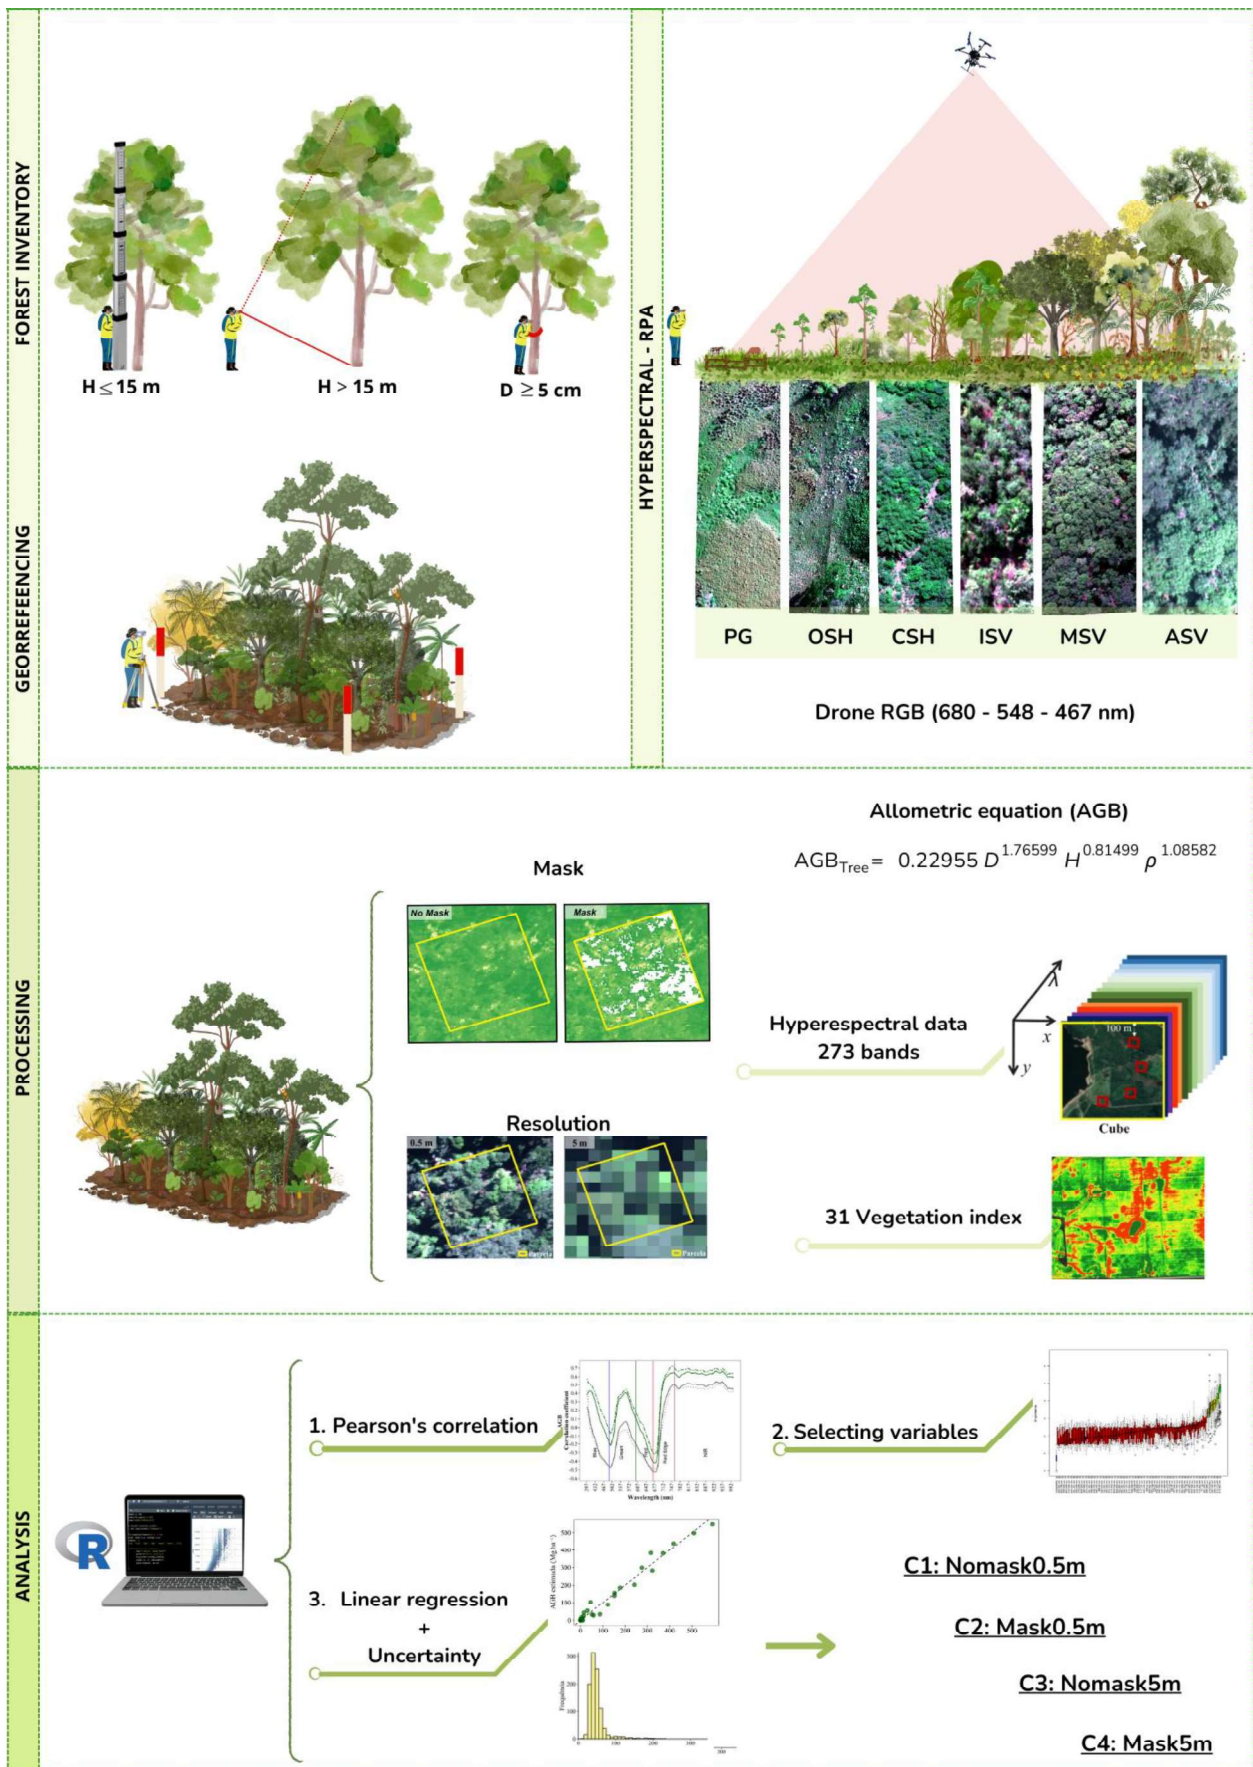
Dentre as exceções, destaca-se o estudo de Almeida *et al.* (2021), que monitoraram a estrutura, diversidade e biomassa em diferentes sistemas de restauração ativa no estado de São Paulo, e de Pinon *et al.* (2024), que analisaram a diversidade espectral de áreas em distintos estágios sucessionais na Mata Atlântica. Tais iniciativas evidenciam a necessidade de aprofundar os protocolos de coleta, processamento e análise de dados hiperespectrais para aprimorar a compreensão sobre as florestas ao longo da sucessão ecológica.

Este estudo parte da hipótese de que métricas espectrais derivadas de dados hiperespectrais obtidos por RPA apresentam forte correlação com a AGB, permitindo a estimativa ao longo de diferentes estágios sucessionais de florestas tropicais secundárias. Além disso, considera-se que a redução da resolução espacial compromete a precisão dessas estimativas e pressupõe-se que pixels sombreados afetam negativamente essa relação. Com isso, busca-se identificar os fatores que mais influenciam a modelagem da AGB, avaliando o impacto da resolução espacial e do sombreamento, a fim de contribuir para o aprimoramento de metodologias de estimativa da biomassa acima do solo em florestas secundárias tropicais.

2 MATERIAL E MÉTODOS

A descrição da área de estudo, do inventário florestal, da coleta e do processamento dos dados HS-RPA, assim como a metodologia da resolução espacial e dos pixels sombreados, está apresentada nos itens 2.1 a 2.5 do Capítulo I desta tese. O fluxograma metodológico das etapas necessárias para a realização do presente capítulo é apresentado na Figura 2.1.

Figura 2.1. Fluxograma das etapas metodológicas de inventário florestal, georreferenciamento, processamento e análise de dados.



Fonte: A autora.

2.1 Dados hiperespectrais

Foram utilizadas 273 bandas espectrais com largura de 2 nm cada (entre as faixas de 397 a 1002 nm) e resolução espacial de 0,11 m. Inicialmente, as imagens foram reamostradas para a resolução espacial de 0,50 m e 5 m, considerando a mediana para uma janela de 4 x 4 pixels, visando minimizar a relação sinal-ruído.

Adicionalmente, foram calculados 31 índices de vegetação (IVs), conforme o Apêndice B. Por fim, foram extraídos os valores medianos de reflectância (%) e dos IVs para cada uma das parcelas de inventário, totalizando 304 métricas hiperespectrais.

2.2 Estimativa de biomassa acima do solo e incerteza associada

Os valores de biomassa de cada árvore (AGB_{tree} , kg) foram estimados utilizando a equação alométrica ajustada por Silva (2020) para a fitofisionomia da Floresta Estacional Semidecidual localizada próximo a área de estudo (20°43'S e 41°13'W) (Tabela 2.1; Equação 2.1), baseada em medições de diâmetro à altura do peito (D), altura total (H) e densidade da madeira (ρ).

Para determinar a ρ , a identificação das espécies foi utilizada para obter os seus valores de ρ por meio do pacote R BIOMASS (Réjou-Méchain *et al.*, 2017). Quando informações em nível de espécie não estavam disponíveis, foram utilizadas médias de gênero ou família. Como referência, foi utilizado o banco de dados global de densidade de madeira de árvores (Chave *et al.*, 2009). Depois de estimada a biomassa individual de cada árvore, os valores foram somados e divididos pelo tamanho da área da parcela, obtendo os valores estimados de AGB por hectare ($Mg \cdot ha^{-1}$) (Tabela 2.1).

Tabela 2.1. Equações alométricas utilizadas para estimar AGB de cada árvore de floresta tropical secundária de Mata Atlântica.

Equações	N.	Fonte
Padrão		
$AGB_{Tree1} = 0,22955 D^{1,76599} H^{0,81499} \rho^{1,08582}$	(2.1)	Silva (2020)
Alternativas		
$AGB_{Tree2} = 21.297 + (-6.953D) + (0.74D^2)$	(2.2)	Tiepolo <i>et al.</i> (2002)
$AGB_{Tree3} = \exp [-0.37+0.333\log(D)+0.933\log(D)^2-0.122\log(D)^3]$	(2.3)	Chambers <i>et al.</i> (2001)
$AGB_{Tree4} = \exp[-3.1141+0.9719\log(D^2H)]$	(2.4)	Brown <i>et al.</i> (1989)
$AGB_{Tree5} = \rho \exp[-1.499+2.148\ln(D)+0.933\ln(D)^2-0.0281\ln(D)^3]$	(2.5)	Chave <i>et al.</i> (2005)

$$AGB_{Tree6} = \exp[-2.977 + \ln(\rho D^2 H)] \quad (2.6) \quad \text{Chave et al. (2005)}$$

$$AGB_{Tree7} = \exp[-2.19 + 2.54 \ln(D)] \quad (2.7) \quad \text{Chave et al. (2001)}$$

Legenda: AGB_{Tree} é a biomassa acima do solo (kg); D é o diâmetro à altura do peito (cm); H é a altura total (m); ρ é densidade da madeira (kg.cm^{-3}).

Neste estudo, as incertezas associadas à estimativa de AGB foram estimadas e propagadas para o modelo alométrico AGB_{Tree1} (Tabela 2.1) com base no trabalho desenvolvido por Gonçalves *et al.* (2017). Os erros (σ_D e σ_H) das estimativas de D e H são descritos em termos totais, sistemáticos e aleatórios. O erro total foi quantificado pelo *root mean square deviation* (RMDS - Equação 2.8), o erro sistemático pelo viés (Bias - Equação 9) e o erro aleatório pelo desvio padrão (SD - Equação 2.10) das diferenças das duas medições de D e H realizadas no inventário florestal (Capítulo I, seção 2.2).

$$RMDS = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i)^2}, \text{ com } e_i = (m1_i - m2_i) \quad (2.8)$$

$$Bias = \frac{1}{n} \sum_{i=1}^n e_i \quad (2.9)$$

$$SD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (e_i - mean)^2} \quad (2.10)$$

Onde “n” é o número de pares de medições repetidas para D e H ; $m1_i$ = a primeira medição de D ou H ; e $m2_i$ = a segunda medição de D ou H .

O desvio padrão dos valores de densidade da madeira foram obtidos pela literatura (Chave *et al.*, 2006). Expandindo a equação AGB_{Tree1} (Tabela 2.1, Equação 2.1) com a série de Taylor com seus termos em primeira ordem, os erros de mensuração do D (σ_D), H (σ_H) e ρ (σ_ρ) para a biomassa estimada foram propagados. As incertezas de estimativa de biomassa de cada árvore viva (σ_{AGB}) foram estimadas em termos dos erros de mensuração conforme equação 2.11 (Chave *et al.*, 2014).

$$\sigma_{AGB} = AGB_{tree} \left(4 \frac{\sigma_D^2}{D^2} + \frac{\sigma_H^2}{H^2} + \frac{\sigma_\rho^2}{\rho^2} + 4 \frac{\sigma_{DH}^2}{DH} \right) \quad (2.11)$$

Onde AGB_{tree} é a biomassa de cada árvore, DH é a covariância entre o diâmetro (D) e a altura (H) da árvore e ρ é a densidade da madeira.

As incertezas do modelo alométrico foram estimadas com base no resíduo do modelo (σ_A) e no erro de seleção de equações alométricas (σ_S). O σ_S foi estimado pelo SD dos valores de biomassa de cada árvore estimados pela equação original (AGB_{Tree1}) e pelas seis equações alternativas apresentadas na Tabela 2.1. O resíduo do modelo (σ_A) foi estimado de acordo com a equação 2.12 (Chave *et al.*, 2004; Chave *et al.*, 2014).

$$\sigma_A = \sqrt{CF^2 - 1AGB} \quad (2.12)$$

Onde $CF = \exp(\sigma^2/2)$, e σ é o desvio padrão do resíduo do modelo alométrico.

Os erros de σ_{AGB} , σ_S e σ_A , em hectare, foram estimados pelo somatório em quadratura dos mesmos erros obtidos em nível de árvore de cada parcela de inventário. Posteriormente, esses erros de cada parcela foram novamente somados em quadratura para calcular a incerteza total σ_{AGB} , considerando as premissas de aditividade e independência estatística (Gonçalves *et al.*, 2017).

2.3 Correlação

Foram conduzidas análises de correlação de Pearson entre AGB e os valores de reflectância em diferentes comprimentos de onda (397 – 1002 nm), considerando duas resoluções espaciais (0,5 m e 5 m) e dois cenários distintos: com e sem a aplicação de máscara para exclusão de pixels sombreados. O objetivo foi avaliar o impacto da resolução espacial e do sombreamento nos padrões espectrais observados.

Para cada parcela, foi calculada a mediana dos valores de reflectância, e a AGB foi analisada em escala linear. A correlação de Pearson foi aplicada para identificar relações entre os valores espectrais e a AGB, permitindo uma análise detalhada dos efeitos das variáveis testadas. Todas as análises estatísticas foram realizadas em ambiente R (R Core Team, 2023).

2.4 Modelagem da biomassa acima do solo

Inicialmente, o algoritmo Boruta foi aplicado às 273 bandas espectrais com o objetivo de reduzir o conjunto de variáveis preditoras para estimar a biomassa acima do solo. A seleção das variáveis foi realizada em ambiente R por meio do pacote Boruta (Kursa; Rudnicki, 2022). As variáveis espectrais selecionadas pelo Boruta, em conjunto com os 31

índices de vegetação (Apêndice B), foram submetidas a regressões lineares múltiplas utilizando o pacote Leaps (Lumley, 2024) em ambiente R.

Para a seleção das variáveis explicativas mais relevantes, foi adotado o método de busca exaustiva. A análise foi conduzida em quatro cenários distintos: (i) cenário 1 - com pixels sombreados e resolução de 0,5 m (*No mask_{0.5m}*); (ii) cenário 2 - sem pixels sombreados e resolução de 0,5 m (*Mask_{0.5m}*); (iii) cenário 3 - com pixels sombreados e resolução de 5 m (*No mask_{5m}*); e (iv) cenário 4 - sem pixels sombreados e resolução de 5 m (*mask_{5m}*). A seleção dos melhores subconjuntos de variáveis para cada cenário foi baseada nos valores do critério de informação bayesiano (BIC) e do coeficiente de determinação (R^2).

Para avaliar o desempenho dos modelos de regressão linear na estimativa da AGB, foi empregado o método bootstrapping. Essa abordagem estatística consiste na geração de múltiplas amostras aleatórias com reposição, permitindo estimar a estabilidade do modelo e reduzir a variabilidade das métricas de desempenho. Em cada iteração, 70% dos dados foram aleatoriamente selecionados para treinamento e os 30% restantes foram utilizados para validação. O modelo foi ajustado utilizando a amostra bootstrap e validado nos dados *out-of-bag* (OOB), que correspondem às observações não incluídas na amostragem. A estimativa de erro OOB foi utilizada para avaliar o desempenho preditivo do modelo. O bootstrapping é particularmente útil em conjuntos de dados pequenos, onde a validação cruzada pode não ser viável, como no presente estudo, que conta com apenas 30 observações.

O desempenho dos modelos foi avaliado por meio das seguintes métricas estatísticas: raiz do erro médio quadrático (*Root Mean Square Error* – RMSE), raiz do erro médio quadrático percentual (RMSE %), viés (Bias), viés percentual (Bias %) e coeficiente de determinação ajustado (R^2_{aj}). O erro de predição foi tomado como a média dos valores de RMSE obtidos nas 1000 repetições. Todas as análises estatísticas foram realizadas em ambiente R (R Core Team, 2023).

3 RESULTADOS

3.1 Biomassa acima do solo de campo

A AGB, estimada por meio de equação alométrica, variou entre $0,099 \text{ Mg}\cdot\text{ha}^{-1}$ e $591,598 \text{ Mg}\cdot\text{ha}^{-1}$, considerando todos os estágios de vegetação analisados (Tabela 2.2). Com o avanço da sucessão ecológica, verificou-se um aumento progressivo nos estoques

de biomassa, com médias de 55,549 Mg.ha⁻¹ no estágio inicial (ISV), 185,507 Mg.ha⁻¹ no estágio médio (MSV) e 410,919 Mg.ha⁻¹ no estágio avançado (ASV). Destaca-se que os estágios mais desenvolvidos (MSV e ASV) apresentaram maior variabilidade nos valores de AGB.

Tabela 2.2. Descrição da biomassa acima do solo (AGB) por estágio nas áreas de floresta tropical secundária de Mata Atlântica.

Estágio	AGB (Mg.ha ⁻¹)		
	Mínimo	Média	Máximo
Pasto sujo ralo (OSH – <i>Open Shrublands</i>)	0,099	13,243	51,708
Pasto sujo denso (CSH – <i>Closed Shrublands</i>)	3,042	10,592	15,579
Estágio inicial de vegetação secundária (ISV - <i>Initial Stage Secondary Vegetation</i>)	31,144	55,549	87,373
Estágio médio de vegetação secundária (MSV - <i>Medium Stage Secondary Vegetation</i>)	122,845	185,507	322,013
Estágio avançado de vegetação secundária (ASV - <i>Advanced Stage Secondary Vegetation</i>)	275,444	410,919	591,598

Fonte: A autora.

3.2 Análise do erro da AGB de campo

Os erros de medição no diâmetro à altura do peito (1,31%), altura (1,76%) e densidade da madeira (12,38%) contribuíram para um erro médio de 15,45% na estimativa de biomassa por árvore. No entanto, esse erro foi reduzido para 13,47% em média, quando a biomassa foi estimada no nível da parcela (σ_M) (Tabela 2.3).

O erro relacionado à seleção da equação alométrica variou de 0,98% a 4,61%, com uma média de 3,78%. O erro associado aos resíduos do modelo alométrico foi, em média, de 4,78%. A incerteza total nas estimativas de biomassa em nível de parcela variou de 4,66% a 39,22%, com uma média de 14,78%.

Tabela 2.3. Incertezas em estimativas de campo da biomassa acima do solo.

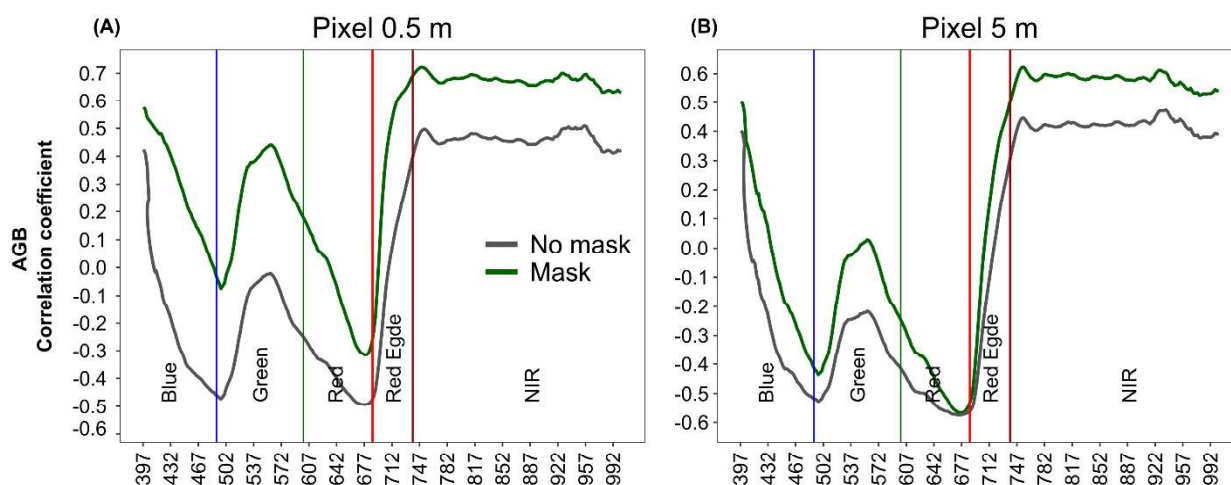
Fonte de erro	Erro (%)		
	Mínimo	Média	Máximo
Mensuração (σ_M)	4,30	13,47	38,63
Alometria (resíduos do modelo, σ_A)	1,51	4,78	4,96
Alometria (seleção de modelo, σ_S)	0,98	3,78	4,61
Total	4,66	14,78	39,22

Fonte: A autora.

3.3 Análise da correlação entre AGB e bandas espectrais

A correlação entre a AGB e as bandas espectrais foi influenciada por três fatores principais: a região espectral analisada, o tamanho do pixel e a aplicação da máscara de exclusão de pixels sombreados. Esses fatores contribuíram para variações na magnitude das correlações ao longo do espectro (Figura 2.2).

Figura 2.2. Coeficientes de correlação entre a biomassa acima do solo (AGB) e as reflectâncias espectrais, considerando diferentes tamanhos de pixel (0,5 m e 5 m). Linhas verdes indicam dados de pixels iluminados (*Mask*), enquanto linhas cinzas representam pixels sombreados (*No mask*).



Fonte: A autora.

Para a resolução de 0,5 m (Figura 2.2A), as maiores correlações foram observadas nas regiões do Red Edge e do NIR, independentemente da aplicação da máscara. Contudo, a utilização da máscara (linhas verdes) resultou em valores de correlação mais elevados em comparação ao cenário sem máscara (linhas cinzas).

Na resolução de 5 m (Figura 2.2B), os padrões de correlação entre AGB e as bandas espectrais seguiram tendências semelhantes às observadas para a resolução de 0,5 m, embora os valores de correlação tenham sido menores em todo o espectro. As regiões do Red Edge e do NIR mantiveram as correlações mais elevadas, enquanto as correlações mais baixas foram observadas nas regiões do azul e do verde do espectro visível.

De modo geral, as maiores correlações positivas foram observadas nas bandas do Red Edge e do NIR (r variando entre 0,6 e 0,72). Em contraste, as regiões do espectro visível, particularmente nas bandas do verde e do vermelho, apresentaram correlações mais fracas, especialmente nos cenários sem aplicação da máscara de exclusão de pixels sombreados (linhas cinzas). A utilização da máscara (linhas verdes) melhorou a força das correlações em todas as regiões espectrais (Figura 2.2). Tanto a resolução espacial quanto

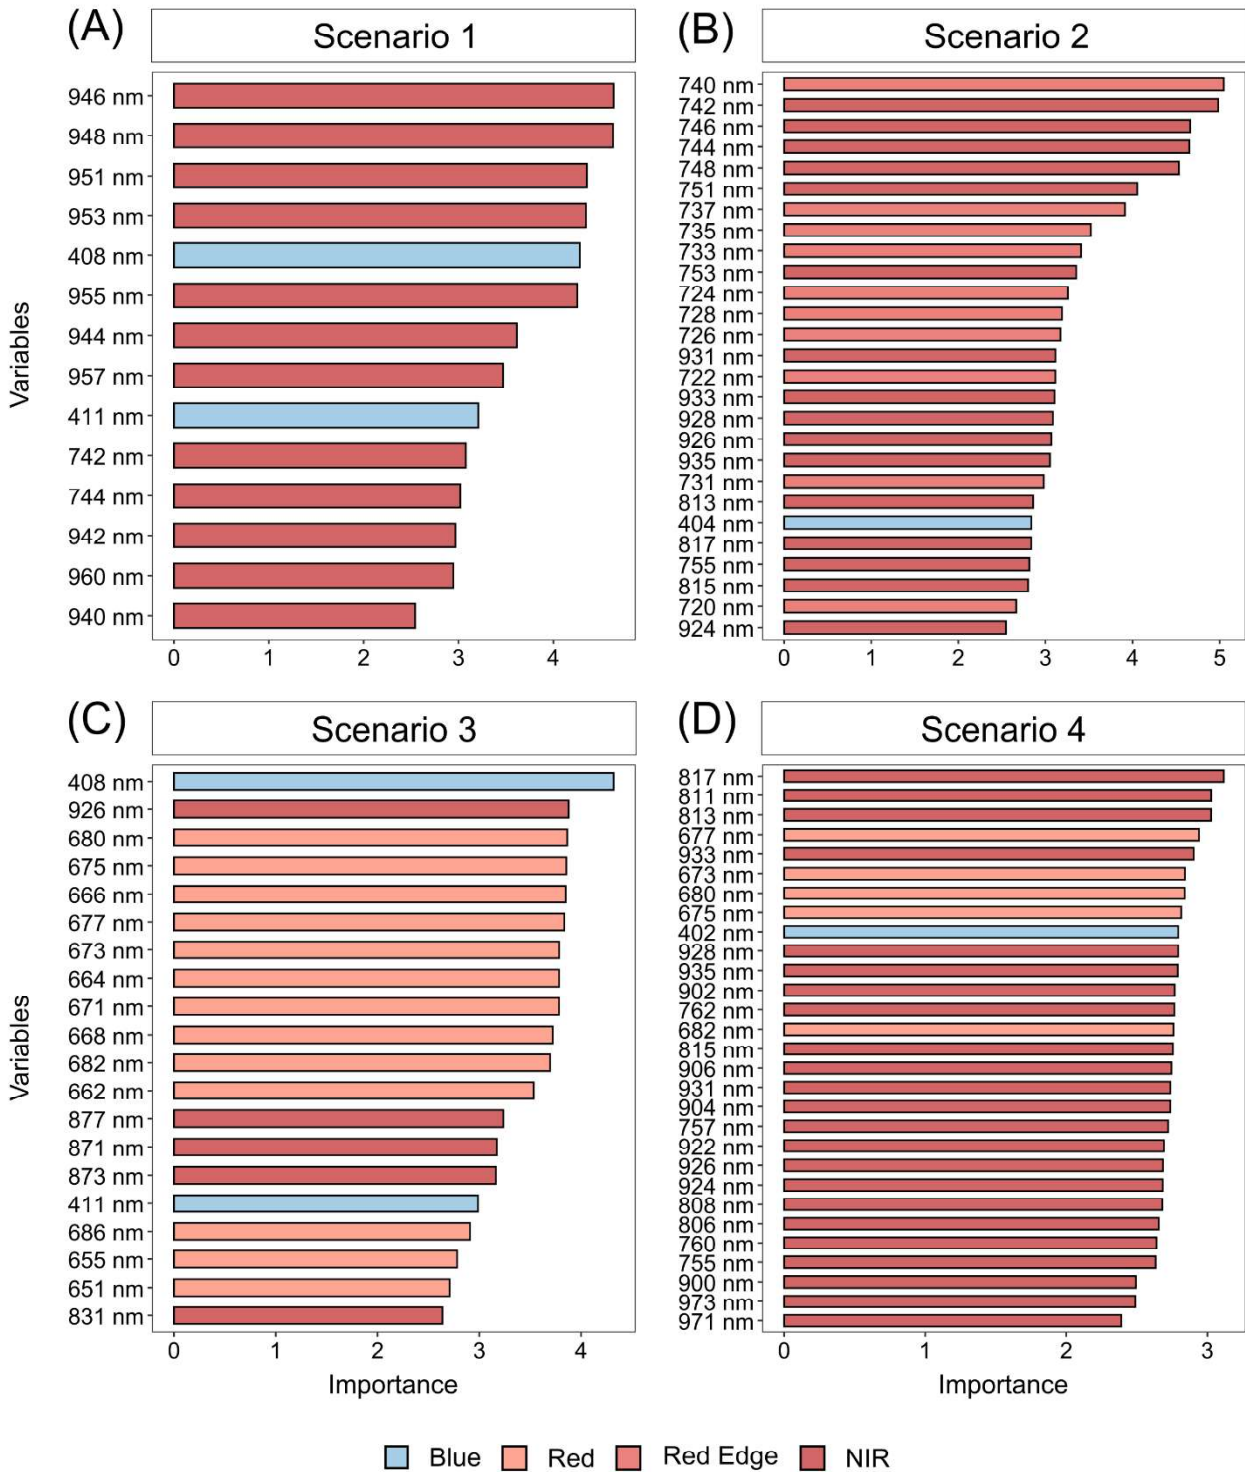
às condições de iluminação demonstrou influenciar diretamente a relação entre as características espectrais e a AGB.

3.4 Seleção de métricas espectrais

De modo geral, observou-se a predominância de bandas espectrais localizadas nas regiões do Red Edge e do NIR entre as variáveis mais relevantes para a modelagem da AGB (Figura 2.3). Embora tenham sido verificadas variações associadas à resolução espacial e ao uso da máscara para remoção de pixels sombreados, a priorização dessas faixas espectrais manteve-se consistente entre os diferentes cenários.

No Cenário 1 (*No mask_{0.5m}*), destacaram-se bandas do NIR e Red Edge, além de comprimentos de onda no azul, como 408 nm e 411 nm (Figura 2.3A). No Cenário 2 (*Mask_{0.5m}*), observou-se um padrão distinto, com maior concentração de bandas relevantes entre 724 nm e 753 nm, todas pertencentes à região do Red Edge (Figura 2.3B). O Cenário 3 (*No mask_{5m}*) apresentou maior dispersão entre as bandas selecionadas, abrangendo desde o visível (azul e vermelho) até o NIR (Figura 2.3C). Por sua vez, o Cenário 4 (*Mask_{5m}*) mostrou concentração mais clara de bandas no NIR (Figura 2.3D).

Figura 2.3. Importância das variáveis espectrais selecionadas pelo algoritmo Boruta nos quatro cenários. (A) Cenário 1 - com pixels sombreados e resolução de 0,5 m (*No mask_{0.5m}*); (B) Cenário 2 - sem pixels sombreados e resolução de 0,5 m (*Mask_{0.5m}*); (C) Cenário 3 - com pixels sombreados e resolução de 5 m (*No mask_{5m}*); (D) Cenário 4 - sem pixels sombreados e resolução de 5 m (*Mask_{5m}*).



Fonte: A autora.

3.5 Modelagem de AGB

Os modelos ajustados para a estimativa da AGB apresentaram variações na composição das variáveis espectrais em função dos diferentes cenários analisados (Tabela 2.4). De modo geral, observou-se a predominância de índices de vegetação entre as variáveis selecionadas, com destaque para o RVSI, incluído em três dos quatro cenários (C1, C3 e C4). O índice PRI também se mostrou relevante, sendo incorporado nos modelos dos cenários C2 e C3. Complementarmente, bandas espectrais específicas foram selecionadas, em especial aquelas situadas nas regiões do azul e do NIR, como B402, B404 e B753.

Tabela 2.4. Modelos selecionados para estimar a biomassa acima do solo (AGB) nos quatro cenários analisados utilizando dados hiperespectrais.

Cenário	Modelos
1	AGB = -154,34 + 1365,57 SL + 13795,49 RVSI – 5697,51 CARI
2	AGB = 284,5 + 5573,07 PRI - 15878,82 B404 + 4147,50 B753
3	AGB = -77,007 + 1322,144 PRI + 12854,192 RVSI + 49,644 PSSR2
4	AGB = -80,124 + 9975,142 RVSI + 65,612 PSSR2 - 3482,368 B402

Todos os coeficientes significativos ao nível de 5%. Legenda: SL = Slope of red-edge; RVSI = Red-edge Vegetation Stress Index; CARI = Chlorophyll Absorption in Reflectance Index; PRI = Photochemical Reflectance Index; B404 = 404 nm; B753 = 753 nm; PSSR2= Pigment Specific Simple Ratio 2; B402 = 402 nm.

Os modelos ajustados apresentaram desempenho variável entre os cenários, refletindo os efeitos combinados da resolução espacial e da aplicação da máscara para remoção de sombras na modelagem da AGB (Tabela 2.5, Figura 2.4).

Tabela 2.5. Estatísticas resumidas dos modelos selecionados para estimar a biomassa acima do solo (AGB) nos quatro cenários analisados utilizando dados hiperespectrais.

Cenário	Treino			Validação		
	R ² aj	RMSE	Bias	R ² aj	RMSE	Bias
1	0,77	73,69 (44,56%)	0 (0%)	0,73	93,68 (56,64%)	3,71 (-2,31%)
2	0,76	67,84 (41,02%)	0 (0%)	0,71	94,18 (56,95%)	15,06 (6,40%)
3	0,76	64,31 (38,88%)	0 (0%)	0,78	83,53 (50,50%)	5,08 (-0,26%)
4	0,70	81,70 (49,40%)	0 (0%)	0,66	107,76 (65,15)	5,82 (-1,76%)

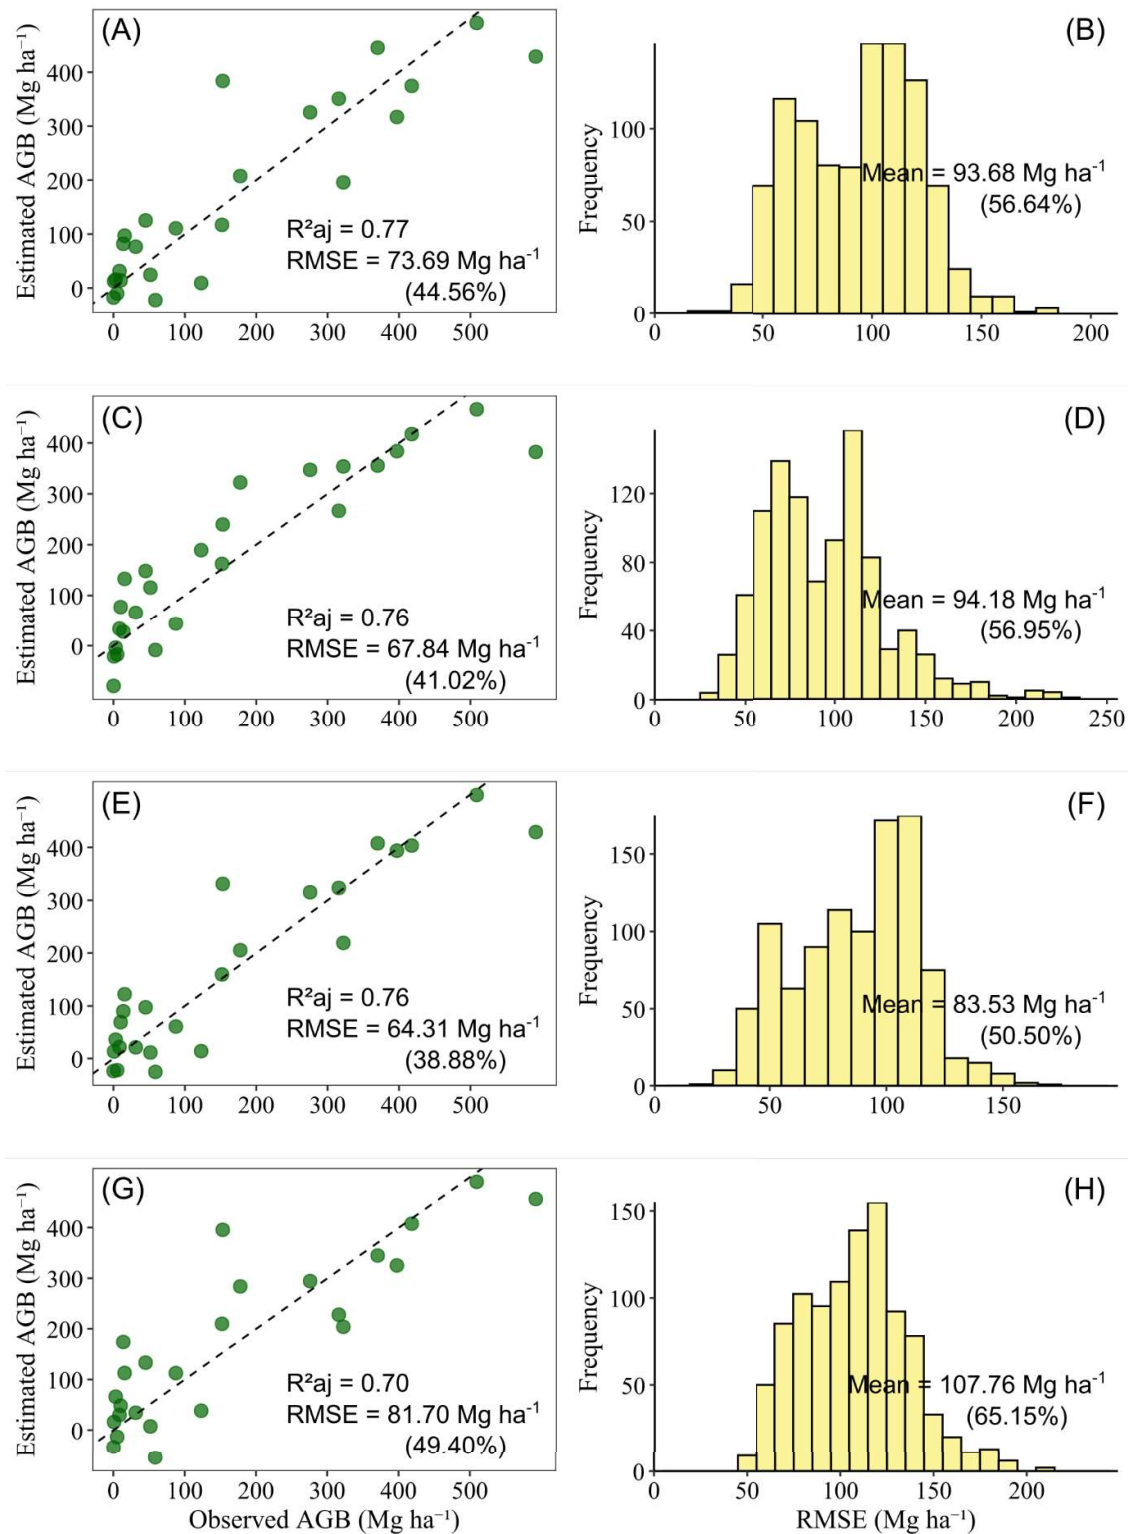
R²aj = coeficiente de determinação ajustado; RMSE = erro quadrático médio (Mg ha⁻¹); Bias = viés.

O melhor resultado foi obtido no cenário 3 (*No mask_{5m}*), que apresentou o menor RMSE na validação (83,53 Mg ha⁻¹; 50,50%), o maior R²aj (0,78) e viés praticamente nulo

(-0,26%), destacando boa capacidade preditiva mesmo sob menor resolução espacial e com pixels sombreados.

Nos cenários com resolução de 0,5 m, o cenário 1 (*No mask_{0.5m}*) apresentou desempenho superior ao cenário 2 (*Mask_{0.5m}*), com menor erro de predição (56,64% vs. 56,95%) e viés mais próximo de zero (-2,31% vs. 6,40%). Padrão semelhante foi observado na resolução de 5 m, em que o cenário 3 (*No mask_{5m}*) também superou o cenário 4 (*Mask_{5m}*) em todos os indicadores avaliados. Embora a aplicação da máscara influencie a seleção das variáveis espectrais, não resultou em melhoria no desempenho preditivo dos modelos, independentemente da resolução espacial considerada.

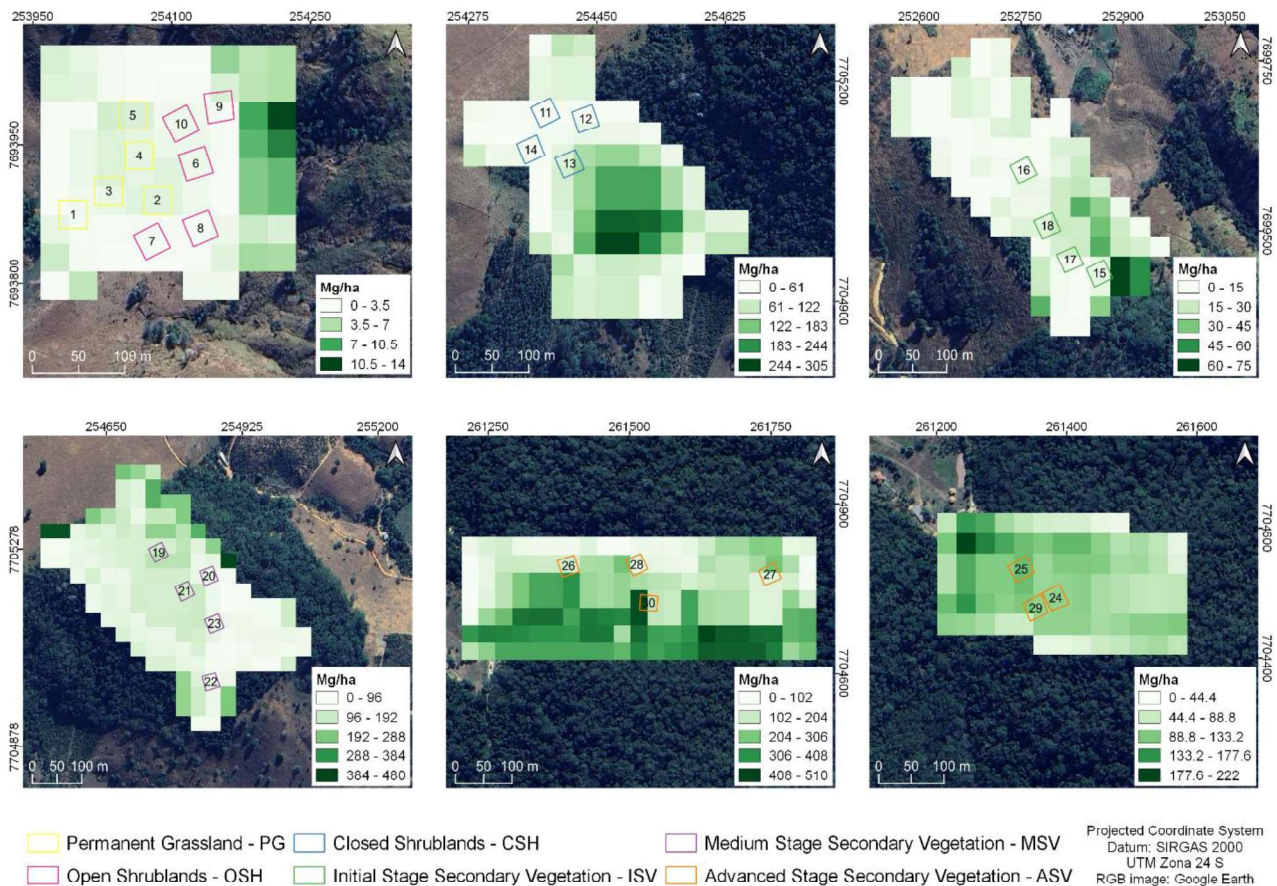
Figura 2.4. Valores estimados da biomassa acima do solo de campo versus valores previstos por métricas hiperespectrais. (A, B) Cenário 1 - com pixels sombreados e resolução de 0,5 m (*No mask_{0.5m}*); (C, D) Cenário 2 - sem pixels sombreados e resolução de 0,5 m (*Mask_{0.5m}*); (E, F) Cenário 3 - com pixels sombreados e resolução de 5 m (*No mask_{5m}*); (G, H) Cenário 4 - sem pixels sombreados e resolução de 5 m (*Mask_{5m}*). Os histogramas mostram a distribuição dos valores de RMSE obtidos nas 1000 repetições no procedimento de validação cruzada.



Fonte: A autora.

Diante do melhor desempenho obtido, o modelo do cenário 3 (*No mask_{5m}*) foi utilizado para a geração do mapa de AGB nas áreas de estudo (Figura 2.5). A aplicação desse modelo possibilitou representar a distribuição espacial da biomassa com maior precisão entre os cenários avaliados (Figura 2.5).

Figura 2.5. Espacialização do melhor modelo de previsão de biomassa acima do solo utilizando dados hiperespectrais.



Fonte: A autora.

4 DISCUSSÃO

4.1 Análise do erro da AGB de campo

A estimativa de AGB está sujeita a erros que afetam sua precisão, incluindo incertezas na medição de diâmetro, altura e densidade da madeira, além da escolha da equação alométrica e dos resíduos do modelo (Li *et al.*, 2022; Saarela *et al.*, 2020). Avaliar e quantificar essas incertezas é essencial para garantir estimativas de biomassa mais confiáveis (Gonçalves *et al.*, 2017).

Neste estudo, os erros nas medições resultaram em uma incerteza média de 15,45% na biomassa por árvore, reduzida para 13,47% ao nível de parcela, sugerindo que a

agregação de dados minimiza variações individuais. Almeida *et al.* (2020) encontraram uma redução ainda mais expressiva, de 50% para 6,7%, o que pode estar relacionado à estrutura da floresta. Estudos anteriores, como o de Fararoda *et al.* (2024), também identificaram redução da incerteza com a passagem da escala individual para a de parcela, reforçando que a calibração de equações para contextos específicos é um fator determinante na precisão das estimativas.

A incerteza total da biomassa neste estudo (14,78%) e os resíduos do modelo (4,78%) foram inferiores aos valores reportados por Gonçalves *et al.* (2017), sendo 25% e 7,5%, respectivamente. Essas diferenças podem resultar da estrutura florestal analisada, da densidade amostral ou da abordagem metodológica adotada. Dessa forma, as incertezas na estimativa de biomassa não são fixas, mas influenciadas por múltiplos fatores. Identificar suas fontes, modelar sua propagação e quantificar seu impacto são etapas fundamentais para aprimorar a confiabilidade dos resultados (Lu *et al.*, 2012). Quando as incertezas do modelo e da estimativa de biomassa não são consideradas, ocorre uma subestimação da incerteza total, levando a decisões não-assertivas sobre o manejo florestal (Silva *et al.*, 2023).

4.2 Análise da correlação entre AGB e bandas espectrais

O efeito dos pixels sombreados reduziu os valores de correlação entre as bandas espectrais e a AGB (Figura 2.2). Essa redução reflete a influência das áreas sombreadas na relação espectral, indicando que as sombras comprometeram a captura das propriedades biofísicas da vegetação.

A exclusão de pixels sombreados (*Mask*) foi uma estratégia eficaz para aprimorar essas correlações, ao minimizar os efeitos das sombras e permitir que os dados espectrais representassem com maior precisão as características estruturais e biofísicas da vegetação. Esse efeito está alinhado com a variabilidade da iluminação natural em campo, que depende das condições climáticas. A presença de sombras, como apontado por Suh, Hofstee e Van Henten (2018) e Cui *et al.* (2023), pode intensificar o contraste, gerando variações expressivas dentro de uma mesma cena, o que reforça a importância de estratégias para mitigar esse impacto na análise espectral.

A resolução espacial desempenhou um papel importante na correlação entre as bandas espectrais e a AGB, influenciando a sensibilidade das bandas às variações estruturais da vegetação. Resoluções mais finas possibilitam a captação de detalhes

espaciais mais sutis, aprimorando a detecção de padrões espectrais relacionados à biomassa.

Em contrapartida, a diminuição da resolução espacial reduz a capacidade de diferenciar elementos estruturais da vegetação, resultando na perda de informações espectrais associadas à AGB. Essa limitação impacta diretamente as correlações espectrais, pois a mistura de alvos dentro de um mesmo pixel suaviza as variações espectrais, dificultando a distinção de gradientes de biomassa.

As maiores correlações com a AGB foram observadas nas bandas Red Edge e NIR (Figura 2.2), destacando a importância dessas faixas espectrais na caracterização da biomassa. Esse resultado está alinhado com o estudo de Almeida *et al.* (2019), que identificaram o NIR e o SWIR como as regiões espectrais mais sensíveis às variações de biomassa na Amazônia brasileira. De forma semelhante, Jacon *et al.* (2021) observaram que as bandas mais correlacionadas com a biomassa florestal no Cerrado estavam distribuídas no espectro visível (681, 671 e 660 nm), Red Edge (691 e 701 nm), NIR (884 nm) e SWIR (1568 e 2113 nm).

No contexto da Mata Atlântica, Barbosa *et al.* (2014), ao utilizarem imagens do satélite Landsat, verificaram que as bandas do infravermelho médio (1,55 - 1,75 μm) apresentaram as melhores correlações com a biomassa acima do solo. Embora o referido estudo tenha sido conduzido no mesmo bioma analisado nesta pesquisa, a principal divergência metodológica está relacionada à faixa espectral dos dados utilizados. Neste trabalho, o sensor hiperespectral embarcado em RPA não contempla a região do infravermelho de ondas curtas (SWIR), diferentemente dos sensores orbitais empregados no estudo comparado.

Apesar dessas diferenças metodológicas, os padrões observados foram similares, sugerindo que, independentemente da plataforma de aquisição dos dados, a resposta espectral da vegetação segue uma tendência consistente na caracterização da biomassa em diferentes ecossistemas. Essa tendência é reforçada pelo estudo de Almeida *et al.* (2021), que investigaram florestas tropicais restauradas na Mata Atlântica utilizando um sensor hiperespectral acoplado em RPA. Nesse estudo, os autores verificaram que o RVSI, um índice baseado em bandas situadas no final da borda vermelha (>730 nm), foi o mais sensível às variações de AGB.

4.3 Modelagem de AGB

A precisão dos modelos na estimativa de AGB variou entre os cenários analisados, destacando a influência da resolução espacial na modelagem. O melhor desempenho foi observado no cenário com resolução de 5 m e sem aplicação da máscara de sombras. Embora a literatura aponte tendência de queda na precisão com a redução da resolução espacial (Yu *et al.*, 2022), os dados utilizados neste estudo já se encontram em faixas consideradas de alta resolução (0,5 m e 5 m), o que pode ter reduzido o impacto desse fator. Além disso, é possível que a resolução mais fina (0,5 m) tenha contribuído para o aumento do ruído espectral. Assim, a resolução de 5 m pode ter favorecido maior estabilidade espectral ao suavizar heterogeneidades locais, resultando em modelos ligeiramente mais robustos.

A influência da escala na modelagem de AGB precisa ser considerada com cautela, especialmente em florestas secundárias tropicais, onde a complexidade estrutural pode intensificar as dificuldades associadas à seleção da resolução espacial mais adequada para estimativas espectrais. É importante desenvolver e validar modelos que identifiquem a escala em que um fenômeno ocorre, uma vez que os efeitos de escala restringem a precisão da recuperação e limitam as aplicações de sensoriamento remoto (Wu; Li, 2009).

De modo geral, considerando a complexidade da estimativa de biomassa em florestas tropicais secundárias e as incertezas associadas ao processo, os modelos desenvolvidos no cenário 1 (resolução espacial de 0,5 m com sombra), cenário 2 (resolução espacial de 0,5 m sem sombra) e cenário 3 (resolução espacial de 5 m com sombra) apresentaram bom desempenho na predição de AGB.

Estudos anteriores também relataram resultados promissores na estimativa de biomassa utilizando dados hiperespectrais. Jacon *et al.* (2022) estimaram a AGB do Cerrado a partir de imagens do sensor Hyperion combinadas com técnicas de aprendizado de máquina, obtendo um RMSE de 28% no melhor modelo. Almeida *et al.* (2019) utilizaram dados hiperespectrais adquiridos por aeronave pilotada para estimar a biomassa na Amazônia, alcançando R^2 de 58% e RMSE de 68,1 Mg.ha⁻¹ (36%). De forma semelhante, Almeida *et al.* (2020) avaliaram a biomassa em florestas tropicais restauradas na Mata Atlântica com um sensor hiperespectral embarcado em RPA, obtendo um R^2 de 75% e um RMSE de 10,1%.

A precisão da estimativa de AGB é afetada pelo tipo de sensor, método de seleção de variáveis e ajuste do modelo (Fassnacht *et al.*, 2014). Embora alguns estudos tenham relatado bons resultados utilizando dados hiperespectrais (Jacon *et al.*, 2022; Almeida *et*

al., 2019; Almeida *et al.*, 2020), outros estudos obtiveram desempenhos de modelo relativamente baixos (Laurin *et al.*, 2014; Clark *et al.*, 2011; Latifi; Fassnacht; Koch, 2012).

Comumente, o Índice de Vegetação por Diferença Normalizada (NDVI) é utilizado em estudos de sensoriamento remoto óptico para estimar biomassa acima do solo (Ali *et al.*, 2023; Breunig *et al.*, 2024; Costa *et al.*, 2023; Lourenço *et al.*, 2021; Laurin *et al.*, 2014). Contudo, conforme Franceschini *et al.* (2017) e Vescovo *et al.* (2011), o NDVI apresenta limitações em áreas de alta densidade de vegetação, onde tende a saturar, não refletindo de forma proporcional o aumento na AGB (Liu *et al.*, 2024). No presente estudo, o NDVI apresentou sinais de saturação em valores de aproximadamente 150 Mg ha⁻¹, enquanto a AGB observada em campo alcançou até 591 Mg ha⁻¹, indicando sua limitação para estimar biomassa em níveis mais elevados.

Em contraste, os demais índices que estiveram presentes nos modelos, mantiveram relação mais contínua com a AGB ao longo de todo o gradiente observado. Esse comportamento reforça uma das principais vantagens do sensoriamento hiperespectral em relação ao multiespectral: a capacidade de capturar variações biofísicas sutis da vegetação, mesmo em áreas com maior acúmulo de biomassa, reduzindo o efeito de saturação frequentemente associado a índices tradicionais como o NDVI (Im; Jensen, 2008).

Os modelos de AGB apresentaram predominância de índices de vegetação, embora algumas bandas localizadas nas regiões do azul e do NIR também tenham sido selecionadas. Os índices escolhidos incluem combinações de bandas do visível (PRI), visível e Red Edge (CARI), visível e NIR (PSSR2) e exclusivamente do Red Edge (RVSI e SL). Conforme apontado por Munyati (2022), além das bandas do NIR e da região vermelha, índices de vegetação que utilizam a borda vermelha apresentam elevado potencial para a estimativa de AGB.

A região do Red Edge é amplamente reconhecida por sua sensibilidade ao conteúdo de clorofila e à biomassa do dossel (Filella; Peñuelas, 1994). Ferreira *et al.* (2024) também ressaltam a relevância de bandas espectrais específicas para a estimativa de AGB, destacando especialmente aquelas situadas próximas ao pico verde (~550 nm) e à borda do vermelho (700–750 nm). Bandas localizadas nas regiões do vermelho e do infravermelho próximo têm se mostrado particularmente eficazes para detectar mudanças na estrutura da vegetação e no seu vigor, devido à sua alta sensibilidade a parâmetros como o conteúdo de clorofila, densidade do dossel (Wang *et al.*, 2024) e área foliar, os quais estão diretamente relacionados à biomassa florestal (Zurqani, 2025).

No contexto do sensoriamento hiperespectral, essa sensibilidade é potencializada pela maior resolução espectral, que permite captar variações sutis nesses atributos

biofísicos ao longo de faixas contínuas do espectro (Im; Jensen, 2008). Essa capacidade é especialmente relevante para a modelagem da biomassa, pois possibilita distinguir diferentes níveis de acúmulo de matéria vegetal mesmo em estágios avançados de sucessão, reduzindo efeitos de saturação comuns em sensores multiespectrais (Mutanga; Masenyama; Sibanda, 2023; Verma; Sharma; Lele, 2023). Os índices de vegetação aprimorados, derivados das bandas Red Edge e NIR, apresentam forte correlação com a AGB (Zhang *et al.*, 2024), refletindo a sensibilidade dessas bandas à variação na biomassa (Chen *et al.*, 2021). Nos modelos obtidos neste estudo, a contribuição dessas regiões espectrais foi evidente, com bandas e índices derivados do vermelho, Red Edge e NIR figurando entre as variáveis mais relevantes para a estimativa da AGB.

O RVSI (Índice de Estresse da Vegetação de Borda Vermelha) foi um dos preditores da AGB no presente estudo, sendo selecionado em três dos quatro cenários analisados. Esse desempenho pode estar relacionado à forte correlação positiva entre a região do Red Edge (680–750 nm), o conteúdo de clorofila e o índice de área foliar do dossel (Filella; Peñuelas, 1994). Esses atributos estão diretamente relacionados à estrutura e ao acúmulo de biomassa, o que justifica a relevância do RVSI na modelagem da AGB com dados hiperespectrais. De acordo com Almeida *et al.* (2021), como o RVSI usa bandas próximas do fim da borda vermelha (>730 nm), ele pode ser sensível a variações de AGB induzidas pelo índice de área foliar e conteúdo de clorofila.

No presente estudo, apesar do uso de dados hiperespectrais com elevada resolução espectral e espacial, os erros de predição mantiveram-se elevados, com RMSE variando entre 50% e 56% nos diferentes cenários. Tal desempenho destaca as limitações dos modelos lineares em representar adequadamente a variabilidade espectral associada à AGB. Considerando a complexidade dessas relações, abordagens não lineares possivelmente apresentam desempenho superior, embora essa hipótese ainda necessite de validação em estudos futuros. Segundo Fassnacht *et al.* (2014), modelos de regressão linear frequentemente apresentaram desempenho inferior em comparação com outros métodos, especialmente ao utilizar dados hiperespectrais. Isso ocorre porque as relações entre preditores hiperespectrais e a biomassa acima do solo tendem a ser não-lineares, dificultando a representação adequada por modelos lineares tradicionais.

A AGB prevista não foi avaliada para os estágios sucessionais individualmente, pois o tamanho da amostra era muito pequeno para atingir resultados significativos. Embora este estudo tenha apresentado resultados comparáveis a outros trabalhos que utilizaram dados hiperespectrais para estimar AGB em diferentes tipos de florestas, um diferencial importante foi a consideração das incertezas inerentes à análise dos dados. O erro na

estimativa de AGB de campo, derivado da equação alométrica, foi propagado para a modelagem baseada em métricas hiperespectrais. No entanto, ainda é fundamental avaliar outras fontes de incerteza, como o tamanho e o formato das parcelas amostrais, que podem influenciar a representatividade dos dados. Além disso, o método de validação adotado e o número reduzido de observações ($n = 30$) podem ter impactado o desempenho dos modelos, sendo aspectos que devem ser considerados em estudos futuros.

5 CONCLUSÕES

Os resultados deste estudo reforçam o potencial do sensoriamento remoto hiperespectral de alta resolução na estimação de biomassa acima do solo em florestas tropicais secundárias da Mata Atlântica. A correlação entre AGB e as bandas espectrais foi mais forte nas faixas Red Edge e NIR. Essas bandas apresentaram maior sensibilidade às variações na biomassa, demonstrando que a modificação no sinal espectral está associada ao aumento da complexidade estrutural ao longo da sucessão florestal.

As variáveis espectrais mostraram correlação expressiva com a AGB, com destaque para os índices baseados em bandas da região do Red Edge, selecionados com frequência nos modelos ajustados. No entanto, observou-se que a maior parte dessas bandas está localizada em faixas espectrais também disponíveis em sensores multiespectrais.

A resolução espacial e a presença de sombras influenciaram o desempenho dos modelos de estimativa da AGB, embora de forma distinta do esperado. Os melhores resultados foram obtidos nos cenários com presença de pixels sombreados, tanto para a resolução de 5 m quanto para 0,5 m, indicando que a remoção desses pixels não resultou em ganhos de precisão. Além disso, o modelo mais preciso foi gerado com resolução de 5 m, sugerindo que, em determinados contextos, resoluções ligeiramente mais baixas podem contribuir para maior estabilidade espectral ao suavizar variações estruturais do dossel.

Os resultados obtidos fornecem subsídios relevantes para o desenvolvimento de metodologias mais precisas voltadas à estimativa de biomassa, contribuindo para o aprimoramento de estratégias de monitoramento florestal. Como perspectivas futuras, destaca-se a integração de dados hiperespectrais com informações LiDAR, visando refinar a caracterização estrutural da vegetação e aumentar a precisão das estimativas. Além disso, recomenda-se a avaliação de diferentes algoritmos de seleção de variáveis e a aplicação de técnicas de aprendizado de máquina como alternativas promissoras para melhorar o desempenho preditivo dos modelos.

6 REFERÊNCIAS

- AIDE, T. M. *et al.* Deforestation and reforestation of Latin America and the Caribbean (2001–2010). **Biotropica**, v. 45, n. 2, p. 262–271, 3 ago. 2013.
- ALI, N. *et al.* Assessment of aboveground biomass and carbon stock of subtropical pine forest of Pakistan. **Journal of Forest Science**, v. 69, n. 7, p. 287–304, 26 jul. 2023.
- ALMEIDA, A. *et al.* Estimating structure and biomass of a secondary Atlantic Forest in Brazil using Fourier transforms of vertical profiles derived from UAV photogrammetry point clouds. **Remote Sensing**, v. 12, n. 21, p. 3560, 30 out. 2020.
- ALMEIDA, C. T. de *et al.* Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, p. 111323, out. 2019.
- ALMEIDA, D. R. A. *et al.* Detecting successional changes in tropical forest structure using GatorEye drone-borne lidar. **Biotropica**, v. 52, n. 6, p. 1155–1167, 30 jul. 2020.
- ALMEIDA, D. R. A. *et al.* Monitoring the structure of forest restoration plantations with a drone-lidar system. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, p. 192–198, jul. 2019.
- ANEECE, I. P.; EPSTEIN, H.; LERDAU, M. Correlating species and spectral diversities using hyperspectral remote sensing in early-successional fields. **Ecology and Evolution**, v. 7, n. 10, p. 3475–3488, 6 abr. 2017.
- ARICAK, B.; WING, M. G.; AKAY, A. E. **Estado da arte em aplicações de LiDAR aerotransportado no campo da engenharia florestal**. In: SURATMAN, M. N. (Org.). *Conceitos e aplicações de sensoriamento remoto em silvicultura*. Cingapura: Springer, 2022. p. 357-369.
- ARYAL, D. R. *et al.* Biomass recovery along a tropical forest succession: Trends on tree diversity, wood traits and stand structure. **Forest Ecology and Management**, v. 555, p. 121709, mar. 2024.
- BREUNIG, F. M. *et al.* Monitoring cover crop biomass in southern Brazil using combined PlanetScope and Sentinel-1 SAR data. **Remote Sensing**, v. 16, n. 15, p. 2686, 23 jul. 2024.
- BROWN, S.; GILLESPIE, A. JR; LUGO, A. E. Biomass estimation methods for tropical forests with applications to forest inventory data. **Forest Science**, v. 35, n. 4, p. 881-902, 1989.
- BUTHELEZI, S. *et al.* Assessing the prospects of remote sensing maize leaf area index using UAV-derived multi-spectral data in smallholder farms across the growing season. **Remote Sensing**, v. 15, n. 6, p. 1597, 15 mar. 2023.
- CABRAL, R. P. *et al.* Mapping of the successional stage of a secondary forest using point clouds derived from UAV photogrammetry. **Remote Sensing**, v. 15, n. 2, p. 509, 14 jan. 2023.

CHAMBERS, J. Q. *et al.* Tree damage, allometric relationships, and above-ground net primary production in central Amazon forest. **Forest Ecology and Management**, v. 152, n. 1-3, p. 73-84, 2001.

CHAVE, J. *et al.* Error propagation and scaling for tropical forest biomass estimates. Philosophical Transactions of the Royal Society of London. Series B: **Biological Sciences**, v. 359, n. 1443, p. 409–420, 29 mar. 2004.

CHAVE, J. *et al.* Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 21 jun. 2014.

CHAVE, J.; ANDALO, C.; BROWN, S. *et al.* Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, p. 87–99, 2005.

CHAVE, J.; *et al.* Regional and phylogenetic variation of wood density across 2456 neotropical tree species. **Ecological Applications**, v. 16, n. 6, p. 2356-2367, 2006.

CHAVE, J.; RIÉRA, B.; DUBOIS, M.-A. Estimation of biomass in a neotropical forest of French Guiana: spatial and temporal variability. **Journal of Tropical Ecology**, v. 17, n. 1, p. 79-96, 2001.

CHAVE, Jerome *et al.* Towards a worldwide wood economics spectrum. **Ecology Letters**, v. 12, n. 4, p. 351–366, 10 mar. 2009.

CHAZDON, R. L. *et al.* The potential for species conservation in tropical secondary forests. **Conservation Biology**, v. 23, n. 6, p. 1406–1417, 24 nov. 2009.

CHEN, S. *et al.* Nondestructive Estimation of the Above-Ground Biomass of Multiple Tree Species in Boreal Forests of China Using Terrestrial Laser Scanning. **Forests**, v. 10, n. 11, p. 936, 2019.

CHEN, Y. *et al.* Mapping maize area in heterogeneous agricultural landscapes with multi-temporal Sentinel-1 and Sentinel-2 images based on random forest. **Remote Sensing**, v. 13, n. 15, p. 2988, 29 jul. 2021.

CLARK, M. L. *et al.* Estimation of tropical rainforest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931–2942, nov. 2011.

CLARK, D. B.; KELLNER, J. R. Tropical Forest biomass estimation and the fallacy of misplaced concreteness. **Journal of Vegetation Science**, v. 23, n. 6, p. 1191-1196, 2012.

COLANGELO, M. *et al.* Mediterranean old-growth forests exhibit resistance to climate warming. **Science of The Total Environment**, v. 801, p. 149684, dez. 2021.

CORTE, A. P. D. *et al.* Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, p. 105815, dez. 2020.

COSTA, A. C. da *et al.* Artificial intelligence tools and vegetation indices combined to estimate aboveground biomass in tropical forests. **Journal of Applied Remote Sensing**, v. 17, n. 02, 19 maio 2023.

DARKO, P. O. *et al.* Spectral complexity of hyperspectral images: A new approach for mangrove classification. **Remote Sensing**, v. 13, n. 13, p. 2604, 2 jul. 2021.

DEBACKER, S. *et al.* **A band selection technique for spectral classification**. IEEE Geoscience and Remote Sensing Letters, v. 2, n. 3, p. 319–323, jul. 2005.

ELZHOV, T. V.; MULLEN, K. M.; SPIESS, A.-N.; BOLKER, B. **minpack.lm: R Interface to the Levenberg-Marquardt Nonlinear Least-Squares Algorithm Found in MINPACK, Plus Support for Bounds**. R package versão 1.2-4, 2023. Disponível em: <https://CRAN.R-project.org/package=minpack.lm>.

FARARODA, R. *et al.* Improving plot-level above ground biomass estimation in tropical Indian forests. **Ecological Informatics**, v. 81, p. 102621, jul. 2024.

FASSNACHT, F. E. *et al.* Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. **Remote Sensing of Environment**, v. 154, p. 102–114, nov. 2014.

FERREIRA, M. P. *et al.* Estimating aboveground biomass of tropical urban forests with UAV-borne hyperspectral and LiDAR data. **Urban Forestry & Urban Greening**, v. 96, p. 128362, jun. 2024.

FERREIRA, M. P. *et al.* Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. **Forest Ecology and Management**, v. 475, p. 118397, nov. 2020.

FERREIRA, M. P. *et al.* Mapping tree species in tropical seasonal semi-deciduous forests with hyperspectral and multispectral data. **Remote Sensing of Environment**, v. 179, p. 66–78, jun. 2016.

FILELLA, I.; PEÑUELAS, J. The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. **International Journal of Remote Sensing**, v. 15, n. 7, p. 1459-1470, 1994.

FISHER, J. T. Optimizing aboveground carbon mapping in Afrotropical forests to fulfil IPCC carbon reporting standards. **Forest Ecology and Management**, v. 552, p. 121583, jan. 2024.

FRANCESCHINI, M. D. *et al.* Intercomparison of unmanned aerial vehicle and ground-based narrow band spectrometers applied to crop trait monitoring in organic potato production. **Sensors**, v. 17, n. 6, p. 1428, 18 jun. 2017.

GARCIA MILLAN, V. E.; SANCHEZ-AZOFEIFA, G. A.; MALVAREZ, G. C. **Mapping tropical dry forest succession with CHRIS/PROBA hyperspectral images using nonparametric decision trees**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 8, n. 6, p. 3081–3094, jun. 2015.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, n. 3, p. 271–282, jan. 2003.

GONÇALVES, F. *et al.* Estimating aboveground biomass in tropical forests: field methods and error analysis for the calibration of remote sensing observations. **Remote Sensing**, v. 9, n. 1, p. 47, 7 jan. 2017.

GOVENDER, M.; CHETTY, K.; BULCOCK, H. A review of hyperspectral remote sensing and its application in vegetation and water resource studies. **Water SA**, v. 33, n. 2, 14 dez. 2007.

GUIMARÃES, M. R. S. *et al.* Perspectivas para estimativa de biomassa viva e estoque de carbono acima do solo em áreas verdes urbanas do domínio Mata Atlântica, Brasil. **Revista da Sociedade Brasileira de Arborização Urbana**, v. 17, n. 4, p. 41, 12 dez. 2022.

HARRISON, D.; RIVARD, B.; SÁNCHEZ-AZOFEIFA, A. Classification of tree species based on longwave hyperspectral data from leaves, a case study for a tropical dry forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 66, p. 93–105, abr. 2018.

HIGA, R. C. V. *et al.* **Protocolo de medição e estimativa de biomassa e carbono florestal**. Colombo, PR: Embrapa Florestas, 2014. v. 266. p. 89.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, ago. 1988.

IM, J.; JENSEN, J. R. Hyperspectral Remote Sensing of Vegetation. **Geography Compass**, v. 2, n. 6, p. 1943-1961, 2008.

IPCC. **Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems**. Intergovernmental Panel on Climate Change, 2019.

JACON, A. D. *et al.* Aboveground biomass estimates over Brazilian savannas using hyperspectral metrics and machine learning models: experiences with Hyperion/EO-1. **GIScience & Remote Sensing**, v. 58, n. 7, p. 1112–1129, 26 ago. 2021.

KANKE, Y. *et al.* Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. **Precision Agriculture**, v. 17, n. 5, p. 507–530, 29 jan. 2016.

KERSHAW JR., J. A. *et al.* **Forest mensuration**. 5. ed. West Sussex: John Wiley & Sons, 2017.

KUMAR, L. *et al.* **Review of hyperspectral remote sensing and vegetation science**. Hyperspectral Remote Sensing. Dordrecht: Kluwer Academic Press, 2001. p. 111–155.

KUNTE, G.; BHAT, V. Deforestation, Climate Change and the Sustainability of Agriculture: A Review. **Journal of Resources and Ecology**, v. 15, n. 1, 23 jan. 2024.

KURSA, M. B.; RUDNICKI, W. R. Feature Selection with the Boruta Package. **Journal of Statistical Software**, v. 36, n. 11, p. 1–13, 2010.

LALECHÈRE, E. *et al.* Assessing the potential of remote sensing-based models to predict old-growth forests on large spatiotemporal scales. **Journal of Environmental Management**, v. 351, p. 119865, fev. 2024.

LAMB, D. **Regreening the bare hills: tropical forest restoration in the Asia-Pacific region**. Dordrecht: Springer, 2011. Disponível em: <https://doi.org/10.1007/978-90-481-9870-2>.

LAPORTE-FAURET, Q. *et al.* Classification of Atlantic Coastal Sand Dune Vegetation Using In Situ, UAV, and Airborne Hyperspectral Data. **Remote Sensing**, v. 12, n. 14, p. 2222, 11 jul. 2020.

LATIFI, H.; FASSNACHT, F.; KOCH, B. Forest structure modeling with combined airborne hyperspectral and LiDAR data. **Remote Sensing of Environment**, v. 121, p. 10–25, jun. 2012.

LAURIN, G. V. *et al.* Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 89, p. 49–58, mar. 2014.

LI, Z. *et al.* Aboveground biomass estimation in forests with random forest and Monte Carlo-based uncertainty analysis. **Ecological Indicators**, v. 142, p. 109246, set. 2022.

LIU, Y. *et al.* Improving potato AGB estimation to mitigate phenological stage impacts through depth features from hyperspectral data. **Computers and Electronics in Agriculture**, v. 219, p. 108808, abr. 2024.

LOURENÇO, P. *et al.* Estimating tree aboveground biomass using multispectral satellite-based data in Mediterranean agroforestry system using random forest algorithm. **Remote Sensing Applications: Society and Environment**, v. 23, p. 100560, ago. 2021.

LU, D. *et al.* Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. **International Journal of Forestry Research**, v. 2012, p. 1–16, 2012.

LUMLEY, T. **Leaps: Regression Subset Selection**. R package versão 3.2, 2024. Disponível em: <https://CRAN.R-project.org/package=leaps>.

MERRICK, T. *et al.* Unveiling spatial and temporal heterogeneity of a tropical forest canopy using high-resolution NIRv, FCVI, and NIRvrad from UAS observations. **Biogeosciences**, v. 18, n. 22, p. 6077-6091, 2021.

MIYOSHI, G. T. *et al.* Evaluation of Hyperspectral Multitemporal Information to Improve Tree Species Identification in the Highly Diverse Atlantic Forest. **Remote Sensing**, v. 12, n. 2, p. 244, 10 jan. 2020.

MO, L. *et al.* Integrated global assessment of the natural forest carbon potential. **Nature**, v. 624, n. 7990, p. 92–101, 13 nov. 2023.

MUNYATI, C. Detecting the distribution of grass aboveground biomass on a rangeland using Sentinel-2 MSI vegetation indices. **Advances in Space Research**, v. 69, n. 2, p. 1130–1145, jan. 2022.

MUTANGA, O.; MASENYAMA, A.; SIBANDA, M. Spectral saturation in the remote sensing of high-density vegetation traits: A systematic review of progress, challenges, and prospects. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 198, p. 297-309, 2023.

PAPA, D. de A. *et al.* Evaluating tropical forest classification and field sampling stratification from lidar to reduce effort and enable landscape monitoring. **Forest Ecology and Management**, v. 457, p. 117634, fev. 2020.

PINON, T. B. M. *et al.* Biodiversity from the Sky: Testing the Spectral Variation Hypothesis in the Brazilian Atlantic Forest. **Remote Sensing**, v. 16, n. 23, p. 4363, 2024.

QIN, Q. *et al.* Comparing vegetation indices from Sentinel-2 and Landsat 8 under different vegetation gradients based on a controlled grazing experiment. **Ecological Indicators**, v. 133, p. 108363, dez. 2021.

R CORE TEAM. **RStudio: Integrated Development Environment for R**. Boston, MA: RStudio, PBC, 2023. Disponível em: <http://www.rstudio.com/>.

RÉJOU-MÉCHAIN, M. *et al.* biomass: an r package for estimating above-ground biomass and its uncertainty in tropical forests. **Methods in Ecology and Evolution**, v. 8, n. 9, p. 1163–1167, 29 mar. 2017.

ROCHA, R. *et al.* Secondary forest regeneration benefits old-growth specialist bats in a fragmented tropical landscape. **Scientific Reports**, v. 8, n. 1, 28 fev. 2018.

ROSAN, T. M. *et al.* Synthesis of the land carbon fluxes of the Amazon region between 2010 and 2020. **Communications Earth & Environment**, v. 5, n. 1, 22 jan. 2024.

ROXBURGH, S. H.; PAUL, K. I. Comprehensive propagation of errors for the prediction of woody biomass. **Methods in Ecology and Evolution**, v. 16, n. 1, p. 197-214, 2025.

ROZENDAAL, D. M. A. *et al.* Biodiversity recovery of Neotropical secondary forests. **Science Advances**, v. 5, n. 3, mar. 2019.

SAARELA, S. *et al.* Mapping aboveground biomass and its prediction uncertainty using LiDAR and field data, accounting for tree-level allometric and LiDAR model errors. **Forest Ecosystems**, v. 7, n. 1, 3 jul. 2020.

SANTORO, M. *et al.* The global forest above-ground biomass pool for 2010 estimated from high-resolution satellite observations. **Earth System Science Data**, v. 13, n. 8, p. 3927–3950, 11 ago. 2021.

SILVA, F. A. da *et al.* Uncertainty assessment in volume and biomass estimations in forest stands. **Floresta**, v. 53, n. 4, p. 548, 29 set. 2023.

SILVA, L. D. C. da. **Mudança em volume, biomassa e carbono do fuste em uma floresta estacional semidecidual da Mata Atlântica, ES**. 2020. 149 f. - Universidade Federal do Espírito Santo, 2020.

SMITH, C.; BAKER, J. C. A.; SPRACKLEN, D. V. Tropical deforestation causes large reductions in observed precipitation. **Nature**, v. 615, n. 7951, p. 270–275, 1 mar. 2023.

SOUZA, E. M. F. R. de *et al.* **Spectral analysis of different vegetation cover using the Hyperion sensor – a case study in the State of Rio de Janeiro – Brazil.** The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. XXXIX-B7, p. 109–111, 31 jul. 2012.

TIEPOLO, G. *et al.* **Measuring and monitoring carbon stocks at the Guaraqueçaba climate action project, Paraná, Brazil.** In: International symposium on forest carbon sequestration and monitoring, 2002. Extension Serie Taiwan Forestry Research Institute. p. 98-115.

TREITZ, P. M.; HOWARTH, P. J. Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems. **Progress in Physical Geography: Earth and Environment**, v. 23, n. 3, p. 359–390, set. 1999.

UPADHYAY, V.; KUMAR, A. Hyperspectral Remote Sensing of Forests: Technological advancements, Opportunities and Challenges. **Earth Science Informatics**, v. 11, n. 4, p. 487–524, 15 maio 2018.

VACEK, Z.; VACEK, S.; CUKOR, J. European forests under global climate change: Review of tree growth processes, crises and management strategies. **Journal of Environmental Management**, v. 332, p. 117353, abr. 2023.

VERMA, R. K.; SHARMA, L. K.; LELE, N. AVIRIS-NG hyperspectral data for biomass modeling: from ground plot selection to forest species recognition. **Journal of Applied Remote Sensing**, v. 17, n. 1, p. 014522, 2023.

VESCOVO, L. *et al.* New spectral vegetation indices based on the near-infrared shoulder wavelengths for remote detection of grassland phytomass. **International Journal of Remote Sensing**, v. 33, n. 7, p. 2178–2195, 18 out. 2011.

WANG, E. *et al.* Improving Forest Above-Ground Biomass Estimation Accuracy Using Multi-Source Remote Sensing and Optimized Least Absolute Shrinkage and Selection Operator Variable Selection Method. **Remote Sensing**, v. 16, n. 23, p. 4497, 30 nov. 2024.

WANG, X.; JIAO, H. **Spatial Scaling of Forest Aboveground Biomass Using Multi-Source Remote Sensing Data.** IEEE Access, v. 8, p. 178870–178885, 2020.

WHITE, J. C. *et al.* A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. **The Forestry Chronicle**, v. 89, n. 06, p. 722–723, dez. 2013.

WHITE, J. C. *et al.* Remote Sensing Technologies for Enhancing Forest Inventories: A Review. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 619–641, 27 jul. 2016.

WRIGHT, S. J.; MULLER-LANDAU, H. C. The Future of Tropical Forest Species1. **Biotropica**, v. 38, n. 3, p. 287–301, 4 abr. 2006.

WU, H.; LI, Z.-L. Scale Issues in Remote Sensing: A Review on Analysis, Processing and Modeling. **Sensors**, v. 9, n. 3, p. 1768–1793, 13 mar. 2009.

YU, Y. *et al.* Spatial Scale Effect and Correction of Forest Aboveground Biomass Estimation Using Remote Sensing. **Remote Sensing**, v. 14, n. 12, p. 2828, 13 jun. 2022.

ZARCO-TEJADA, P. J. *et al.* Scaling-up and model inversion methods with narrowband optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 7, p. 1491–1507, jul. 2001.

ZHANG, Xiaoli *et al.* Improved random forest algorithms for increasing the accuracy of forest aboveground biomass estimation using Sentinel-2 imagery. **Ecological Indicators**, v. 159, p. 111752, fev. 2024.

ZURQANI, H. A. A multi-source approach combining GEDI LiDAR, satellite data, and machine learning algorithms for estimating forest aboveground biomass on Google Earth Engine platform. **Ecological Informatics**, v. 86, p. 103052, maio 2025.

CAPÍTULO III - ESTIMATIVA DE BIOMASSA ACIMA DO SOLO EM FRAGMENTOS FLORESTAIS DE MATA ATLÂNTICA POR MEIO DA COMBINAÇÃO DE DADOS HIPERESPECTRAIS E LIDAR OBTIDOS A PARTIR DE RPA

RESUMO

As florestas tropicais são fundamentais para a conservação dos ecossistemas, atuando como sumidouros de carbono e habitat de espécies endêmicas. Contudo, a degradação, como ocorre na Mata Atlântica, compromete serviços ecossistêmicos, incluindo o armazenamento de carbono na biomassa acima do solo (AGB). A quantificação da biomassa pode ser realizada por imagens de satélite e inventário florestal (IF), no qual unidades amostrais são instaladas e variáveis como altura, diâmetro e densidade da madeira são medidas em campo. No entanto, o IF na Mata Atlântica é caro e demorado. Assim, a integração de IF com sensores LiDAR e hiperespectrais tem sido empregada para obter estimativas mais eficientes de biomassa. No presente estudo, objetivou-se combinar dados de sensores LiDAR e hiperespectrais para estimar a biomassa acima do solo em fragmentos de Mata Atlântica em diferentes estágios sucessionais. Para isso, foram instaladas 30 parcelas permanentes (30 m × 30 m) em cinco remanescentes florestais localizadas no sul do estado do Espírito Santo, Brasil. Em cada parcela, todos os indivíduos arbóreos com diâmetro à altura do peito (D , medido à 1,3 m do solo) ≥ 5 cm foram identificados e mensurados, permitindo a estimativa da AGB. A aquisição de dados espectrais foi realizada com um sensor hiperespectral embarcado em RPA, cobrindo a faixa espectral de 397–1002 nm com resolução espacial de 0,11 m, posteriormente reamostrada para 0,5 m e 5 m. Paralelamente, os dados tridimensionais foram obtidos a partir de um sistema LiDAR também acoplado ao RPA. O processamento incluiu remoção de ruídos, classificação do solo e geração de um modelo digital de terreno. Métricas estruturais foram extraídas, incluindo altura e transformada de Fourier. O algoritmo Boruta foi usado para seleção de variáveis, seguido de regressão não linear para estimar a biomassa acima do solo. O desempenho dos modelos foi avaliado por bootstrap, utilizando métricas como raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2). Todo o processamento e análise estatística foram conduzidos no ambiente de programação R. A análise de importância indicou que as métricas LiDAR mais relevantes para a predição de AGB estão associadas à distribuição de altura da vegetação e à amplitude das frequências da transformada de Fourier. As métricas Hmax, HL1, Hmean e HP99 se destacaram entre as tradicionais, enquanto amp.01, amp.28 e amp.27 foram as mais relevantes entre as

métricas espectrais. Os modelos ajustados apresentaram alta precisão (R^2 entre 0,87 e 0,92) e baixos erros (RMSE entre 57,24 e 63,15 Mg.ha⁻¹). A melhor estimativa foi alcançada pelo modelo que combinou H_{max} , HL₄ e amp.01, resultando em um RMSE de 57,24 Mg.ha⁻¹ (34,61%). A fusão de dados LiDAR e hiperespectrais melhorou ligeiramente a precisão da estimativa, com o melhor modelo atingindo um RMSE de 51,14 Mg.ha⁻¹ (30,92%). A fusão de ambos os dados trouxe ganhos mínimos na precisão, e em alguns casos, os modelos baseados apenas em LiDAR foram mais eficientes. As métricas mais relevantes foram altura máxima, percentis de altura e amplitudes da transformada de Fourier, que capturam variações estruturais da vegetação. Assim, os dados LiDAR isoladamente foram suficientes para estimativas confiáveis de biomassa, sugerindo que melhorias na seleção de variáveis espectrais podem ser necessárias para otimizar o uso de dados hiperespectrais em estudos futuros.

Palavras-chave: Sensoriamento remoto. Modelagem florestal. Florestas secundárias.

ABSTRACT

Tropical forests are essential for ecosystem conservation, acting as carbon sinks and habitats for endemic species. However, degradation—as seen in the Atlantic Forest—compromises ecosystem services, including carbon storage in aboveground biomass (AGB). Biomass quantification can be achieved through satellite imagery and forest inventory (FI), in which sampling plots are installed and variables such as height, diameter, and wood density are measured in the field. Nevertheless, FI in the Atlantic Forest is costly and time-consuming. Thus, the integration of FI with LiDAR and hyperspectral sensors has been employed to produce more efficient biomass estimates. This study aimed to combine LiDAR and hyperspectral sensor data to estimate AGB in Atlantic Forest fragments at different successional stages. Thirty permanent plots (30 m × 30 m) were established in five forest remnants located in southern Espírito Santo, Brazil. In each plot, all tree individuals with a diameter at breast height (DBH, measured at 1.3 m from the ground) ≥ 5 cm were identified and measured, enabling AGB estimation. Spectral data were acquired using a hyperspectral sensor mounted on a remotely piloted aircraft (RPA), covering the 397–1002 nm spectral range with a spatial resolution of 0.11 m, later resampled to 0.5 m and 5 m. In parallel, three-dimensional data were obtained from a LiDAR system also mounted on the RPA. Processing included noise removal, ground classification, and generation of a digital terrain model. Structural metrics were extracted, including height and Fourier transform-based variables. The Boruta algorithm was used for variable selection, followed by non-linear regression to estimate AGB. Model performance was assessed using bootstrap resampling, with metrics such as root mean square error (RMSE) and coefficient of determination (R^2). All data processing and statistical analyses were performed in the R programming environment. The importance analysis indicated that the most relevant LiDAR metrics for AGB prediction were associated with vegetation height distribution and Fourier transform frequency amplitudes. Among traditional metrics, H_{\max} , HL_1 , H_{mean} , and HP_{99} stood out, while amp.01, amp.28, and amp.27 were the most relevant spectral metrics. The fitted models showed high accuracy (R^2 between 0.87 and 0.92) and low errors (RMSE between 57.24 and 63.15 $\text{Mg}\cdot\text{ha}^{-1}$). The best estimate was achieved by a model combining H_{\max} , HL_4 , and amp.01, resulting in an RMSE of 57.24 $\text{Mg}\cdot\text{ha}^{-1}$ (34.61%). The fusion of LiDAR and hyperspectral data slightly improved estimation accuracy, with the best model achieving an RMSE of 51.14 $\text{Mg}\cdot\text{ha}^{-1}$ (30.92%). However, this data fusion yielded minimal gains in accuracy, and in some cases, LiDAR-only models were more efficient. The most relevant metrics included maximum height, height percentiles, and Fourier transform amplitudes, which capture structural variations in vegetation. Thus, LiDAR data alone proved sufficient

for reliable biomass estimates, suggesting that further improvements in spectral variable selection may be necessary to optimise the use of hyperspectral data in future studies.

Keywords: Remote sensing, Forest modeling, Secondary forests.

1 INTRODUÇÃO

As florestas tropicais desempenham um papel fundamental na conservação dos ecossistemas, sendo sumidouros de carbono, habitat de espécies endêmicas e ameaçadas de extinção e elementos-chave na regulação do clima. No entanto, a crescente pressão antrópica tem intensificado a degradação de ecossistemas terrestres, comprometendo serviços ecossistêmicos fundamentais (Thakur *et al.*, 2024; Theobald *et al.*, 2025), como o armazenamento de carbono.

A Mata Atlântica, um dos biomas mais biodiversos do planeta e reconhecido como um *hotspot* de biodiversidade (Mittermeier *et al.*, 2004; Myers *et al.*, 2000), exemplifica esse cenário, sendo caracterizada por intensa fragmentação e degradação. A vegetação é composta principalmente por remanescentes florestais localizados em Unidades de Conservação e pequenos fragmentos isolados (Guariz; Guariz, 2020; SFB, 2020), imersos em uma matriz predominantemente desmatada (Santos *et al.*, 2020), composta por um mosaico de pastagens degradadas ou áreas agrícolas (Simonelli *et al.*, 2021).

A estimativa da biomassa acima do solo (AGB) é uma ferramenta essencial para o monitoramento florestal e estratégias de conservação, sendo tradicionalmente realizada por meio de inventários florestais (IF), onde são instaladas unidades amostrais na área de interesse e as variáveis como altura, diâmetro à altura do peito e densidade da madeira são medidas e coletadas em campo (Araújo *et al.*, 2023; Ferreira *et al.*, 2024).

O IF, embora seja preciso, apresenta limitações relacionadas ao custo e à baixa eficiência em áreas extensas e de difícil acesso, como a Mata Atlântica (Silveira *et al.*, 2019). Nesse sentido, o avanço do sensoriamento remoto, especialmente com sensores Light Detection and Ranging (LiDAR) e hiperespectrais, tem proporcionado alternativas mais eficientes para a estimativa de biomassa florestal (Adhikari *et al.*, 2024; Ferreira *et al.*, 2024; Luo *et al.*, 2017).

O LiDAR utiliza um sistema de varredura a laser para obter medidas tridimensionais da vegetação, fornecendo informações detalhadas sobre altura, densidade e estrutura do dossel florestal (Achim *et al.*, 2021; Ferraz *et al.*, 2016). Essa tecnologia fornece estimativa precisa da estrutura da floresta (Calders *et al.*, 2015; Newnham *et al.*, 2012). Complementarmente, os sensores hiperespectrais fornecem imagens hiperespectrais (HSI) com alto detalhamento espectral, além de fornecerem informações essenciais para a calibração de modelos, possibilitando estimar atributos florestais para grandes áreas (Fagua *et al.*, 2019; Gupta; Sharma, 2022; Huang *et al.*, 2022). É importante ressaltar que, diferente do LiDAR, as informações hiperespectrais são capazes de detectar características

de absorção úteis para distinguir características funcionais e de composição (Almeida *et al.*, 2019; Ustin *et al.*, 2004), por exemplo, estimar classes de cobertura da terra, tipos funcionais de plantas, espécies de árvores (Richter *et al.*, 2016; Roth *et al.*, 2015) e, conteúdo bioquímico e nutricional (Asner *et al.*, 2015; Wang *et al.*, 2020).

A integração dessas tecnologias tem sido amplamente explorada para aprimorar a estimativa de biomassa acima do solo (Ferreira *et al.*, 2024; Almeida *et al.*, 2019), a identificação de espécies (Martins-Neto *et al.*, 2023) e o monitoramento da estrutura e diversidade das florestas tropicais (Almeida *et al.*, 2021). Diferentemente do LiDAR, que fornece informações estruturais, os sensores hiperespectrais são capazes de detectar sinais espectrais associados a propriedades bioquímicas da vegetação, possibilitando análises mais completas da composição e funcionamento do ecossistema (Asner *et al.*, 2015; Wang *et al.*, 2020). A combinação desses sensores permite superar as limitações inerentes a cada tecnologia quando utilizadas isoladamente, proporcionando estimativas mais confiáveis.

O avanço das tecnologias de aquisição de dados também permitiu a incorporação de LiDAR e sensores hiperespectrais em Aeronaves Remotamente Pilotadas (RPAs), ampliando a resolução espacial e temporal dos dados coletados (White *et al.*, 2013). Comparado a sensores orbitais e aeronaves tripuladas, o uso de RPAs apresenta vantagens como maior precisão, uma vez que permite voos em baixa altitude e coleta de dados em alta resolução (Almeida *et al.*, 2021; Sothe *et al.*, 2019). Essas características tornam as RPAs particularmente úteis para o monitoramento de fragmentos florestais de diferentes tamanhos e estados de conservação, onde a aquisição de dados detalhados por métodos tradicionais é desafiadora.

Embora LiDAR e sensores hiperespectrais sejam amplamente utilizados para estimativas de AGB, ainda há incertezas sobre os ganhos reais da fusão dessas tecnologias. Estudos como os de Almeida *et al.* (2019), Almeida *et al.* (2020) e Ferreira *et al.* (2024) reportaram ganhos significativos na precisão da estimativa de biomassa ao combinar dados LiDAR e hiperespectrais. Em contraste, pesquisas como as de Clark *et al.* (2011), Laurin *et al.* (2014) e Luo *et al.* (2017) identificaram melhorias mínimas na precisão dos modelos preditivos com a fusão dessas tecnologias.

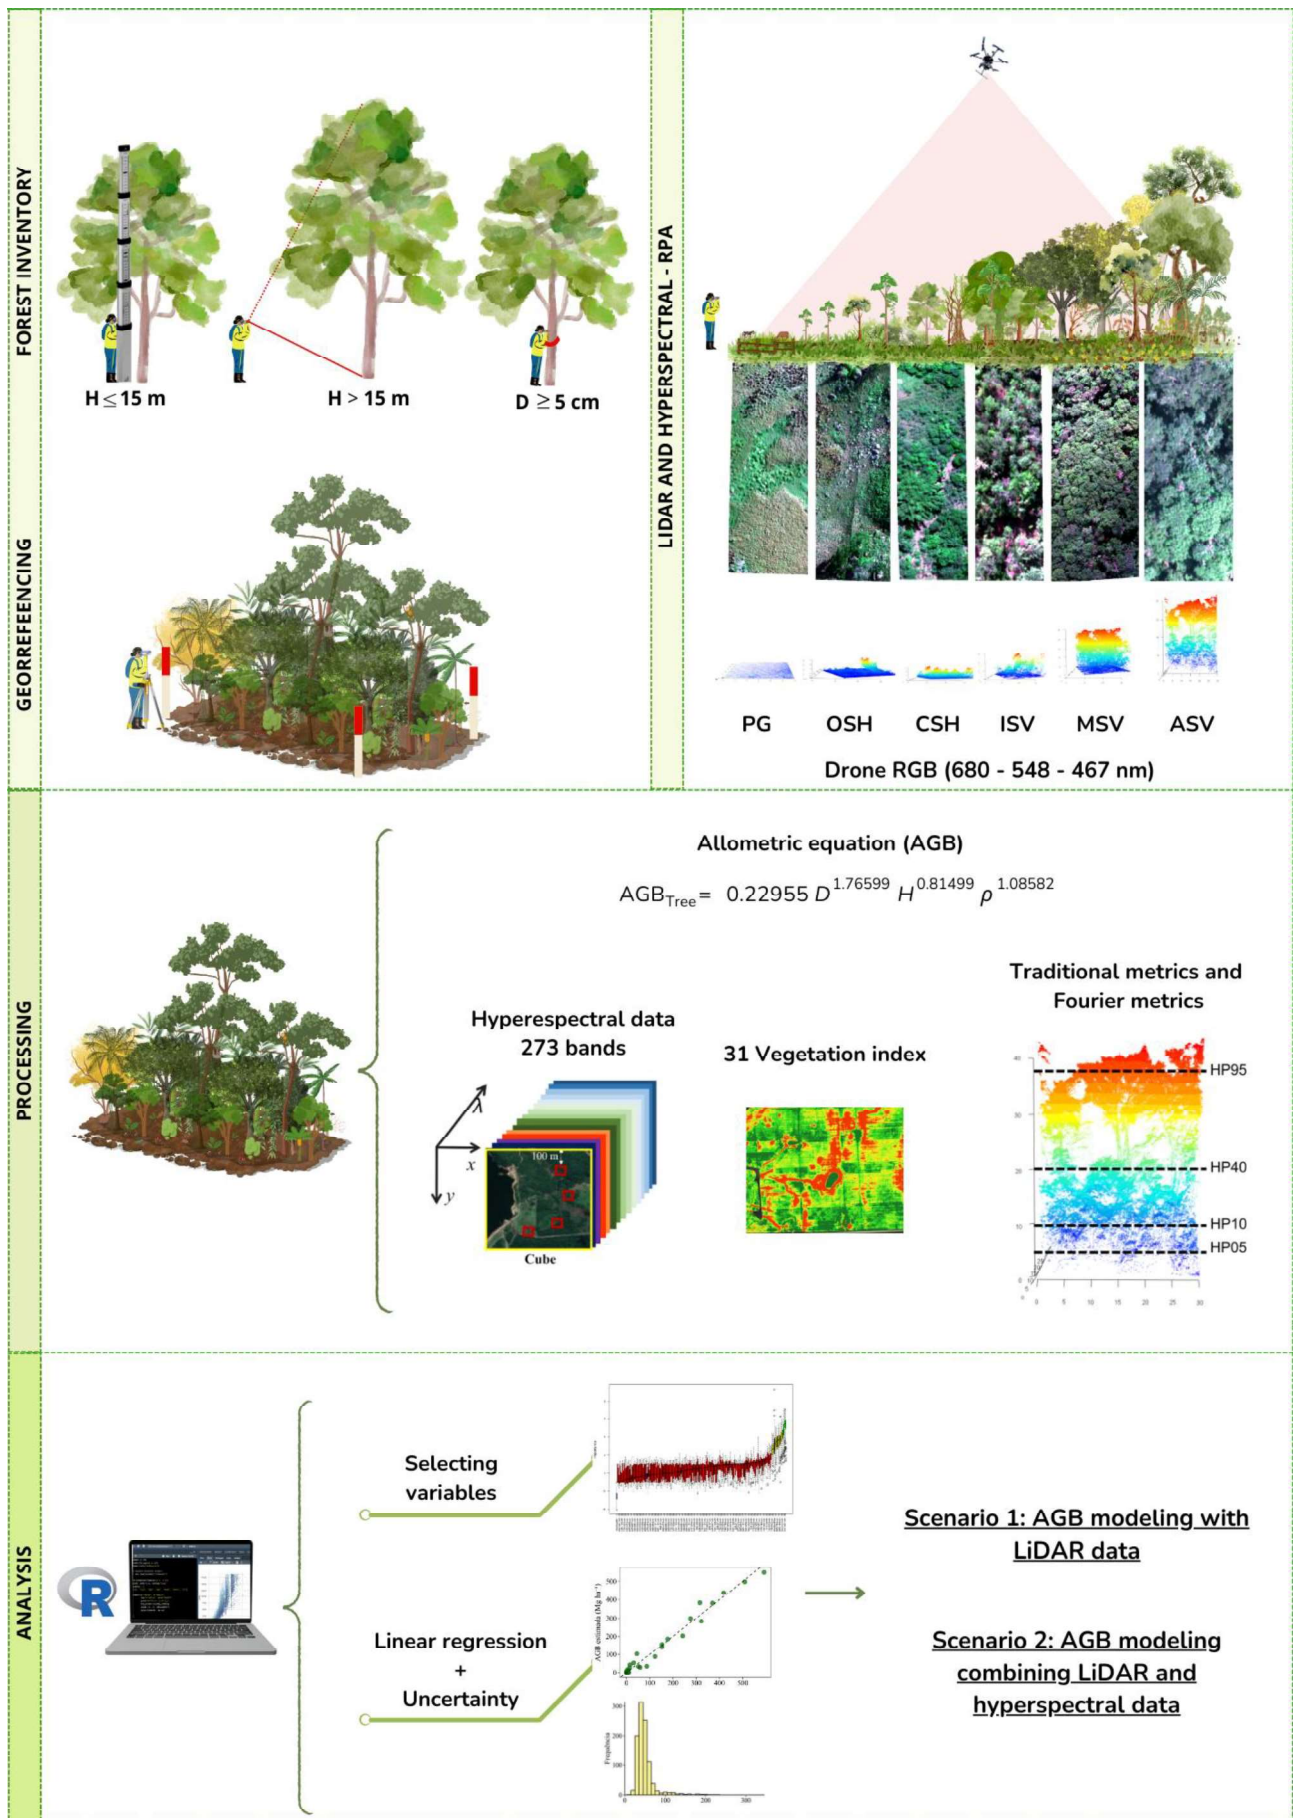
Assim, em função do exposto, este estudo busca avaliar a contribuição da fusão de dados LiDAR e hiperespectrais na estimativa de AGB em fragmentos de Mata Atlântica, comparando sua eficiência em relação ao uso exclusivo do LiDAR. Com base nessa abordagem, este estudo teve como objetivos avaliar as seguintes hipóteses: (1) a AGB pode ser estimada com precisão a partir de métricas estruturais extraídas de dados LiDAR

adquiridos por RPA; e (2) a contribuição dos dados hiperespectrais para a estimativa de AGB é limitada, podendo não resultar em melhorias significativas em comparação aos modelos baseados apenas em LiDAR.

2 MATERIAL E MÉTODOS

A descrição da área de estudo, do inventário florestal e da coleta de dados hiperespectrais estão apresentadas na seção 2 do Capítulo I desta tese. O fluxograma metodológico das etapas necessárias para a realização do presente capítulo é apresentado na Figura 3.1.

Figura 3.1. Fluxograma das etapas metodológicas de inventário florestal, georreferenciamento, processamento e análise de dados.



Fonte: A autora.

2.1 Aquisição e pré-processamento de dados LiDAR-RPA

Os dados LiDAR de retorno discreto foram adquiridos em abril de 2023. A varredura foi realizada utilizando um sensor LiDAR GeoSLam ZEB-HORIZON (modelo GS_510254), com frequência de varredura de 100 Hz, precisão de 1-3 cm e taxa de aquisição de 300.000 pontos por segundo (GEOSLAM, 2022). O sensor foi acoplado a uma aeronave remotamente pilotada (RPA) DJI Matrice 600 PRO, equipada com seis rotores.

Foram realizados cinco voos de forma Visual Line of Sight (VLOS), com altura média de 60 m e velocidade de 3 m/s (Tabela 3.1). Essa altura foi utilizada para garantir que o sensor LiDAR permanecesse dentro do alcance operacional de 100 m, conforme especificado pelo fabricante (GEOSLAM, 2022).

Tabela 3.1. Descrição da área de varredura em cada estágio sucessional.

Estágios	Área de cobertura (ha)	Altura média de voo (m)	Velocidade de voo (m/s)	Tempo médio de voo (min)	Densidade de pontos (pontos/m ²)
Pastagem permanente (<i>Permanent Grassland</i> – PG) Pasto sujo ralo (<i>Open Shrublands</i> – OSH)	10,46	60	3	12	397,82
Pastagem permanente (<i>Permanent Grassland</i> – PG) Pasto sujo denso (<i>Closed Shrublands</i> – CSH)	13,42	60	3	12	465,89
Estágio inicial de vegetação secundária (<i>Initial Stage Secondary Vegetation</i> – ISV)	12,20	60	3	12	538,00
Estágio médio de vegetação secundária (<i>Medium Stage Secondary Vegetation</i> – MSV)	15,69	60	3	12	576,69
Estágio avançado de vegetação secundária (<i>Advanced Stage Secondary Vegetation</i> – ASV)	16,47	60	3	12	353,43

Fonte: A autora.

O georreferenciamento das nuvens de pontos foi realizado no software CloudCompare (CloudCompare, 2023) utilizando pontos de controle de solo. As coordenadas dos pontos de controle foram coletadas por meio de um receptor GNSS modelo Geomax Zenith-16 no modo *Real-Time Kinematic* (RTK), com precisão horizontal de $\pm 0,01$ m e vertical de $\pm 0,02$ m. A raiz do erro médio quadrático (RMSE) final em X e Y foi menor que um (1.00) m em todas as áreas de estudo.

2.2 Processamento de dados LiDAR-RPA

A nuvem de pontos bruta de cada estágio foi inicialmente pré-processada para identificar e remover os ruídos isolados utilizando o pacote lidR (Roussel *et al.*, 2021). A classificação dos ruídos foi realizada por meio do filtro de voxels isolados (IVF), que detecta pontos com poucos vizinhos em seu entorno imediato. Nesse processo, foi adotada uma resolução de voxel (res) de 2 unidades, e o número máximo de vizinhos (n) foi definido como 5. Assim, pontos com menos de 5 vizinhos em uma região de 27 voxels (3 x 3 x 3) foram classificados como ruídos e removidos pelo algoritmo. Em seguida, os pontos previamente classificados como ruídos foram filtrados e eliminados, assegurando que apenas pontos válidos permanecessem nas nuvens de pontos.

A classificação dos pontos do solo foi realizada utilizando o *Ground Segmentation Algorithm* (CSF) do pacote lidR (Roussel *et al.*, 2021), baseado no *Cloth Simulation Filter* (Zhang *et al.*, 2016). O algoritmo foi configurado com os seguintes parâmetros: `sloop_smooth = TRUE`, `class_threshold = 0.1`, `cloth_resolution = 0.1`, `rigidness = 1`, `iterations = 500` e `time_step = 0.5`. Esses parâmetros foram definidos para garantir uma classificação precisa, considerando que boa parte das áreas de estudo apresenta relevo declivoso (Apêndice A).

Após a classificação, os pontos de solo foram interpolados utilizando o algoritmo TIN (*Triangular Irregular Network*) para gerar um modelo digital de terreno (MDT) com resolução espacial de 1 m. A normalização das nuvens de pontos foi realizada subtraindo as elevações do MDT das elevações dos pontos. Esse procedimento ajustou a elevação de cada ponto em relação ao nível do solo, permitindo a obtenção de alturas normalizadas. Todo o procedimento metodológico foi realizado em ambiente R (R Core Team, 2023), utilizando as funções disponíveis no pacote lidR (Roussel *et al.*, 2021).

2.3 Métricas estruturais

A partir das nuvens de pontos normalizadas, foram extraídas métricas tradicionais relacionadas à distribuição de altura, como média, moda, variância, máximo, percentis, etc., bem como métricas que descrevem a forma da distribuição da altura da nuvem de pontos, como a assimetria, curtose e momentos lineares (Tabela 3.2). Também foram calculadas métricas derivadas da transformada de Fourier (Equação 3.1), aplicadas aos perfis verticais de vegetação de cada parcela de inventário (Gonçalves, 2014).

$$\gamma(f) = \frac{\int_0^{\infty} w(z) e^{-i2\pi fz} dz}{\int_0^{\infty} w(z) dz} \quad (3.1)$$

Em que $\gamma(f)$ é a transformada de Fourier normalizada do perfil na frequência espacial f , e $w(z)$ representa a potência do laser recebida centrado na altura z .

Os perfis verticais de cada parcela foram obtidos ao segmentar as nuvens de pontos em intervalos verticais de 50 cm, contabilizando a densidade de pontos em cada intervalo para representar a distribuição vertical da vegetação (Treuhaft *et al.*, 2009; Treuhaft *et al.*, 2010). Os perfis verticais foram decompostos no domínio da frequência, com frequências espaciais variando de 0,01 ciclos por metro. Esse processo resultou em 30 métricas adicionais relacionadas à amplitude e fase em cada frequência analisada (Gonçalves, 2014).

As métricas tradicionais foram extraídas no software FUSION/LDV versão 4.41 (Mcgaughey, 2014) e as métricas de Fourier foram calculadas com scripts personalizados implementados em ambiente R (R Core Team, 2023).

Tabela 3.2. Métricas tradicionais e Fourier obtidas a partir de dados LiDAR.

Tipo	Métricas	Descrição
Altura	H_{\min}	Altura mínima
	H_{\max}	Altura máxima
	H_{mean}	Altura média
	H_{mode}	Moda da altura
	H_{CV}	Coefficiente de variação
	H_{SD}	Desvio padrão
	H_V	Variância
	H_{IQ}	Distância interquartil
	H_{skew}	Assimetria
	H_{kurt}	Curtose
	HP_X	Percentil (1, 5, 10, 20, 25, 30, 40, 50, 60, 70, 75, 80, 90, 95, 99)
	$H_{\text{SQRTmeanSQ}}$	Média generalizada para a 2ª potência
	$H_{\text{CURTmeanCUBE}}$	Média generalizada para a 3ª potência
	HAAD	Desvio absoluto médio
	$HMAD_{\text{median}}$	Mediana dos desvios absolutos em relação à mediana geral
	$HMAD_{\text{mode}}$	Moda dos desvios absolutos em relação à moda geral
	HL_X	Momentos lineares (L1, L2, L3 e L4)
	HL_{skew}	Assimetria baseada em momentos lineares
	HL_{kurt}	Curtose baseada em momentos lineares
	HCRR	Razão de relevo do dossel $(H_{\text{mean}} - H_{\min}) / (H_{\max} - H_{\min})$
CCH	Total de todos os retornos	

	CCHmean	Todos os retornos acima da altura média
	CCHmode	Todos os retornos acima do valor modal de altura
Cobertura de dossel	CCHmean	Porcentagem de todos os retornos acima da altura média em relação ao número total de pontos
	CCHmode	Porcentagem de todos os retornos acima da altura modal em relação ao número total de pontos
	CCH2 _m	Porcentagem de todos os retornos acima de 2 m de altura em relação ao número total de pontos
Fourier	Amp.X	Frequência de Fourier (Amp. 01 - Amp. 30)

Fonte: A autora.

2.4 Métodos estatísticos

O processo de seleção de variáveis preditoras para estimar a biomassa acima do solo foi realizado utilizando o algoritmo Boruta (Kursa; Rudnicki, 2022). Esse procedimento foi aplicado inicialmente às 73 métricas LiDAR para reduzir o conjunto de variáveis, identificando as mais relevantes para a modelagem. Na etapa seguinte, as métricas LiDAR selecionadas pelo Boruta foram submetidas ao método de busca exaustiva, restringindo-se a modelos com até três preditores. A escolha dos subconjuntos mais adequados de variáveis considerou os valores do Critério de Informação Bayesiano (BIC) e do coeficiente de determinação (R^2).

Posteriormente, as métricas LiDAR selecionadas pelo Boruta foram combinadas com as métricas hiperespectrais previamente identificadas no cenário 3 (Capítulo II, seção 3.2), formando um novo conjunto de variáveis combinadas. Essas métricas combinadas foram novamente submetidas ao método de busca exaustiva. Assim como na etapa anterior, a modelagem foi conduzida por meio de regressão linear.

O desempenho dos modelos de regressão linear foi avaliado por meio do método bootstrap, que gera múltiplas amostras aleatórias com reposição, permitindo avaliar a estabilidade dos modelos e reduzir a variabilidade das métricas de desempenho. Em cada iteração, 70% dos dados foram selecionados aleatoriamente para compor o conjunto de treinamento, enquanto os 30% restantes foram usados para validação. O modelo foi ajustado com a amostra bootstrap e validado nas observações não incluídas na amostragem, conhecidas como out-of-bag (OOB). A estimativa do erro OOB foi utilizada como medida de desempenho preditivo. Essa abordagem é especialmente útil para conjuntos de dados pequenos, como o deste estudo, que conta com 30 observações.

Para avaliar o desempenho dos modelos, foram utilizadas métricas estatísticas como erro quadrático médio (Root Mean Square Error – RMSE), RMSE percentual (RMSE%), viés (Bias), viés percentual (Bias%) e coeficiente de determinação ajustado (R^2_{aj}). O erro

de predição foi tomado como a média dos valores de RMSE obtidos nas 1000 repetições. Todas as análises estatísticas foram realizadas em ambiente R (R Core Team, 2023).

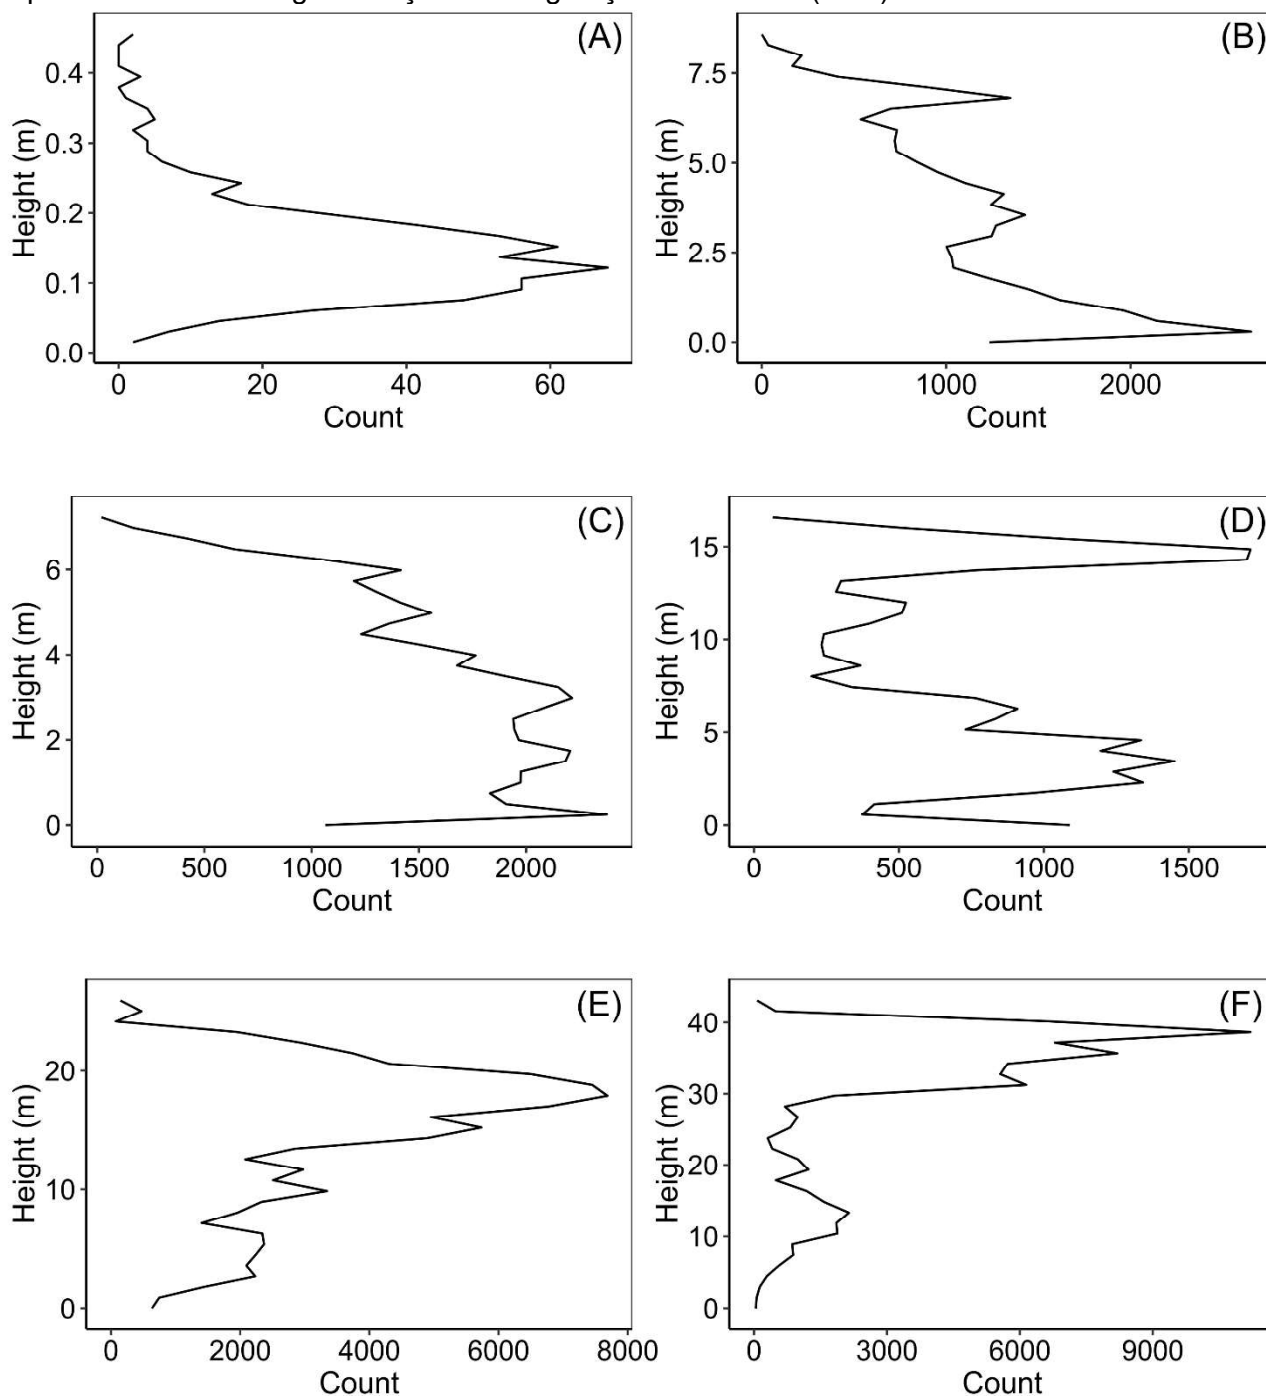
3 RESULTADOS

3.1 Caracterização das áreas

A Figura 3.2 destaca as diferenças na estrutura do dossel ao longo dos distintos estágios sucessionais. Observa-se um aumento na altura da vegetação e na complexidade estrutural à medida que a sucessão ecológica avança. Nos estágios iniciais, a amostra representativa do pasto sujo ralo (OSH) é caracterizada por vegetação de baixa estatura, com altura máxima inferior a 8 metros e baixa densidade de pulsos nas camadas superiores (Figura 3.2B). A amostra representativa do pasto sujo denso (CSH) (Figura 3.2C) apresenta um dossel ligeiramente mais estruturado, com altura máxima em torno de 6 metros, além de maior densidade de pontos em relação às classes anteriores (PG e OSH), mostrando-se um estágio intermediário entre áreas abertas e formações mais desenvolvidas.

Nos estágios mais avançados, as amostras representativas dos estágios inicial (ISV) e médio (MSV) de vegetação secundária (Figuras 3.2D e 3.2E) apresentam uma estrutura mais complexa e estratificada, com árvores atingindo aproximadamente 15 metros em ISV e mais de 20 metros em MSV. O aumento da densidade de pontos ao longo do perfil indica maior heterogeneidade estrutural. No estágio sucessional avançado (ASV), observa-se a formação de um dossel contínuo e bem desenvolvido, com árvores emergentes ultrapassando 30 metros (Figura 3.2F).

Figura 3.2. Representação dos perfis verticais. (A) Perfil vertical de amostra representativa da pastagem permanente (PG); (B) Perfil vertical de amostra representativa do pasto sujo ralo (OSH); (C) Perfil vertical de amostra representativa do pasto sujo denso (CSH); (D) Perfil vertical de amostra representativa do estágio inicial de vegetação secundária (ISV); (E) Perfil vertical de amostra representativa do estágio médio de vegetação secundária (MSV); (F) Perfil vertical de amostra representativa do estágio avançado de vegetação secundária (ASV).



Fonte: A autora.


3.2 Seleção de variáveis

A análise de importância indicou que as métricas mais relevantes para a predição de AGB estão relacionadas principalmente à distribuição de altura da vegetação e à amplitude

das frequências derivadas da transformada de Fourier (Figura 3.3). Entre as variáveis de maior importância, destacam-se H_{\max} (altura máxima), HL_1 (primeiro momento linear da distribuição de altura), H_{mean} (altura média) e HP_{99} (percentil 99 de altura).

Além das métricas tradicionais, as variáveis associadas à amplitude das frequências de Fourier, como amp.01, amp.28 e amp.27, também demonstraram alta relevância. Por outro lado, métricas derivadas da transformada de Fourier, como amp.13, amp.14 e amp.03, tiveram impacto reduzido.

Figura 3.3. Seleção de métricas LiDAR com o algoritmo Boruta.



Fonte: A autora.

3.3 Modelagem de AGB com dados LiDAR

As combinações de métricas estruturais variaram desde modelos mais simples, baseados apenas na altura máxima (H_{\max}), até modelos mais complexos, que incluíram métricas de percentil de altura (HP_{25}), momentos lineares (HL_4) e amplitude de Fourier (amp 01) (Tabela 3.3).

Tabela 3.3. Modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando dados LiDAR.

Nº	Modelos
1	$AGB = -141,8009 + 14,0548 H_{\max}$
2	$AGB = -116,082 + 10,625 H_{\max} + 6,820 HP_{25}$
3	$AGB = 1127,462 + 7,564 H_{\max} + 161,241 HL_4 - 1230,708 \text{ amp}01$

Legenda: Nº 1 é o modelo com uma variável; Nº 2 é o modelo com duas variáveis; Nº 3 é o modelo com três variáveis; H_{\max} é a altura máxima; HP_{25} é o percentil 25; HL_4 é o momento linear 4; amp 01 é a amplitude 01 da transformada de Fourier. Todos os coeficientes foram significativos ao nível de 5%. Fonte: A autora.

Os modelos ajustados para a estimativa de AGB demonstraram altos valores de R^2 tanto na etapa de treino quanto na validação. Na etapa de treino, os valores de R^2 variaram de 0,86 a 0,87, enquanto na validação os valores ficaram entre 0,87 e 0,92 (Tabela 3.4). O RMSE na etapa de treino variou de 40,66 $Mg \cdot ha^{-1}$ a 54,48 $Mg \cdot ha^{-1}$, representando percentuais entre 24,59% e 32,94%. Na etapa de validação, o RMSE foi um pouco mais elevado, com valores variando entre 57,24 $M \cdot ha^{-1}$ e 63,15 $M \cdot ha^{-1}$, correspondendo a percentuais de erro entre 34,61% e 38,18% (Tabela 3.4, Figura 3.4).

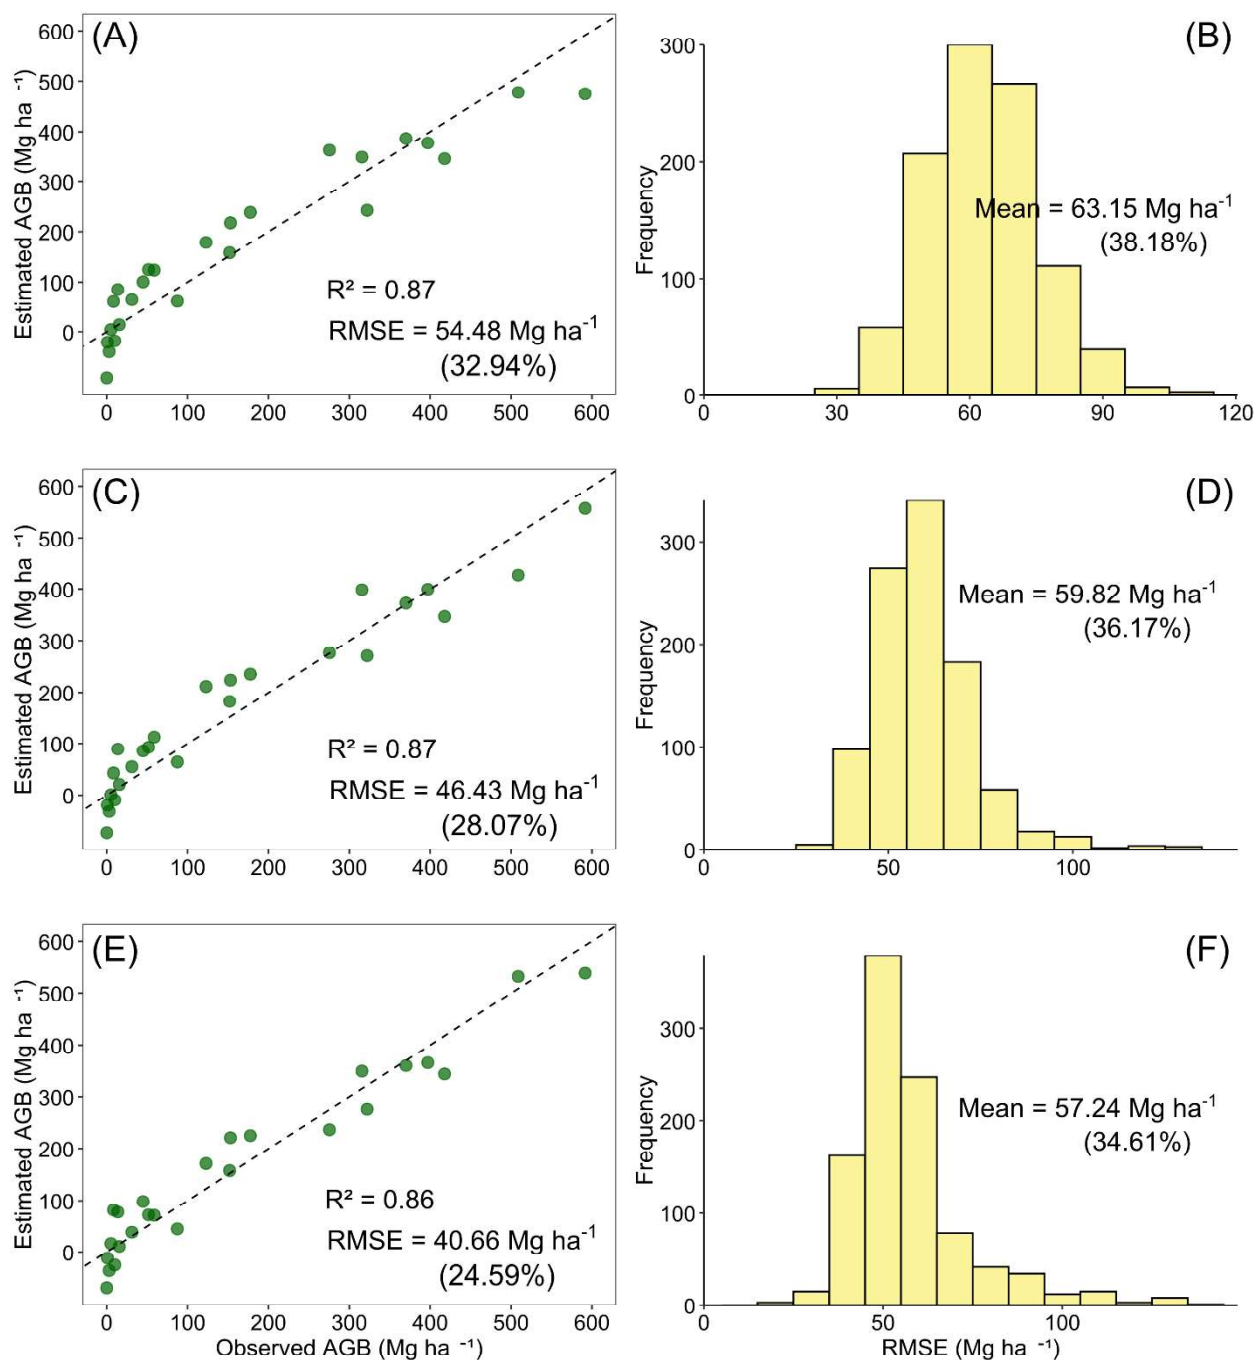
O viés apresentou valores baixos na maioria dos modelos, sugerindo ausência de tendência sistemática de subestimação ou superestimação da biomassa. O menor viés foi registrado no modelo 1, com 1,16% na etapa de validação. O maior viés absoluto foi observado no modelo 3, com valor de 3,16% na validação, sugerindo uma leve subestimação das estimativas de biomassa nesse caso. Entre os modelos ajustados, o menor RMSE na validação foi alcançado pela combinação das métricas H_{\max} , HL_4 e amp 01, com valor de 57,24 $Mg \cdot ha^{-1}$ (34,61%), destacando-se como o mais preciso.

Tabela 3.4. Estatísticas resumidas dos modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando dados LiDAR.

Nº	Treino			Validação		
	R^2_{aj}	RMSE	Bias	R^2_{aj}	RMSE	Bias
1	0,87	54,48 (32,94%)	0 (0%)	0,87	63,15 (38,18%)	4,50 (1,16%)
2	0,87	46,43 (28,07%)	0 (0%)	0,90	59,82 (36,17%)	6,14 (2,43%)
3	0,86	40,66 (24,59%)	0 (0%)	0,92	57,24 (34,61%)	7,25 (3,16%)

Legenda: Nº é o número de variáveis; R^2_{aj} = coeficiente de determinação ajustado; RMSE = erro quadrático médio ($Mg \cdot ha^{-1}$).
Fonte: A autora.

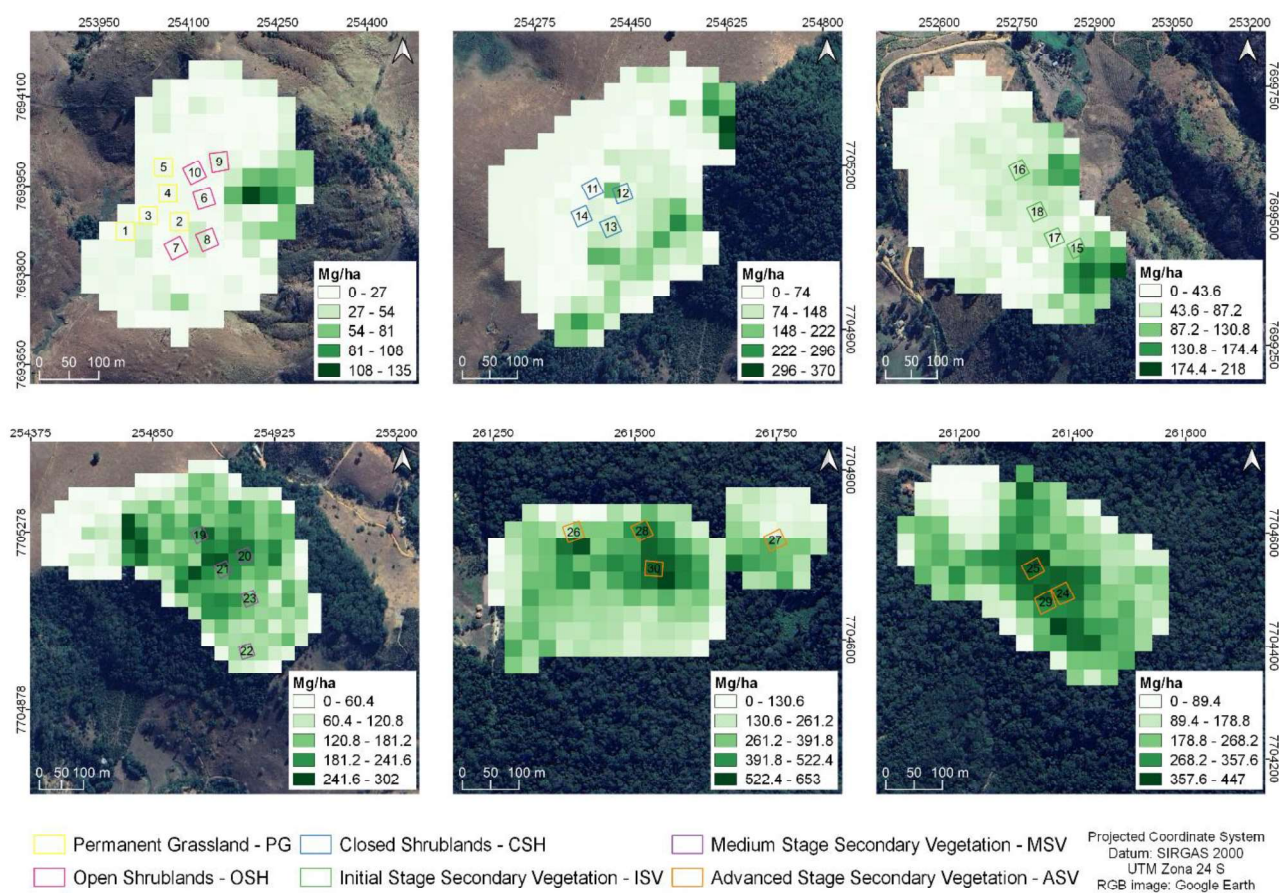
Figura 3.4. Valores estimados da biomassa acima do solo de campo versus valores previstos utilizando métricas LiDAR. (A, B) Modelo com 1 variável; (C, D) Modelo com 2 variáveis; (E, F) Modelo com 3 variáveis. Os histogramas mostram a distribuição dos valores de RMSE obtidos nas 1000 repetições no procedimento de validação.



Fonte: A autora.

Diante do melhor desempenho obtido, o modelo 3 foi utilizado para a geração do mapa de AGB nas áreas de estudo (Figura 3.5). A aplicação desse modelo possibilitou representar a distribuição espacial da biomassa com maior precisão entre os modelos avaliados.

Figura 3.5. Espacialização do melhor modelo de predição de biomassa acima do solo utilizando dados LiDAR.



Fonte: A autora.

3.4 Modelagem de AGB com a fusão de dados LiDAR e hiperespectrais

Os modelos selecionados para estimar a AGB integraram métricas derivadas de dados LiDAR e hiperespectrais, combinando atributos estruturais (H_{max} e HP_{20}) com índices espectrais relacionados à composição bioquímica da vegetação (SIPI e RVSI), conforme apresentado na Tabela 3.5. Essa abordagem destaca o potencial da fusão de diferentes fontes de dados para capturar, de forma mais abrangente, a variabilidade estrutural e funcional da vegetação.

Tabela 3.5. Modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando fusão de dados LiDAR e hiperespectrais.

Nº	Modelos
1	$AGB = -897,350 + 16,570 H_{max} + 660,478 SIPI$
2	$AGB = -94,212 + 8,862 H_{max} + 9,921 HP_{20} + 4905,978 RVSI$

Legenda: Nº 1 é o modelo com duas variáveis; Nº 2 é o modelo com três variáveis; H_{max} é a altura máxima; SIPI é o *Structurally Insensitive Pigment Index*; HP_{20} é o percentil 20; RVSI é o Red-edge Vegetation Stress Index. Todos os coeficientes foram significativos ao nível de 5%. Fonte: A autora.

Os modelos ajustados para a estimativa de AGB apresentaram altos valores de R^2 tanto na etapa de treino quanto na validação. No treino, os valores de R^2 variaram de 0,85 a 0,95, enquanto na validação ficaram entre 0,88 e 0,93 (Tabela 3.6). O RMSE na etapa de treino variou de 37,29 Mg ha⁻¹ a 50,42 Mg ha⁻¹, correspondendo a percentuais de erro entre 22,54% e 30,48%. Na validação, o RMSE foi mais elevado, variando de 51,14 Mg ha⁻¹ a 63,84 Mg ha⁻¹, com percentuais de erro entre 30,92% e 38,61% (Tabela 3.6, Figura 3.6).

O viés permaneceu próximo de zero na maioria dos modelos, indicando ausência de tendência sistemática de superestimação ou subestimação da biomassa. O menor viés foi observado no modelo 2, com 0,04% na validação, enquanto o maior viés foi registrado no modelo 1, com -0,53%. Entre os modelos ajustados, o menor RMSE na validação foi alcançado pelo modelo 2, apresentando 51,14 Mg ha⁻¹ (30,92%). De modo geral, a adição de métricas hiperespectrais às métricas LiDAR aumentou a precisão moderadamente.

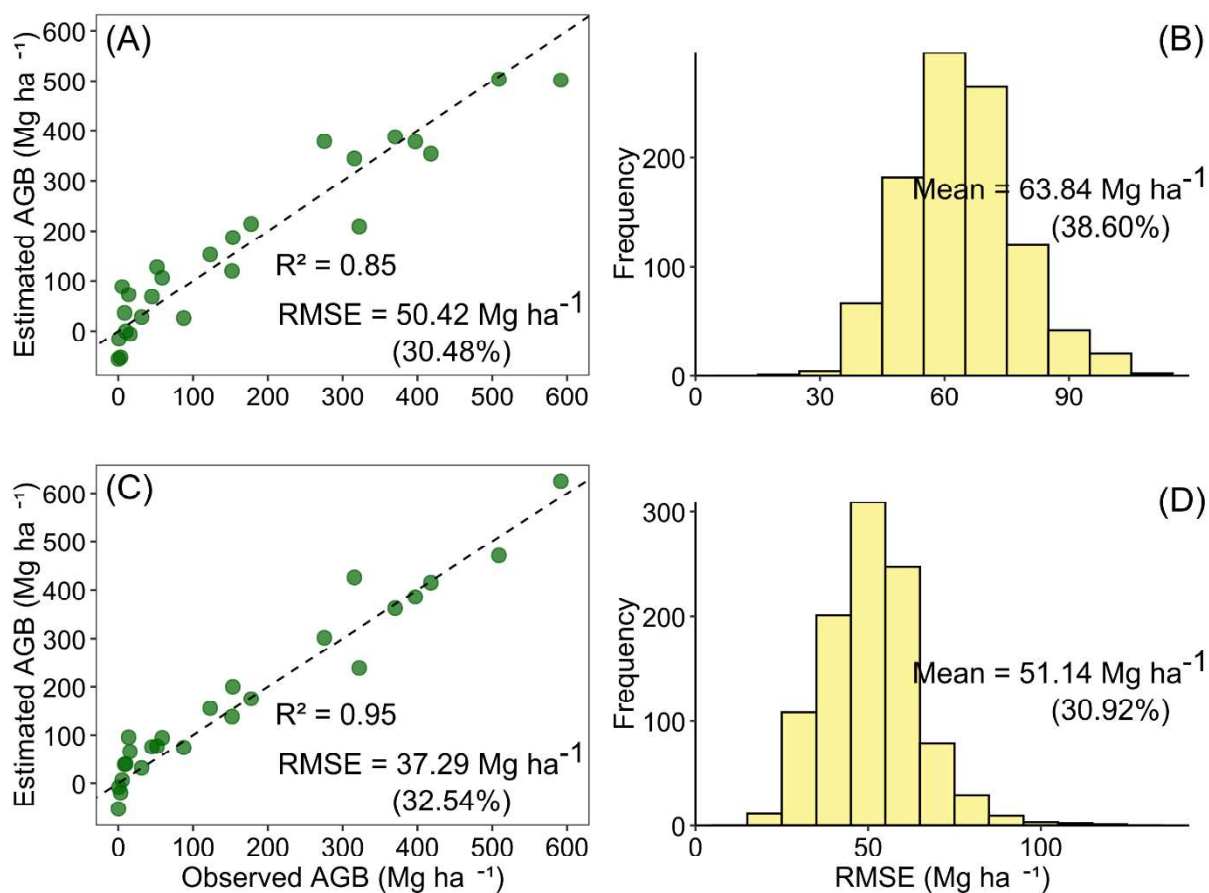
Tabela 3.6. Estatísticas resumidas dos modelos selecionados para estimar a biomassa acima do solo (AGB) utilizando fusão de dados LiDAR e hiperespectral.

Nº	Treino			Validação		
	R ² aj	RMSE	Bias	R ² aj	RMSE	Bias
1	0,85	50,42 (30,48%)	0 (0%)	0,88	63,84 (38,60%)	2,31 (-0,53%)
2	0,95	37,29 (22,54%)	0 (0%)	0,93	51,14 (30,92%)	1,82 (0,04%)

Legenda: Nº 1 é o modelo com duas variáveis; Nº 2 é o modelo com três variáveis; R²aj = coeficiente de determinação ajustado; RMSE = erro quadrático médio (Mg.ha⁻¹).

Fonte: A autora.

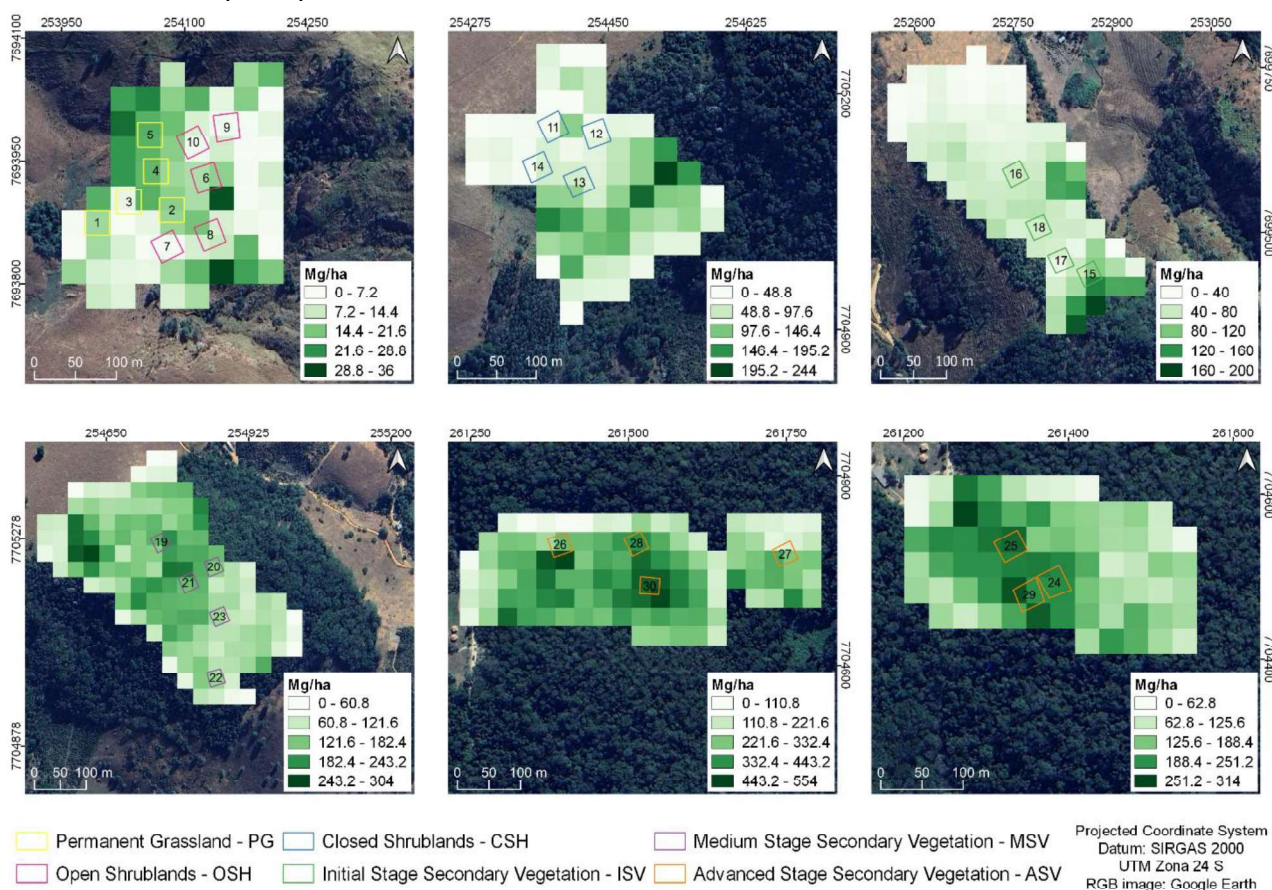
Figura 3.6. Valores estimados da biomassa acima do solo de campo versus valores previstos pela combinação de métricas LiDAR e hiperespectrais. (A, B) Modelo com duas variáveis; (C, D) Modelo com três variáveis. Os histogramas mostram a distribuição dos valores de RMSE obtidos nas 1000 repetições no procedimento de validação.



Fonte: A autora.

Diante do melhor desempenho obtido, o modelo 2 foi utilizado para a geração do mapa de AGB nas áreas de estudo (Figura 3.7). A aplicação desse modelo possibilitou representar a distribuição espacial da biomassa com maior precisão entre os modelos avaliados.

Figura 3.7. Espacialização do melhor modelo de predição de biomassa acima do solo utilizando dados LiDAR e hiperespectrais.



Fonte: A autora.

4 DISCUSSÃO

4.1 Seleção de variáveis

A seleção de métricas LiDAR é importante para aprimorar a precisão de modelos de estimativa de biomassa florestal. Variáveis relacionadas à estrutura vertical, como altura média, percentis de altura e altura máxima, são frequentemente reconhecidas como preditores consistentes de AGB em diferentes tipos de floresta (Zhang *et al.*, 2024; KC *et al.*, 2024). No presente estudo, essas métricas também estiveram entre as mais relevantes, com a altura máxima se destacando como a variável de maior importância. A altura média, por sua vez, esteve entre as três primeiras variáveis mais importantes, corroborando estudos anteriores, como o de Jubanski *et al.* (2013), que também identificaram essa variável como um bom preditor para estimar AGB.

Diversas abordagens para a seleção de métricas adequadas na modelagem de AGB foram descritas por Lu *et al.* (2014). Essas abordagens incluem métodos como regressão

linear stepwise, extração de características, análise de correlação, redes neurais e Random Forest. Neste estudo, o algoritmo Boruta foi utilizado para identificar as variáveis mais relevantes. O Boruta é uma extensão do Random Forest que compara a importância das variáveis reais com variáveis artificiais embaralhadas (shadow variables), selecionando aquelas que se mostram consistentemente mais importantes. Esse método oferece uma seleção mais robusta e abrangente, garantindo que todas as variáveis potencialmente informativas sejam consideradas no modelo (Kursa; Rudnicki, 2010).

4.2 Modelagem de AGB com dados LiDAR

Neste estudo foi confirmada a confiabilidade dos dados LiDAR-RPA na estimação da biomassa acima do solo. Os resultados deste estudo, com valores de R^2 ajustado variando entre 0,87 e 0,92 e RMSE (%) entre 34,61% e 38,18% na etapa de validação, encontram-se dentro da faixa relatada em estudos anteriores para diferentes tipos de florestas (Almeida *et al.*, 2019; Cao *et al.*, 2018; Almeida *et al.*, 2021; Zolkos; Goetz; Dubayah, 2013; Ferreira *et al.*, 2024; Garcia *et al.*, 2017; d'Oliveira *et al.*, 2012; Coops *et al.*, 2021; Omar; Misman; Leong, 2023).

No entanto, é importante ressaltar que a precisão dos modelos pode ser influenciada por fatores como o tipo de floresta e as características das parcelas amostrais. Goetz e Dubayah (2011) observaram, por exemplo, que o aumento no tamanho das parcelas tende a reduzir o erro de predição, devido à suavização dos erros individuais por meio da média espacial. Além disso, de acordo com Lu *et al.* (2012), a precisão das estimativas pode variar espacialmente em função da complexidade da paisagem, da densidade dos dados amostrais e da qualidade dos dados de sensoriamento remoto utilizados.

Na literatura, diferentes variáveis têm sido adotadas para a estimativa de biomassa, incluindo a altura mediana ou a altura total das árvores (Drake *et al.*, 2002), a altura quadrática média (Nelson *et al.*, 2007; Næsset, 2011; Chen *et al.*, 2012), a densidade de área foliar (LAD) (Almeida *et al.*, 2019), índice de área foliar (LAI) (Peng *et al.*, 2020) e percentis de altura (Almeida *et al.*, 2019; Laurin *et al.*, 2014; Næsset, 2007; Peng *et al.*, 2020). Assim, não há um conjunto de descritores estruturais amplamente consensual, nem mesmo quando se considera o mesmo tipo de floresta (Treuhaft *et al.*, 2013).

Neste estudo, os modelos ajustados incorporaram métricas relacionadas à estrutura vertical da vegetação, como altura máxima, percentis de altura e amplitude derivadas da transformada de Fourier, com a H_{\max} sendo a única variável presente em todos os modelos (Tabela 3). A recorrência da H_{\max} como variável preditora em todos os modelos pode estar

relacionada à sua capacidade de representar a variação estrutural ao longo dos diferentes estágios sucessionais da vegetação incluídos na modelagem, que variaram desde pastos ralos e densos até florestas em estágios inicial, médio e avançado.

Os dados LiDAR foram mais sensíveis às características de altura da vegetação. As métricas relacionadas à altura do dossel frequentemente se destacam como preditores importantes na modelagem da AGB devido à sua estreita relação com a estrutura vertical da floresta e, conseqüentemente, com a biomassa. No estudo de Li *et al.* (2014), as métricas de altura também foram mais relevantes para quantificar a biomassa, enquanto outras métricas relacionadas à cobertura do dossel apresentaram menor contribuição. No presente estudo, a H_{\max} sozinha capturou 87% da variância na AGB (Modelo 1), em comparação com 92% do modelo 3 com três variáveis.

As métricas de altura do dossel, com destaque para aquelas relacionadas à percentis, oferecem boa precisão na modelagem de AGB, reforçando sua relevância na representação das mudanças estruturais da floresta (Zhang *et al.*, 2024; Li *et al.*, 2014; Lim; Treitz, 2003; Ehlers *et al.*, 2022). Percentis de altura, como HP_{25} e HP_{40} , fornecem informações sobre a estrutura intermediária do dossel, complementando métricas mais tradicionais, como a altura máxima, e aumentando a precisão ao capturar a variabilidade vertical da floresta. O bom desempenho de percentis mais baixos já foi destacado anteriormente, demonstrando que em florestas de diferentes estratos há uma parcela significativa de biomassa concentrada nas árvores de médio porte (Laurin *et al.*, 2014).

As métricas de amplitude derivadas da transformada de Fourier destacaram-se como variáveis relevantes nos modelos, capturando padrões estruturais da vegetação em diferentes escalas verticais. Estudos anteriores, como o de Treuhaft *et al.* (2010) verificaram uma forte correlação entre as frequências verticais e a biomassa em florestas tropicais, utilizando perfis verticais de vegetação derivados de dados de LiDAR aerotransportado.

A relevância das amplitudes derivadas da transformada de Fourier foi confirmada por Gonçalves (2015), que demonstrou que os modelos baseados nessa técnica apresentam desempenho preditivo significativamente superior ao dos modelos tradicionais, especialmente em florestas de alta biomassa. Esses modelos explicaram até 94% da variação na biomassa, superando os modelos tradicionais em 25% a 27%, particularmente em áreas de maior densidade de vegetação. Deste modo, as frequências verticais são importantes na representação da complexidade estrutural da floresta, contribuindo para estimativas mais precisas de biomassa acima do solo em ambientes de alta heterogeneidade florestal.

Esses resultados reforçam a necessidade de se utilizar uma abordagem mais

abrangente na construção de modelos de estimativa de biomassa, combinando métricas que capturam diferentes aspectos da estrutura florestal. No entanto, mesmo o modelo mais simples, baseado exclusivamente na altura máxima (Hmax), apresentou elevada precisão na estimativa da biomassa acima do solo em florestas tropicais secundárias.

A precisão dos modelos ajustados destaca a relevância do LiDAR-RPA para aprimorar o monitoramento florestal, especialmente em florestas tropicais secundárias, onde a variabilidade estrutural pode ser um desafio. Esse avanço é promissor para estratégias de manejo sustentável e para subsidiar políticas de mitigação das mudanças climáticas em escala local e regional. Os modelos desenvolvidos neste estudo podem ser úteis em estudos futuros, especialmente aqueles focados em escalas locais, sendo fundamental para reduzir a incerteza e aprimorar a confiabilidade das estimativas.

4.3 Modelagem de AGB com dados LiDAR e hiperespectrais

A combinação de dados LiDAR e hiperespectrais tem sido amplamente reconhecida como uma abordagem promissora para a modelagem de AGB, combinando informações estruturais e bioquímicas da vegetação (Almeida *et al.*, 2019; Almeida *et al.*, 2020; Ferreira *et al.*, 2024). No presente estudo, a integração dessas duas fontes de dados resultou em melhoria na estimativa em relação aos modelos baseados exclusivamente em LiDAR.

Entre os dois modelos avaliados, apenas o modelo integrado LiDAR + hiperespectral com três variáveis apresentou um desempenho superior ao modelo correspondente baseado exclusivamente em LiDAR, com um R^2 de 0,93 e um RMSE (%) de 30,92% na etapa de validação, em comparação com R^2 de 0,92 e RMSE (%) de 34,61% no modelo LiDAR. Apesar do ganho, a melhoria foi mínima, indicando que, embora as métricas hiperespectrais possam fornecer informações complementares, o impacto na precisão das estimativas foi limitado.

De acordo com Li *et al.* (2010), vegetações de sucessão florestal são sistemas ecológicos complexos, compostos por diversas espécies de plantas em configurações de povoamento distintas, cada uma apresentando uma estrutura biofísica própria. No presente estudo, essa heterogeneidade estrutural pode ter influenciado a capacidade das métricas hiperespectrais de capturar padrões consistentes relacionados à biomassa, reforçando o papel das métricas estruturais derivadas de LiDAR como preditores mais robustos em paisagens sucessionais.

Estudos anteriores, como o de Clark *et al.* (2011), realizado em uma floresta tropical úmida na Costa Rica, mostraram que a inclusão de dados hiperespectrais não contribuiu

significativamente para aprimorar os modelos de estimativa de biomassa. Segundo os autores, um dos fatores que pode ter influenciado esse desempenho foi a fenologia foliar, já que diversas espécies de árvores do dossel estavam perdendo folhas ou sem folhas durante o período de aquisição dos dados hiperespectrais. Dessa forma, o tempo e os custos adicionais associados à aquisição e ao processamento desses dados não se justificaram no contexto avaliado.

Resultados semelhantes foram encontrados por Laurin *et al.* (2014) ao estudar uma floresta tropical na África Ocidental, onde a integração de métricas hiperespectrais aos modelos baseados em LiDAR resultou em um aumento modesto da precisão, com o R^2 passando de 0,64 para 0,70 e RMSE diminuindo de 67,8 $Mg \cdot ha^{-1}$ para 61,7 $Mg \cdot ha^{-1}$. De forma similar, no estudo de Luo *et al.* (2017), conduzido em uma floresta na China, a fusão de dados LiDAR e hiperespectrais resultou em uma melhoria discreta, com um incremento de 1,39% na precisão da estimativa de AGB.

Esses resultados reforçam que, embora a integração de diferentes fontes de dados possa agregar informações complementares, seu impacto na modelagem da biomassa depende do contexto ecológico, das métricas selecionadas e das condições dos dados adquiridos. Em ambos os estudos, os sensores hiperespectrais operaram em faixas espectrais entre 380 nm e 1050 nm, com variações entre os trabalhos: Laurin *et al.* (2014) utilizaram um intervalo de 400 a 900 nm, enquanto Luo *et al.* (2017) empregaram uma faixa mais ampla, de 380 a 1050 nm. No presente estudo, os dados hiperespectrais abrangeram comprimentos de onda entre 397 e 1002 nm.

Por outro lado, estudos que empregaram sensores com faixas espectrais mais amplas demonstraram ganhos mais expressivos na estimativa de biomassa. Almeida *et al.* (2019), por exemplo, utilizaram dados hiperespectrais abrangendo 460 a 2330 nm para estimar a AGB em florestas da Amazônia, obtendo melhorias de até 15% no RMSE dos modelos que combinaram dados LiDAR e hiperespectrais, em comparação com modelos individuais. Esses resultados sugerem que o uso de comprimentos de onda mais longos, como os do infravermelho de ondas curtas (SWIR), pode ampliar a capacidade de estimar a biomassa, tornando a integração de dados espectrais mais eficaz (Almeida *et al.*, 2019; Psomas *et al.*, 2011).

O desempenho modesto dos modelos que integraram dados hiperespectrais indica que a eficácia da fusão de dados depende do contexto ecológico em que são aplicados. A contribuição dos dados hiperespectrais para a estimativa de biomassa tende a ser mais significativa em cenários onde as métricas estruturais derivadas do LiDAR apresentam correlações mais fracas com a biomassa. Nesses casos, as informações espectrais podem

complementar as variáveis estruturais, reduzindo incertezas e melhorando a precisão dos modelos. Estudos anteriores também apontam que a integração de dados hiperespectrais é mais vantajosa quando a relação entre LiDAR e biomassa não é suficientemente forte, permitindo que as métricas espectrais acrescentem informações relevantes à modelagem (Anderson *et al.*, 2008; Swatantran *et al.*, 2011).

5 CONCLUSÕES

A integração de dados hiperespectrais e LiDAR resultou em melhorias mínimas na estimativa da biomassa acima do solo (AGB). Embora o modelo combinado tenha apresentado desempenho levemente superior, os ganhos em precisão foram pouco expressivos, o que indica que a combinação das fontes de dados nem sempre representa um avanço substancial.

Ainda assim, o sensoriamento remoto ativo, representado pelo LiDAR, é mais adequado para a estimativa de AGB do que os dados hiperespectrais, embora estes também tenham apresentado desempenho satisfatório quando utilizados isoladamente. No entanto, é importante considerar também os aspectos operacionais envolvidos: sensores hiperespectrais do tipo *push-broom* geralmente exigem maior complexidade na aquisição dos dados e etapas de processamento mais intensas, o que pode representar uma limitação prática em relação ao LiDAR.

Entre as métricas LiDAR analisadas, altura máxima, percentis de altura e amplitude derivada da transformada de Fourier foram as mais relevantes para a modelagem de AGB. A altura máxima esteve presente em todos os modelos ajustados. Além disso, as métricas de amplitude de Fourier capturaram padrões estruturais em diferentes escalas verticais, permitindo uma melhor estimativa da biomassa.

Considerando esses aspectos, a utilização de dados LiDAR isolados foram suficientes para produzir estimativas confiáveis de AGB, sem a necessidade de integração com informações espectrais. Para maximizar a contribuição dos dados hiperespectrais em estudos futuros, é fundamental considerar a inclusão de comprimentos de onda mais amplos, como os do SWIR, especialmente em cenários onde as métricas estruturais apresentam menor correlação com a biomassa.

6 REFERÊNCIAS

ACHIM, A.; MOREAU, G.; COOPS, N. *et al.* The changing culture of silviculture. **Forestry**, v. 95, n. 2, p. 143-152, 2022.

ALMEIDA, C. T. *et al.* Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v. 232, p. 111323, out. 2019.

ALMEIDA, D. R. A. *et al.* Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. **Remote Sensing of Environment**, v. 264, p. 112582, out. 2021.

ANDERSON, J. *et al.* Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. **Remote Sensing of Environment**, v. 112, n. 4, p. 1856–1870, 15 abr. 2008.

ASNER, G. P.; MARTIN, R. E.; ANDERSON, C. B.; KNAPP, D. E. Quantifying forest canopy traits: Imaging spectroscopy versus field survey. **Remote Sensing of Environment**, v. 158, p. 15–27, 2015.

CALDERS, K.; NEWNHAM, G.; BURT, A.; MURPHY, S.; RAUMONEN, P.; HEROLD, M.; CULVENOR, D.; AVITABILE, V.; DISNEY, M.; ARMSTON, J.; KAASALAINEN, M. Nondestructive estimates of above-ground biomass using terrestrial laser scanning. **Methods in Ecology and Evolution**, v. 6, n. 2, p. 198–208, 2015.

CAO, L. *et al.* Integrating Airborne LiDAR and Optical Data to Estimate Forest Aboveground Biomass in Arid and Semi-Arid Regions of China. **Remote Sensing**, v. 10, n. 4, p. 532, 30 mar. 2018.

CHEN, Q. *et al.* Integration of airborne lidar and vegetation types derived from aerial photography for mapping aboveground live biomass. **Remote Sensing of Environment**, v. 121, p. 108–117, jun. 2012.

CLARK, M. L. *et al.* Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931–2942, nov. 2011.

CloudCompare [GPL software]. (2023). Retrieved from <http://www.cloudcompare.org/>

COOPS, N. C. *et al.* Modelling lidar-derived estimates of forest attributes over space and time: A review of approaches and future trends. **Remote Sensing of Environment**, v. 260, p. 112477, jul. 2021.

D'OLIVEIRA, M. V. N. *et al.* Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479–491, set. 2012.

DRAKE, J. B. *et al.* Estimation of tropical forest structural characteristics using large-footprint lidar. **Remote Sensing of Environment**, v. 79, n. 2–3, p. 305–319, fev. 2002.

EHLERS, D. *et al.* Mapping Forest Aboveground Biomass Using Multisource Remotely Sensed Data. **Remote Sensing**, v. 14, n. 5, p. 1115, 24 fev. 2022.

ELZHOV, T. V.; MULLEN, K. M.; SPIESS, A.-N.; BOLKER, B. **minpack.lm: R Interface to the Levenberg-Marquardt Nonlinear Least-Squares Algorithm Found in MINPACK, Plus Support for Bounds**. R package versão 1.2-4, 2023. Disponível em: <https://CRAN.R-project.org/package=minpack.lm>.

FAGUA, J. C.; JANTZ, P.; RODRIGUEZ-BURITICA, S.; DUNCANSON, L.; GOETZ, S. J. Integrating LiDAR, Multispectral and SAR Data to Estimate and Map Canopy Height in Tropical Forests. **Remote Sensing**, v. 11, n. 22, p. 2697, 2019.

FERRAZ, R.S.; SOUZA, S.F.; REIS, M.L.L. Laser scanner terrestre: teoria, aplicações e prática. **Revista Brasileira de Geomática** [online] 4, 2016.

FERREIRA, M. P. *et al.* Estimating aboveground biomass of tropical urban forests with UAV-borne hyperspectral and LiDAR data. **Urban Forestry & Urban Greening**, v. 96, p. 128362, jun. 2024.

GARCIA, M. *et al.* Impact of data model and point density on aboveground forest biomass estimation from airborne LiDAR. **Carbon Balance and Management**, v. 12, n. 1, 15 fev. 2017.

GEOSLAM. **ZEB Horizon: The Ultimate Mobile Mapping Solution**. Disponível em: <<https://geoslam.com/solutions/zeb-horizon/>>. Acesso em: 20 set. 2022.

GOETZ, S.; DUBAYAH, R. Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. **Carbon Management**, v. 2, n. 3, p. 231-244, 2011.

GONÇALVES, F. G. **Vertical structure and aboveground biomass of tropical forests from lidar remote sensing**. Tese (Doctor of Philosophy in Forest Science). 2014.

GUARIZ, H. R; GUARIZ, F. R. Avaliação do tamanho e forma de fragmentos florestais por meio de métricas de paisagem para o Município de São Roque do Canaã, Noroeste do Estado do Espírito Santo. **Revista Brasileira de Geografia Física**, v. 13, n. 5, p. 2139-2153, 2020.

GUPTA, R.; SHARMA, L. K. Mixed tropical forests canopy height mapping from spaceborne LiDAR GEDI and multisensor imagery using machine learning models. **Remote Sensing Applications: Society and Environment**, v. 27, p. 100817, 2022.

HUANG, W.; MIN, W.; DING, J.; LIU, Y.; HU, Y.; NI, W.; SHEN, H. Forest height mapping using inventory and multi-source satellite data over Hunan Province in southern China. **Forest Ecosystems**, v. 9, p. 100006, 2022.

JING, L. *et al.* Vegetation Information Extraction of Pinus Massoniana Forest in Soil Erosion Areas Using Soil-adjusted Vegetation Index. **Journal of Geo-information Science**, v. 17, n. 9, p. 1128–1134, 2015.

JUBANSKI, J. *et al.* Detection of large above-ground biomass variability in lowland forest ecosystems by airborne LiDAR. **Biogeosciences**, v. 10, n. 6, p. 3917–3930, 17 jun. 2013.

KC, Y. B. *et al.* Estimation of Above-Ground Forest Biomass in Nepal by the Use of Airborne

LiDAR, and Forest Inventory Data. **Land**, v. 13, n. 2, p. 213, 8 fev. 2024.

KURSA, M. B.; RUDNICKI, W. R. Feature Selection with the Boruta Package. **Journal of Statistical Software**, v. 36, n. 11, p. 1–13, 2022.

LAURIN, G. V. *et al.* Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 49–58, mar. 2014.

LI, H. *et al.* A framework for creating and validating a non-linear spectrum-biomass model to estimate the secondary succession biomass in moist tropical forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 2, p. 241–254, mar. 2010.

LI, M. *et al.* Forest Biomass and Carbon Stock Quantification Using Airborne LiDAR Data: A Case Study Over Huntington Wildlife Forest in the Adirondack Park. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 7, p. 3143–3156, jul. 2014.

LIM, K. S.; TREITZ, P. M. Estimation of above ground forest biomass from airborne discrete return laser scanner data using canopy-based quantile estimators. **Scandinavian Journal of Forest Research**, v. 19, n. 6, p. 558–570, dez. 2004.

LU, D. *et al.* A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63-105, 2016.

LU, D. *et al.* Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. **International Journal of Forestry Research**, v. 2012, p. 1–16, 2012.

LUO, S. *et al.* Fusion of airborne LiDAR data and hyperspectral imagery for aboveground and belowground forest biomass estimation. **Ecological Indicators**, v. 73, p. 378–387, fev. 2017.

MARTINS-NETO, R. P. *et al.* Tree Species Classification in a Complex Brazilian Tropical Forest Using Hyperspectral and LiDAR Data. **Forests**, v. 14, n. 5, p. 945, 4 maio 2023.

MCGAUGHEY, R. J. **FUSION/LDV: Software for LiDAR Data Analysis and Visualization; Version 3.30.** U.S. Department of Agriculture Forest Service, Pacific Northwest Research Station, University of Washington, Seattle, WA, USA, 2018. Disponível em: <http://forsys.cfr.washington.edu/fusion/fusionlatest.html>.

MITTERMEIER, R. A. *et al.* **Hotspots Revisited: Earth's Biologically Richest and Most Endangered Ecoregions.** 1 ed. Mexico: CEMEX, 2004.

MYERS, N. *et al.* Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, fev. 2000.

NÆSSET, E. Airborne laser scanning as a method in operational forest inventory: Status of accuracy assessments accomplished in Scandinavia. **Scandinavian Journal of Forest Research**, v. 22, n. 5, p. 433–442, out. 2007.

NÆSSET, E. Estimating above-ground biomass in young forests with airborne laser

- scanning. **International Journal of Remote Sensing**, v. 32, n. 2, p. 473–501, 2 fev. 2011.
- NELSON, R. F. *et al.* Investigating RaDAR–LiDAR synergy in a North Carolina pine forest. **Remote Sensing of Environment**, v. 110, n. 1, p. 98–108, set. 2007.
- NEWNHAM, G.; ARMSTON, J.; MUIR, J.; GOODWIN, N.; TINDALL, D.; CULVENOR, D.; PÜSCHEL, P.; NYSTRÖM, M.; JOHANSEN, K. **Evaluation of Terrestrial Laser Scanners for Measuring Vegetation Structure**. Austrália: CSIRO, 2012.
- OMAR, H.; MISMAN, M. A.; LEONG, Y. T. Quantifying aboveground biomass over 50-ha tropical forest dynamic plot in Pasoh, Malaysia using LiDAR and census data. **Borneo Science | The Journal of Science and Technology**, v. 41, n. 2, 10 jul. 2023.
- PENG, X. *et al.* Comparison of Modeling Algorithms for Forest Canopy Structures Based on UAV-LiDAR: A Case Study in Tropical China. **Forests**, v. 11, n. 12, p. 1324, 14 dez. 2020.
- PSOMAS, A. *et al.* Hyperspectral remote sensing for estimating aboveground biomass and for exploring species richness patterns of grassland habitats. **International Journal of Remote Sensing**, v. 32, n. 24, p. 9007-9031, 2011.
- R CORE TEAM. **RStudio: Integrated Development Environment for R**. RStudio, PBC, Boston, MA, 2023. Disponível em: <http://www.rstudio.com/>.
- RICHTER, R.; REU, B.; WIRTH, C.; DOKTOR, D.; VOHLAND, M. The use of airborne hyperspectral data for tree species classification in a species-rich Central European forest area. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 464–474, 2016.
- ROTH, K. L.; ROBERTS, D. A.; DENNISON, P. E.; PETERSON, S. H.; ALONZO, M. The impact of spatial resolution on the classification of plant species and functional types within imaging spectrometer data. **Remote Sensing of Environment**, v. 171, p. 45–57, 2015.
- ROUSSEL, J.-R. *et al.* lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, p. 112061, 2021.
- SANTOS, A. R. dos *et al.* Fuzzy concept applied in determining potential forest fragments for deployment of a network of ecological corridors in the Brazilian Atlantic Forest. **Ecological Indicators**, v. 115, p. 106423, ago. 2020.
- SFB – Serviço Florestal Brasileiro. **Florestas naturais**. 2020. Disponível em: <https://snif.florestal.gov.br/pt-br/os-biomas-e-suas-florestas>. Acesso em: 17 jul. 2023.
- SILVEIRA, E. M. O. *et al.* Modelling aboveground biomass in forest remnants of the Brazilian Atlantic Forest using remote sensing, environmental and terrain-related data. **Geocarto International**, v. 36, n. 3, p. 281-298, 2021.
- SIMONELLI, M; MARTINS, S. V.; SARTORI, M; RAPOSO FILHO, F. L.; DADALTO, G.; PEREIRA, M. L. **Levantamento do potencial de regeneração natural de florestas nativas nas diferentes regiões do estado do Espírito Santo**. 1. ed. Vitória: Edifes, 2021.
- SOTHE, Camile *et al.* Tree species classification in a highly diverse subtropical forest

integrating UAV-based photogrammetric point cloud and hyperspectral data. **Remote Sensing**, v. 11, n. 11, p. 1338, 2019.

SWATANTRAN, A. *et al.* Mapping biomass and stress in the Sierra Nevada using lidar and hyperspectral data fusion. **Remote Sensing of Environment**, v. 115, n. 11, p. 2917–2930, nov. 2011.

THAKUR, T. K. *et al.* Assessment of land use dynamics and vulnerability to land degradation in coal-mined landscapes of central India: implications for ecorestoration strategies. **Frontiers in Environmental Science**, v. 12, p. 1419041, 2024.

THEOBALD, D. M. *et al.* Global extent and change in human modification of terrestrial ecosystems from 1990 to 2022. **bioRxiv**, p. 2025.01.12.632633, 2025.

TREUHAFT, R. *et al.* Relationships between remotely sensed forest structure and biomass: Fourier structure from LiDAR and InSAR and penetration at microwave frequencies. **Revista Brasileira de Cartografia**, v. 65, n. 4, 24 ago. 2013.

TREUHAFT, R. N. *et al.* Biomass estimation in a tropical wet forest using Fourier transforms of profiles from lidar or interferometric SAR. **Geophysical Research Letters**, v. 37, n. 23, dez. 2010.

TREUHAFT, R. N. *et al.* Vegetation profiles in tropical forests from multibaseline interferometric synthetic aperture radar, field, and lidar measurements. **Journal of Geophysical Research: Atmospheres**, v. 114, n. D23, 15 dez. 2009.

USTIN, S. L.; ROBERTS, D. A.; GAMON, J. A.; ASNER, G. P.; GREEN, R. O. Using Imaging Spectroscopy to Study Ecosystem Processes and Properties. **BioScience**, v. 54, n. 6, p. 523–534, 2004.

WANG, J.; SHI, T.; YU, D.; TENG, D.; GE, X.; ZHANG, Z.; YANG, X.; WANG, H.; WU, G. Ensemble machine-learning-based framework for estimating total nitrogen concentration in water using drone-borne hyperspectral imagery of emergent plants: A case study in an arid oasis, NW China. **Environmental Pollution**, v. 266, p. 115412, 2020.

WANG, X.; JIAO, H. Spatial Scaling of Forest Aboveground Biomass Using Multi-Source Remote Sensing Data. **IEEE Access**, v. 8, p. 178870–178885, 2020. Acesso em: 6 fev. 2025.

WHITE, J. C. *et al.* A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. **The Forestry Chronicle**, v. 89, n. 06, p. 722–723, dez. 2013.

ZHANG, W. *et al.* An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. **Remote Sensing**, v. 8, n. 6, p. 501, 15 jun. 2016.

ZHANG, Xiaofang *et al.* Forest above-ground biomass estimation based on strongly collinear variables derived from airborne laser scanning data. **Ecological Indicators**, v. 166, p. 112517, set. 2024.

ZHANG, Xiaoli *et al.* Improved random forest algorithms for increasing the accuracy of forest aboveground biomass estimation using Sentinel-2 imagery. **Ecological Indicators**, v. 159,

p. 111752, fev. 2024.

ZHEN, Z. *et al.* Using the Negative Soil Adjustment Factor of Soil Adjusted Vegetation Index (SAVI) to Resist Saturation Effects and Estimate Leaf Area Index (LAI) in Dense Vegetation Areas. **Sensors**, v. 21, n. 6, p. 2115, 17 mar. 2021.

ZOLKOS, S. G.; GOETZ, S. J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. **Remote Sensing of Environment**, v. 128, p. 289–298, jan. 2013.

7 CONSIDERAÇÕES FINAIS

A caracterização da vegetação e a estimativa de AGB são fundamentais para compreender a sucessão florestal e aprimorar estratégias de monitoramento e conservação. Este estudo investigou o potencial do sensoriamento remoto hiperespectral e LiDAR, analisando como resolução espacial e sombreamento afetam a distinção dos estágios sucessionais e como a integração dessas fontes de dados influencia a predição da biomassa.

As hipóteses formuladas foram amplamente corroboradas. As métricas espectrais apresentaram forte correlação com a AGB, especialmente aquelas associadas às regiões do Red Edge e do infravermelho próximo (NIR), que se mostraram sensíveis às variações estruturais da vegetação ao longo do gradiente sucessional. A presença de sombras reduziu a reflectância, confirmando seu efeito sobre a resposta espectral. Por outro lado, a redução da resolução espacial, dentro dos limites avaliados (0,5 m e 5 m), não comprometeu a precisão das estimativas. O melhor desempenho foi obtido com resolução de 5 m e com a presença de pixels sombreados, sugerindo que, em determinados contextos, resoluções ligeiramente mais baixas podem atenuar a variabilidade espectral indesejada associada à heterogeneidade do dossel.

Esses achados abrem espaço para reflexões importantes sobre a viabilidade de realizar o “downgrade” para sensores multiespectrais e/ou com resolução espacial mais grosseira, sem comprometer significativamente a precisão das estimativas. Como as bandas mais relevantes situam-se em faixas espectrais comuns a sensores multiespectrais, como o Red Edge e o NIR, a substituição de sensores hiperespectrais por sistemas multiespectrais de alta resolução, mais acessíveis operacionalmente, pode ser considerada para aplicações práticas, tanto na estimativa de biomassa quanto na caracterização dos estágios sucessionais.

Adicionalmente, a integração de dados hiperespectrais e LiDAR resultou em ganhos

discretos na predição da AGB, sendo que os dados LiDAR, isoladamente, já se mostraram suficientes para fornecer estimativas robustas. Estudos futuros devem explorar a inclusão de faixas espectrais mais amplas, como o infravermelho de ondas curtas (SWIR), e avaliar o desempenho de modelos não lineares e métodos de aprendizado de máquina na modelagem da AGB. Tais abordagens podem aprimorar a modelagem da AGB e permitir uma avaliação mais abrangente do potencial da integração entre diferentes fontes de dados em contextos florestais tropicais.

8 APÊNDICES

APÊNDICE A – Características topográficas das parcelas por estágio sucessional obtidas por meio de dados LiDAR.

Estágio	Parcela	Altitude (m)			Declividade (%)
		Mín.	Média	Máx.	
Clean Pasture (CP)	1	125,81	127,65	129,35	11,36
	2	134,25	136,46	138,65	13,64
	3	128,34	132,36	135,38	20,80
	4	132,31	135,47	139,09	18,68
	5	133,85	136,39	138,16	14,13
Sparse Dirty Pasture (SDP)	6	138,47	143,39	149,86	28,43
	7	129,55	132,87	135,82	26,68
	8	139,41	146,82	156,36	25,55
	9	153,94	163,24	171,74	43,52
	10	141,65	146,21	153,75	28,41
Dirty Dense Pasture (DDP)	11	177,33	187,50	194,95	45,64
	12	160,34	176,06	192,62	49,53
	13	129,05	136,55	147,28	45,8
	14	149,01	163,14	175,32	52,72
Initial Stage Secondary Vegetation (ISV)	15	186,20	200,56	210,53	54,14
	16	175,82	183,13	190,39	43,52
	17	194,98	204,78	214,53	47,27
	18	175,78	189,99	203,61	59,42
Medium Stage Secondary Vegetation (MSV)	19	183,67	187,88	194,46	28,52
	20	153,11	158,66	162,94	24,28
	21	157,06	162,75	168,76	33,63
	22	56,13	65,97	76,78	51,02
	23	122,20	129,69	137,65	44,33
Advanced Stage Secondary Vegetation (ASV)	24	102,57	104,02	106,26	20,45
	25	99,37	102,13	106,84	19,67
	26	91,88	103,02	112,54	50,43
	27	118,02	126,88	134,55	45,72
	28	89,76	106,95	122,88	62,49
	29	101,20	103,06	107,83	20,78
	30	82,26	86,62	90,51	26,70

APÊNDICE B – Índices de vegetação utilizados nas análises.

Código	Índice	Equação	Referência
C1	Chlorophyll Index 1	$(\rho_{850} - \rho_{710}) / (\rho_{850} + \rho_{680})$	(Datt, 1999)
C2	Chlorophyll Index 2	ρ_{750} / ρ_{700}	(Datt, 1999)
ACI1	Anthocyanin content index 1	$\text{sum}(\rho_{600}:\rho_{700}) / \text{sum}(\rho_{500}:\rho_{600})$	(Gamon; Surfus, 1999)
ACI2	Anthocyanin content index 2	ρ_{650} / ρ_{550}	(Gamon; Surfus, 1999)
PSI	Plant Stress Index	ρ_{695} / ρ_{760}	(Carter; Miller, 1994)
SL	Slope of red-edge Normalized Difference	$(\rho_{740} - \rho_{690}) / (N_{740} - 690)$	(Merton, 1999)
NDVI	Vegetation Index	$(\rho_{800} - \rho_{670}) / (\rho_{800} + \rho_{670})$	(Rouse <i>et al.</i> , 1974)
PRI	Photochemical Reflectance Index	$(\rho_{529} - \rho_{570}) / (\rho_{529} + \rho_{570})$	(Gamon <i>et al.</i> , 1992)
MEAN	Average reflectance between 690 nm to 740 nm	$\sum_{i=690}^{i=740} \rho_i / N$	(Merton, 1999)
MEDIAN	Median reflectance between 690 nm to 740 nm	$\text{median} \sum_{i=690}^{i=740} \rho_i$	(Merton, 1999)
RVSI	Red-edge Vegetation Stress Index	$(\rho_{714} + \rho_{752}) / 2 - \rho_{733}$	(Merton, 1999)
R1	Ratio Vegetation Stress Index	ρ_{694} / ρ_{760}	(Carter; Miller, 1994)
R2	Ratio Vegetation Stress Index	ρ_{600} / ρ_{760}	(Carter; Miller, 1994)
R3	Ratio Vegetation Stress Index	ρ_{710} / ρ_{760}	(Carter; Miller, 1994)
PSSR1	Pigment Specific Simple Ratio 1	ρ_{800} / ρ_{680}	(Blackburn, 1998)
PSSR2	Pigment Specific Simple Ratio 2	ρ_{800} / ρ_{635}	(Blackburn, 1998)
WBI	Water Band Index Vegetation Atmospherically	ρ_{970} / ρ_{900}	(Peñuelas <i>et al.</i> , 1993)
VARI	Resistant Index	$(\rho_{557} - \rho_{643}) / (\rho_{557} + \rho_{643} - \rho_{465})$	(Gitelson <i>et al.</i> , 2002)
SR	Simple Ratio Normalized Difference	ρ_{797} / ρ_{680}	(Jordan, 1969)
NDVI 2	Vegetation Index 2	$(\rho_{800} - \rho_{670}) / (\rho_{800} + \rho_{670})$ $2.5 (\rho_{797} - \rho_{673}) / (\rho_{797} + 6 * \rho_{673}$	(Rouse <i>et al.</i> , 1974)
EVI	Enhanced Vegetation Index Structurally Insensitive Pigment	$- 7.5 * \rho_{474} + 1)$	(Huete <i>et al.</i> , 2002)
SIPI	Index Chlorophyll Absorption in	$(\rho_{800} - \rho_{445}) / (\rho_{800} + \rho_{680})$	(Peñuelas <i>et al.</i> , 1995)
CARI	Reflectance Index	$(\rho_{700} - \rho_{670}) - 0.2 * (\rho_{700} - \rho_{550})$	(Kim, 1994)
CI.rededge	Chlorophyll Red-Edge Index	$\rho_{851} / \rho_{730} - 1$	(Gitelson <i>et al.</i> , 2006)

CI.green	Chlorophyll Green Index Modified Anthocyanin	$\rho_{730} / \rho_{531-1}$	(Gitelson <i>et al.</i> , 2006)
mARI	Reflectance Index	$(1 / \rho_{551}) - (1 / \rho_{701})$	(Gitelson <i>et al.</i> , 2006) (van den Berg; Perkins, 2005)
ACI	Anthocyanin Content Index	ρ_{531} / ρ_{941}	(Gitelson <i>et al.</i> , 2007)
CRI	Carotenoid Reflectance Index	$(1/\rho_{511}) - (1/\rho_{551})$	(Gamon <i>et al.</i> , 1997)
PRI2	Photochemical Reflectance Index	$(\rho_{531} - \rho_{571}) / (\rho_{531} + \rho_{571})$	(Merton; Huntington, 2021)
RVSI2	Red-edge Vegetation Stress Index	$(\rho_{712} + \rho_{753}) / 2 - \rho_{733}$ $((\rho_{800} - \rho_{671}) / (\rho_{800} + \rho_{671} +$	(Huete, 1988)
SAVI	Soil Adjusted Vegetation Index	$0.5)) * (1 + 0.5)$	

Legenda: ρ = Reflectância.

APÊNDICE C – Teste t pareado considerando as diferentes posições cardeais.

Posições cardeais	Posição central			
	Green (501 - 600 nm)	Red Edge (690 - 740 nm)	NIR (741 - 1002 nm)	NDVI
Norte	0.8649 ^{ns}	0.6841 ^{ns}	0.646 ^{ns}	0.7013 ^{ns}
Sul	0.5927 ^{ns}	0.702 ^{ns}	0.679 ^{ns}	0.8517 ^{ns}
Leste	0.8091 ^{ns}	0.8143 ^{ns}	0.6459 ^{ns}	0.9532 ^{ns}
Oeste	0.9276 ^{ns}	0.8303 ^{ns}	0.7067 ^{ns}	0.8867 ^{ns}

Legenda: Teste t pareado com nível de significância de 5%. Os valores apresentados correspondem aos p-valores obtidos. “ns” indica ausência de significância estatística ($p > 0,05$).