

UFRRJ
INSTITUTO DE FLORESTAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS
AMBIENTAIS E FLORESTAIS

DISSERTAÇÃO

**Avaliação da diversidade e composição funcional na
Mata Atlântica por meio de imagens multiespectrais
obtidas com drone**

Júlia Ayres de Oliveira

2025



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS E
FLORESTAIS**

**AVALIAÇÃO DA DIVERSIDADE E COMPOSIÇÃO FUNCIONAL NA
MATA ATLÂNTICA POR MEIO DE IMAGENS MULTIESPECTRAIS
OBTIDAS COM DRONE**

JULIA AYRES DE OLIVEIRA

*Sob a Orientação do Professor
Jerônimo Boelsums Barreto Sansevero*

*e Co-orientação dos Professores
Gustavo Bastos Lyra e
Luiz Fernando Duarte de Moraes*

Dissertação submetida como requisito
parcial para obtenção do grau de **Mestre**
em Ciências Ambientais e Florestais,
no Programa de Pós-Graduação em
Ciências Ambientais e Florestais, Área
de Concentração em Conservação da
Natureza.

Seropédica, RJ
Fevereiro de 2025

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

048a Oliveira, Júlia Ayres de, 1997-
Avaliação da diversidade e composição funcional na
Mata Atlântica por meio de imagens multiespectrais
obtidas com drone / Júlia Ayres de Oliveira. -
Seropédica, 2025.
78 f.: il.

Orientador: Jerônimo Boelsums Barreto Sansevero.
Coorientador: Gustavo Bastos Lyra.
Coorientador: Luiz Fernando Duarte de Moraes.
Dissertação(Mestrado) . -- Universidade Federal
Rural do Rio de Janeiro, Programa de Pós-Graduação em
Ciências Ambientais e Florestais, 2025.

1. Biodiversidade. 2. Sensoriamento remoto. 3.
Aeronave Remotamente Pilotada. I. Sansevero, Jerônimo
Boelsums Barreto, 1980-, orient. II. Lyra, Gustavo
Bastos, 1975-, coorient. III. Moraes, Luiz Fernando
Duarte de, 1963-, coorient. IV Universidade Federal
Rural do Rio de Janeiro. Programa de Pós-Graduação em
Ciências Ambientais e Florestais. V. Título.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

This study was financed in part by de Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001.

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS E
FLORESTAIS**

JÚLIA AYRES DE OLIVEIRA

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em**
Ciências Ambientais e Florestais, no Programa de Pós-Graduação em Ciências Ambientais e
Florestais, área de Concentração em Conservação da Natureza.

DISSERTAÇÃO APROVADA EM 21/02/2025

Jerônimo Boelsums Barreto Sansevero. Prof. Dr. UFRRJ.
(Orientador)

Catherine Torres de Almeida. Dra. UNESP-Registro.

Eric Bastos Gorgens. Dr.UFVJM.

TERMO Nº 165/2025 - PPGCAF (12.28.01.00.00.00.00.27)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 17/03/2025 20:17)
JERONIMO BOELSUMS BARRETO SANSEVERO
PROFESSOR DO MAGISTERIO SUPERIOR
DeptCMB (12.28.01.00.00.00.00.29)
Matrícula: ####372#1

(Assinado digitalmente em 18/03/2025 07:53)
ERIC BASTOS GORGENS
ASSINANTE EXTERNO
CPF: ####.###.666-##

(Assinado digitalmente em 18/03/2025 08:45)
CATHERINE TORRES DE ALMEIDA
ASSINANTE EXTERNO
CPF: ####.###.467-##

Visualize o documento original em <https://sipac.ufrrj.br/documentos/> informando seu número: 165, ano: 2025, tipo: TERMO, data de emissão: 17/03/2025 e o código de verificação: 5871b37407

DEDICATÓRIA

A todos os professores e pesquisadores que me inspiraram, me incentivaram e me auxiliaram na busca pelo conhecimento, dedico.

AGRADECIMENTOS

Para ser sincera, entrar no mestrado não foi bem uma escolha. Os eventos determinísticos ou estocásticos me trouxeram até aqui e, embora com muitas dúvidas e receios, eu segui. O tema da minha pesquisa, por outro lado, foi uma escolha. Uma escolha, acredito eu, muito corajosa, dada toda dificuldade que tive com geotecnologias na graduação. Além da dificuldade, por muito tempo eu me questionei se tinha aptidão para fazer o que me propus a fazer: ser cientista. Confesso que ainda não sei, mas um trecho do livro “Cartas a um jovem cientista” de Edward O. Wilson me incentivou nessa profissão. Ele diz que sou necessária e que “a sobrevivência da humanidade no longo prazo depende de obter respostas para muitas perguntas relacionadas ao planeta onde moramos”. Neste trabalho, acho que consegui desbravar uma dessas possíveis perguntas, mas não o fiz sozinha. Tenho muitas pessoas a quem agradecer.

Primeiramente, agradeço o suporte da minha família. Meus pais, Elizabeth e Adimilson. Vendedora e frentista, respectivamente. Eles não têm ensino superior e não entendem muito bem o que estou fazendo no mestrado, mas me encorajaram e me apoiaram durante todo o processo. Seus passos abriram o caminho para que hoje eu pudesse ser mestre. Minhas irmãs, Juliana e Victória, quem me traz força e propósito.

Sem dúvidas, essa jornada não seria possível sem o meu orientador, Prof. Dr. Jerônimo Boelsums Barreto Sansevero, e os meus coorientadores, Prof. Dr. Gustavo Bastos Lyra e Prof. Dr. Luiz Fernando Duarte de Moraes. Muito além da orientação e da transmissão de conhecimentos, eles acreditaram em mim e me incentivaram constantemente. Cada um, à sua maneira, me inspira. O Prof. Jerônimo, com sua serenidade, me trouxe tranquilidade e calma nos momentos em que o desespero parecia tomar conta. O Prof. Gustavo, com seu entusiasmo, me impulsionou nos momentos de desânimo e me ensinou a redirecionar as frustrações. O Prof. Luiz Fernando, com sua sabedoria, me motivou a buscar mais aprendizado.

Agradeço profundamente a todos que me acompanharam nas campanhas de campo: Adilson Pintor, aquele que conhece a floresta como ninguém e me guiou em todas as coletas; Ângelo Mantovani, Heron Casati e Joaquim Sarmento, amigos que trabalharam muito e ainda aguentaram comer os sanduíches que eu preparava. Meus agradecimentos também à família do Prof. Jerônimo, Márcia e Flora, por me receberem com tanto carinho em sua casa após essas campanhas.

Agradeço aos amigos que me auxiliaram nas outras etapas: Ariani Dario, por toda ajuda com as análises químicas foliares; Ângelo Mantovani e Samuel Vilela, por compartilharem suas experiências com o QGis. Jorge Alonso, pela ajuda com o software R. A todos os outros amigos e amigas, pelo apoio, pela companhia nas disciplinas e eventos acadêmicos, e por tornarem os meus dias mais alegres.

Agradeço aos membros das bancas de qualificação, relatório anual e defesa final, Dra. Catherine Almeida, Dr. Eric Gorgens, Dr. André Quintão e Dra. Adriana Manhães, por contribuírem tanto com este trabalho. Todas as sugestões e as observações oferecidas foram fundamentais para o desenvolvimento e para a qualidade desta pesquisa.

Agradeço à Fundação de Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa que permitiu minha permanência no mestrado. À Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ), pelo financiamento. À Universidade Federal Rural do Rio de Janeiro (UFRRJ) e ao Programa de Pós-Graduação em Ciências Ambientais e Florestais (PPGCAF) pelo ensino público, gratuito e de qualidade. À Reserva Biológica de Poço das Antas e ao Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) pela autorização, espaço e alojamento. Por fim, agradeço ao Laboratório de Ecologia Aplicada (LEAp), ao Grupo de Modelagem Ambiental e Atmosférica (GMAAT) e à Embrapa Agrobiologia, por disponibilizarem infraestrutura e material, essenciais na execução desta pesquisa.

RESUMO

OLIVEIRA, Júlia A. **Avaliação da diversidade e composição funcional na Mata Atlântica por meio de imagens multiespectrais obtidas com drone.** 2025. 78p. Dissertação (Mestrado em Ciências Ambientais e Florestais). Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

A avaliação da diversidade funcional de florestas fornece importantes informações para compreender o funcionamento dos ecossistemas e as respostas das espécies frente às mudanças climáticas, além de servir como ferramenta de gestão em áreas em processo de restauração ecológica. No entanto, as medições em campo de atributos funcionais tendem a ser dispendiosas, enquanto o sensoriamento remoto oferece alternativas para o estudo da biodiversidade em maiores escalas e em menor tempo. O objetivo geral deste estudo foi utilizar imagens multiespectrais obtidas com drone para quantificar a composição funcional e a diversidade funcional e taxonômica em plantios de restauração ecológica baseados em distintas combinações de grupos sucessionais na Mata Atlântica, no estado do Rio de Janeiro. Os objetivos específicos foram quantificar a composição funcional e a diversidade funcional e taxonômica na escala de comunidade na área em processo de restauração ecológica; obter imagens multiespectrais com câmera embarcada em drone; analisar as relações entre os parâmetros de composição funcional e diversidade funcional e taxonômica medidos em campo e os índices de vegetação determinados com base nas imagens multiespectrais; ajustar e validar modelos estatísticos para quantificar a composição funcional e a diversidade funcional e taxonômica de áreas em processo de restauração na Mata Atlântica por meio de imagens multiespectrais. As hipóteses testadas foram: 1) As medidas de composição funcional e diversidade funcional e taxonômica são diferentes entre os tratamentos baseados em grupos sucessionais; 2) As medidas dos índices de vegetação obtidos com drone são diferentes entre os tratamentos baseados em grupos sucessionais; 3) As medidas dos índices de vegetação obtidos com drone são correlacionadas com as medidas de composição funcional e diversidade funcional e taxonômica. Além disso, foram avaliadas duas abordagens de ponderação dos dados de composição e diversidade funcional (abundância vs produto entre área de copa e altura) e duas abordagens de obtenção dos índices de vegetação (todos os pixels vs somente pixels iluminados). Nossos resultados indicaram que apenas duas medidas de composição funcional, as Médias Ponderadas (CWM) da Área Foliar e do Teor de Matéria Seca Foliar, e um índice de vegetação, a média do *Simple Ratio*, apresentam diferenças estatísticas significativas entre os tratamentos. Por outro lado, as correlações de Spearman entre os dados medidos em campo e os dados remotos variaram de -0,85 a 0,72. Os índices de diversidade funcional apresentaram maiores correlações quando ponderados pela abundância, enquanto as medidas de composição funcional apresentaram maiores correlações quando ponderadas pelo produto entre a área de copa e a altura. Os modelos de regressão lineares simples para a CWM do Fósforo Foliar alcançaram coeficientes de determinação (R^2) de até 0,69. Os modelos de regressão lineares múltiplos em função de dois ou mais índices de vegetação permitiram melhores ajustes, com o aumento considerável dos R^2 (até 0,81). Esta pesquisa reforça o potencial do sensoriamento remoto na avaliação dos componentes da biodiversidade, assim como evidencia desafios e limitações da abordagem aplicada. Acreditamos que os métodos e os modelos propostos poderão servir como base para novos estudos e contribuir para o avanço do conhecimento científico.

Palavras-chave: biodiversidade, sensoriamento remoto, aeronave remotamente pilotada

ABSTRACT

OLIVEIRA, Júlia A. **Assessment of functional diversity and composition in the Atlantic Forest using multispectral images obtained with drone.** 2025. 78p. Dissertation (Masters in Environmental and Forest Sciences). Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

The assessment of forest functional diversity provides important insights into ecosystem functioning and species responses to climate change, in addition to serving as a management tool for areas undergoing ecological restoration. However, field measurements of functional traits tend to be costly, while remote sensing offers alternatives for studying biodiversity on larger scales and in less time. The main objective of this study was to use multispectral images acquired with a drone to quantify functional composition as well as functional and taxonomic diversity in ecological restoration plantations based on different combinations of successional groups in the Atlantic Forest, in the state of Rio de Janeiro. The specific objectives were to quantify functional composition and functional and taxonomic diversity at the community scale in the area under ecological restoration; obtain multispectral images using a drone-mounted camera; analyze the relationships between functional composition and functional and taxonomic diversity parameters measured in the field and vegetation indices derived from multispectral images; and adjust and validate statistical models to quantify functional composition and functional and taxonomic diversity in restoration areas of the Atlantic Forest using multispectral images. The hypotheses tested were: (1) Functional composition and functional and taxonomic diversity metrics differ among treatments based on successional groups; (2) Vegetation index values obtained with a drone differ among treatments based on successional groups; (3) Vegetation index values obtained with a drone are correlated with functional composition and functional and taxonomic diversity metrics. Additionally, two weighting approaches for functional composition and diversity data (abundance vs. the product of canopy area and height) and two approaches for vegetation index extraction (all pixels vs. only sunlit pixels) were evaluated. Our results indicated that only two functional composition metrics, the Community Weighted Means (CWM) of Leaf Area and Leaf Dry Matter Content, and one vegetation index, the mean Simple Ratio, showed statistically significant differences among treatments. On the other hand, Spearman correlations between field-measured and remotely sensed data ranged from -0,85 to 0,72. Functional diversity indices showed higher correlations when weighted by abundance, while functional composition metrics showed higher correlations when weighted by the product of canopy area and height. Simple linear regression models for the CWM of Leaf Phosphorus achieved coefficients of determination (R^2) of up to 0,69. Multiple linear regression models based on two or more vegetation indices provided better fits, with a considerable increase in R^2 values (up to 0,81). This research reinforces the potential of remote sensing in assessing biodiversity components while also highlighting the challenges and limitations of the applied approach. We believe that the proposed methods and models can serve as a foundation for future studies and contribute to the advancement of scientific knowledge.

Keywords: biodiversity, remote sensing, remotely piloted aircraft

LISTA DE ABREVIAÇÕES E SÍMBOLOS

- A - Ponderado pela abundância.
- ACxH - Ponderado pelo produto entre área de copa e altura.
- AIC - Critério de Informação de Akaike (*Akaike Information Criterion*).
- ARP/RPA - Aeronave Remotamente Pilotada (*Remotely Piloted Aircraft*), também conhecida como drone.
- Aw (Köppen) - Clima tropical, com estação seca no inverno e chuvosa no verão.
- B - Reflectância proveniente do canal azul da região do visível.
- BNDVI - Índice de Diferença Normalizada Azul (*Blue Normalized Difference Vegetation Index*).
- C/C1 - Tratamento com espécies clímax.
- Cfoliar - Concentração foliar de carbono.
- ClRedEdge - Índice Red-Edge de Clorofila (*Chlorophyll Red-Edge Index*).
- CWM – Média Ponderada da Comunidade (*Community Weighted Mean*).
- DAP - Diâmetro à altura do peito, medido a 1,30m.
- E - Equabilidade taxonômica.
- EVI - Índice de Vegetação Melhorado (*Enhanced Vegetation Index*).
- ExG - Índice de Excesso de Verde (*Excess Green Index*).
- FDis - Dispersão funcional (*Functional dispersion*).
- FDiv - Divergência funcional (*Functional divergence*).
- FEve - Equabilidade funcional (*Functional evenness*).
- FRic - Riqueza funcional (*Functional richness*).
- G - Reflectância proveniente do canal verde da região do visível.
- GNDVI - Índice de Diferença Normalizada Verde (*Green Normalized Difference Vegetation Index*).
- GNSS - Sistema Global de Navegação por Satélite (*Global Navigation Satellite System*).
- H - Altura total.
- H - Estatística de teste do Kruskal-Wallis.
- H' - Índice de Shannon-Weaver.
- HVE - Hipótese da Variação Espectral.
- IVs - Índices espectrais de vegetação.
- LA - Área Foliar (*Leaf Area*).
- LASSO - Operador de Encolhimento e Seleção Absoluta Mínima (*Least Absolute Shrinkage and Selection Operator*).
- LDMC - Teor de Matéria Seca Foliar (*Leaf Dry Matter Content*).
- MTR - Modelos de Transferência Radiativa.

NDRE - Índice de Diferença Normalizada da Borda Vermelha (*Normalized Difference Red Edge*).

NDVI - Índice de Diferença Normalizada de Vegetação (*Normalized Difference Vegetation Index*).

Nfoliar - Concentração foliar de nitrogênio.

NGRDI - Índice de Diferença Normalizada Verde-Vermelho (*Normalized Green Red Difference Index*).

NIR - Reflectância proveniente do canal do infravermelho próximo.

NLI - Índice Não Linear (*No Linear Index*).

P/Pi - Tratamento com espécies pioneiras.

PC - Tratamento com espécies pioneiras e clímax.

PCA - Análise de Componentes Principais (*Principal Component Analysis*).

Pfoliar - Concentração foliar de fósforo.

PLSR - Regressão de Mínimos Quadrados Parciais (*Partial Least-Squares Regression*).

PSC - Pontos de Controle em Superfície.

PSC - Tratamento com espécies pioneiras, secundárias e clímax,

R - Reflectância proveniente do canal vermelho da região do visível.

R² - Coeficiente de determinação.

Rao - Entropia quadrática de Rao.

RBPA - Reserva Biológica de Poço das Antas.

RedEdge - Reflectância proveniente do canal da borda do vermelho.

S - Riqueza taxonômica.

S/Se - Tratamento com espécies secundárias.

SC - Tratamento com espécies secundárias e clímax.

SLA - Área Foliar Específica (*Specific Leaf Area*).

SR - Razão Simples (*Simple Ratio*).

TGI - Índice de Verdes Triangular (*Triangle Greenness Index*).

TWM - *Top-of-Canopy Weighted Mean*.

VDVI - Índice de Diferença de Vegetação Visível (*Visible Difference Vegetation Index*).

ρ - correlação de Spearman.

LISTA DE FIGURAS

- Figura 1.** As propriedades estruturais e bioquímicas das folhas regulam a quantidade de radiação incidente refletida, transmitida ou absorvida. Por exemplo, características da camada externa da folha, como presença de cera ou tricomas, influenciam a quantidade de radiação que é refletida e, por consequência, a quantidade de radiação penetrada na folha. Além disso, a espessura do mesófilo associada a outras propriedades provoca diferentes comportamentos de transmissão e absorção da radiação. Fonte: Adaptado de Serbin e Townsend, 2020.....5
- Figura 2.** Exemplo de um espectro de reflectância foliar. São mostradas as três principais regiões do espectro (visível, infravermelho próximo e infravermelho de ondas curtas), assim como as principais características químicas e estruturais das folhas que influenciam a reflectância, são elas: os pigmentos, a anatomia e a morfologia foliar, o teor de água e a composição química. As barras azuis indicam as características de absorção da água. VIS: Visível (entre 400 – 700nm); NIR: Infravermelho próximo (entre 700 a 1400 nm); SWIR: Infravermelho de onda curta (entre 1400 a 3000nm). Fonte: Adaptado de Kothari e Schweiger, 2022.6
- Figura 3.** A interação entre a radiação e as propriedades e estruturas químicas das folhas resultam em diferentes assinaturas espectrais entre distintos grupos filogenéticos. Dessa forma, os dados espectrais podem ser utilizados para estimar a biodiversidade. VIS: Visível (entre 400 – 700nm); NIR: Infravermelho próximo (entre 700 a 1400 nm); SWIR: Infravermelho de onda curta (entre 1400 a 3000nm). Fonte: Adaptado de Cavender-Bares et al., 2017.....6
- Figura 4.** Mapa da localização da Reserva Biológica de Poço das Antas, Silva Jardim, Rio de Janeiro, Brasil. Fonte: Elaborado pela autora, 2024.....9
- Figura 5.** Fluxograma metodológico para quantificar os atributos funcionais, a composição funcional e os índices de diversidade funcional e taxonômica na área de estudo. Fonte: Elaborado pela autora, 2024.....14
- Figura 6.** Ortofotomosaico produzido com as imagens levantadas no segundo voo, no dia 11 de novembro de 2024, na Reserva Biológica de Poço das Antas, Rio de Janeiro, Brasil. Os Pontos de Controle em Superfície são apresentados na cor vermelha. Fonte: Elaborado pela autora, 2024.16
- Figura 7.** Ortofotomosaico produzido com as imagens levantadas no primeiro voo, no dia 04 de abril de 2024, na Reserva Biológica de Poço das Antas, Rio de Janeiro, Brasil. Fonte: Elaborado pela autora, 2024.16
- Figura 8.** Representação da remoção dos pixels sombreados no ortofotomosaico. (A) Ortofotomosaico produzido a partir das imagens levantadas com sensor multiespectral; (B) Imagem gerada a partir da remoção dos pixels sombreados com classificação com algoritmo Random Forest. Fonte: Elaborado pela autora, 2024.17
- Figura 9.** Fluxograma metodológico para calcular os índices espectrais de vegetação com sensor multiespectral aerotransportado na área de estudo. Fonte: Elaborado pela autora, 2024.20
- Figura 10.** Fluxograma metodológico da análise dos dados obtidos em campo e remotamente. Fonte: Elaborado pela autora, 2024.....23
- Figura 11.** Boxplots das variáveis taxonômicas: Riqueza (S), Índice de Shannon-Weaver (H) e Equabilidade (E). Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem

significativamente entre si ($p > 0,05$) no teste de Conover. Fonte: Elaborado pela autora, 2024. 24

Figura 12. Boxplots das medidas de composição funcional ponderadas pela comunidade: Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Códigos: “A” = Ponderado pela abundância e “ACxH” = Ponderado pelo produto entre área de copa e altura. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$) no teste de Conover. Fonte: Elaborado pela autora, 2024. 25

Figura 13. Boxplots dos índices de diversidade funcional: Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), e Dispersão funcional (FDis). Códigos: “A” = Ponderado pela abundância e “ACxH” = Ponderado pelo produto entre área de copa e altura. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$) no teste de Conover. Fonte: Elaborado pela autora, 2024. 26

Figura 14. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “A” = Ponderado pela abundância. Fonte: Elaborado pela autora, 2024. 27

Figura 15. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “ACxH” = Ponderado pelo produto entre a área de copa e a altura. Fonte: Elaborado pela autora, 2024. 27

Figura 16. Análises de Componentes Principais. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “A” = Ponderado pela abundância. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024. 28

Figura 17. Análises de Componentes Principais. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “ACxH” = Ponderado pelo produto entre a área de copa e a altura. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.....29

Figura 18. Boxplot da média índice de vegetação *Simple Ratio* calculado com o ortofotomosaico original, contendo todos os pixels iluminados e sombreados. Código: “tp” = todos os pixels. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$). Fonte: Elaborado pela autora, 2024.....30

Figura 19. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “tp” = calculado a partir do ortofotomosaico com todos os pixels; “mean” = média, “stdev” = desvio-padrão. Fonte: Elaborado pela autora, 2024.....30

Figura 20. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; “mean” = média, “stdev” = desvio-padrão. Fonte: Elaborado pela autora, 2024.....31

Figura 21. Análises de Componentes Principais. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “tp” = Calculado a partir do ortofotomosaico com todos os pixels; “mean” = média, “stdev” = desvio-padrão. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.....32

Figura 22. Análises de Componentes Principais. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation*

Index (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “ss” = Calculado a partir do ortofotomosaico sem as sombras; “mean” = média, “stdev” = desvio-padrão. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.....33

Figura 23. Correlações de Spearman entre os valores de diversidade taxonômica, diversidade funcional e composição funcional medidos em campo e a média dos os índices de vegetação obtidos com drone. Códigos: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels. Os valores significativos são marcados com asteriscos ($p < 0.001$, “***”, $p < 0.01$, “**”, $p < 0.05$, “*”). Fonte: Elaborado pela autora, 2024.....34

Figura 24. Correlações de Spearman entre os valores de diversidade taxonômica, diversidade funcional e composição funcional medidos em campo e o desvio-padrão dos os índices de vegetação obtidos com drone. Códigos: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels. Os valores significativos são marcados com asteriscos ($p < 0.001$, “***”, $p < 0.01$, “**”, $p < 0.05$, “*”). Fonte: Elaborado pela autora, 2024.....35

Figura 25. Modelos de regressão linear simples entre a Riqueza Taxonômica (S) e a média do *Simple Ratio*, considerando tanto o índice obtido com todos os pixels (SR.tp.mean) quanto o obtido apenas com os pixels iluminados (SR.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado, a área sombreada indica o intervalo de confiança de 95%, e a cor azul indica que o modelo foi significativo ($p \leq 0,05$), enquanto a cor vermelha indica que o modelo não foi significativo ($p > 0,05$). Fonte: Elaborado pela autora, 2024.....36

Figura 26. Modelos de regressão linear simples entre o Índice de Shannon-Weaver (H) e a média do *Simple Ratio*, considerando tanto o índice obtido com todos os pixels (SR.tp.mean) quanto o obtido apenas com os pixels iluminados (SR.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.....37

Figura 27. Modelos de regressão linear simples entre a Dispersão Funcional ponderada pela abundância (FDis.A) e o desvio-padrão do *Normalized Difference Red Edge*, considerando tanto o índice obtido com todos os pixels (NDRE.tp.stdev) quanto o obtido apenas com os pixels iluminados (NDRE.ss.stdev). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.....37

Figura 28. Modelos de regressão linear simples entre a Divergência Funcional ponderada pela abundância (FDiv.A) e o desvio-padrão do *Normalized Difference Red Edge*, considerando tanto o índice obtido com todos os pixels (NDRE.tp.stdev) quanto o obtido apenas com os pixels iluminados (NDRE.ss.stdev). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.....38

Figura 29. Modelos de regressão linear simples entre a Média do Fósforo Foliar, ponderada pela abundância (CWM.Pfoliar.A) e ponderada pelo produto entre a área de copa e a altura (CWM.Pfoliar.ACxH), e a média do *Normalized Green Red Difference Index*, considerando tanto o índice obtido com todos os pixels (NGRDI.tp.mean) quanto o obtido apenas com os

pixels iluminados (NGRDI.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.....39

Figura 30. Modelos de regressão linear simples entre a Média do Teor de Matéria Seca Foliar, ponderada pela abundância (CWM.LDMC.A) e ponderada pelo produto entre a área de copa e a altura (CWM.LDMC.ACxH), e a média do *Normalized Difference Vegetation Index*, considerando tanto o índice obtido com todos os pixels (NDVI.tp.mean) quanto o obtido apenas com os pixels iluminados (NDVI.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado, a área sombreada indica o intervalo de confiança de 95%, e a cor azul indica que o modelo foi significativo ($p \leq 0,05$), enquanto a cor vermelha indica que o modelo não foi significativo ($p > 0,05$). Fonte: Elaborado pela autora, 2024.....40

LISTA DE TABELAS

Tabela 1. Lista de espécies plantadas por tratamento na área experimental. Tratamentos: Pi: espécies pioneiras; Se: espécies secundárias; Cl: espécies clímax; SC: espécies secundárias tardias e clímax; PC: espécies pioneiras e clímax; PSC: espécies de todos os grupos ecológicos. Fonte: Restrepo-Carvajal et al., 2024	10
Tabela 2. Métricas de composição, diversidade funcional e diversidade taxonômica calculados com os dados obtidos em campo.	12
Tabela 3. Índices de vegetação calculados utilizando dados espectrais obtidos com drone. ..	18
Tabela 4. Modelos de regressão linear múltipla ajustados para a Divergência Funcional em função dos índices de vegetação obtidos com drone.	41
Tabela 5. Modelos de regressão linear múltipla ajustados para a Média Ponderada de Fósforo Foliar (CWM Pfoliar) em função dos índices de vegetação obtidos com drone.	42
Tabela 6. Modelos de regressão linear múltipla ajustados para a Média Ponderada de Fósforo Foliar (CWM LDMC) em função dos índices de vegetação obtidos com drone.	42

SUMÁRIO

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	2
2.1. Atributos funcionais, composição e diversidade funcional.....	2
2.2. Uso da abordagem funcional na restauração ecológica	4
2.3. Comportamento espectral das folhas.....	4
2.4. Detecção remota da diversidade funcional.....	6
3. MATERIAL E MÉTODOS.....	8
3.1. Área de estudo.....	8
3.2. Coleta de dados em campo.....	10
3.2.1. Inventário florístico	10
3.2.2. Medição de atributos funcionais por espécie	11
3.2.3. Cálculo dos índices de composição, diversidade funcional e taxonômica ..	12
3.3. Coleta de dados remotos	15
3.3.1. Levantamento das imagens multiespectrais.....	15
3.3.2. Coleta de coordenadas e voo complementar	15
3.3.3. Pré-processamento das imagens.....	15
3.3.4. Remoção dos pixels sombreados	17
3.3.5. Cálculo dos índices de vegetação	18
3.4. Análise dos dados.....	21
4. RESULTADOS.....	24
4.1. Composição e diversidade da comunidade de plantas	24
4.2. Índices de vegetação obtidos com drone.....	29
4.3. Correlações de Spearman	33
4.4. Regressão Linear Simples	35
4.4.1. Riqueza taxonômica (S)	36
4.4.2. Índice de Shannon-Weaver (H)	36

4.4.3. Dispersão Funcional (FDis)	37
4.4.4. Divergência Funcional (FDiv).....	38
4.4.5. Média Ponderada de Fósforo Foliar (CWM.Pfoliar).....	38
4.4.6. Média Ponderada do Teor de Matéria Seca Foliar (CWM.LDMC).....	39
4.5. Regressão Linear Múltipla	40
4.5.1. Divergência Funcional (FDiv).....	41
4.5.2. Média Ponderada de Fósforo Foliar (CWM.Pfoliar).....	41
4.5.3. Média Ponderada do Teor de Matéria Seca Foliar (CWM.LDMC).....	42
5. DISCUSSÃO.....	43
5.1. Comparações entre os tratamentos.....	43
5.2. Correlação e modelos entre os componentes da biodiversidade e os índices de vegetação obtidos com sensor multiespectral.....	44
5.3. Principais implicações e limitações do estudo.....	45
6. CONCLUSÕES	46
REFERÊNCIAS BIBLIOGRÁFICAS	47
APÊNDICE A – MAPAS COM OS ÍNDICES DE VEGETAÇÃO CALCULADOS A PARTIR DO ORTOFOTOMOSAICO APENAS COM OS PIXELS ILUMINADOS. ..	54
APÊNDICE B – MAPAS COM OS ÍNDICES DE VEGETAÇÃO CALCULADOS A PARTIR DO ORTOFOTOMOSAICO COM TODOS OS PIXELS.....	60
APÊNDICE C –FAMÍLIAS E ESPÉCIES REGISTRADAS EM TODA ÁREA EXPERIMENTAL.	66
APÊNDICE D – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES PIONEIRAS (Pi).	68
APÊNDICE E – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES SECUNDÁRIAS (Se).	69
APÊNDICE F – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES CLÍMAX (CL).	70
APÊNDICE G – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES PIONEIRAS, SECUNDÁRIAS E CLÍMAX (PSC).	71

APÊNDICE H – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES PIONEIRAS E CLÍMAX (PC).	72
APÊNDICE I – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES SECUNDÁRIAS E CLÍMAX (SC).	73
APÊNDICE J – VALORES DOS ATRIBUTOS FUNCIONAIS POR ESPÉCIE.	74
ANEXO A – PONTOS DE CONTROLE EM SUPERFÍCIE E COORDENADAS DOS VÉRTICES DAS PARCELAS.	76

1. INTRODUÇÃO

O bioma Mata Atlântica apresenta uma cobertura vegetal atual de 32 milhões de hectares de vegetação nativa, o que inclui formações florestais e não florestais (Rezende *et al.*, 2018). Embora este valor ofereça uma perspectiva positiva em relação a estimativas anteriores (e.g. Ribeiro *et al.*, 2009), este bioma permanece classificado como um *hotspot* de biodiversidade e, desse modo, continua altamente ameaçado (Myers *et al.*, 2000; Rezende *et al.*, 2018). De acordo com o relatório da SOS Mata Atlântica e do INPE (2022), a perda de florestas observada na Mata Atlântica apenas entre 2020 e 2021 correspondeu a 59 hectares por dia, o que reflete a emissão de 10,3 milhões de toneladas de CO₂ na atmosfera. O histórico de conversão no uso da terra, por meio do desmatamento, também torna este bioma extremamente vulnerável ao aquecimento global (Bellard *et al.*, 2014; Scarano; Ceotto, 2015). De acordo com Bellard *et al.* (2014), a Mata Atlântica está listada como um dos três hotspots mais vulneráveis aos impactos das mudanças climáticas.

Por outro lado, o aumento da cobertura vegetal nativa da Mata Atlântica poderá aumentar a conectividade entre os remanescentes e reduzir os processos de extinção, além de servir como um mecanismo de adaptação às mudanças climáticas (Scarano; Ceotto, 2015; Rezende *et al.*, 2018). Desse modo, a restauração ecológica, definida como uma atividade que visa a recuperação substancial de um ecossistema em relação a um modelo de referência apropriado (Gann *et al.*, 2019), ganhou impulso em todo o mundo na última década, envolvendo esforços de diversas organizações, além de metas ambiciosas e de grande escala (Chazdon *et al.*, 2017; Crouzeilles *et al.*, 2019). Na Mata Atlântica, destaca-se o “Pacto pela Restauração da Mata Atlântica”, criado em 2009 com o objetivo de restaurar 15 milhões de hectares até 2050 (Calmon *et al.*, 2009).

Gann *et al.* (2019) destacam que um projeto de restauração ecológica pode envolver diferentes etapas divididas em quatro práticas padronizadas: 1) planejamento e delineamento, 2) implantação, 3) monitoramento e avaliação e 4) manutenção. Nesse contexto, o uso da abordagem funcional tem sido reconhecido como uma ferramenta muito útil na restauração ecológica e pode ser aplicada em suas diversas etapas (e.g. Laughlin, 2014; Sansevero; Garbin, 2015; Loureiro *et al.*, 2023). Além disso, a abordagem funcional fornece informações valiosas para compreender a resposta das espécies frente às mudanças climáticas (Suding *et al.*, 2008; Laughlin, 2014). De acordo com Violle *et al.* (2007), os atributos funcionais são características fisiológicas, morfológicas e fenológicas das plantas e estão relacionados à absorção, alocação e utilização de recursos, assim como seus efeitos em processos ecológicos e funcionamento dos ecossistemas (Laughlin, 2014). Os índices de diversidade funcional, por sua vez, consideram a variedade e a distribuição dos atributos em um espaço multidimensional e descrevem a ocupação e a distribuição das espécies neste espaço (Mason *et al.*, 2005; Villéger; Mason; Mouillot, 2008).

A caracterização da composição e diversidade funcional é extremamente importante, dada a influência dos atributos funcionais na montagem de comunidades e na estrutura, composição e função dos ecossistemas (Suding *et al.*, 2008; Laughlin, 2014; Cavender-Bares *et al.*, 2020; Serbin; Townsend, 2020). No entanto, de acordo com Serbin e Townsend (2020), as medições contínuas em campo de atributos funcionais representam um desafio logístico, o que limita a cobertura geográfica e temporal de dados de diversidade funcional. As técnicas de sensoriamento remoto, por outro lado, surgem como uma alternativa, fornecendo novos caminhos para o levantamento de dados de vegetação em maiores escalas (Serbin; Townsend, 2020; Robinson *et al.*, 2022).

Na década passada, Schimel, Asner e Moorcroft (2013) consideravam que o sensoriamento remoto da atual geração seria capaz de identificar espécies e diversidade funcional a partir de características observadas do dossel. A revisão de Kothari e Schweiger

(2022) corrobora este pensamento e afirma que os espectros de reflectância da vegetação, nas escalas de folhas e copas, fornecem uma grande riqueza de informações sobre como as plantas funcionam. Nesse contexto, Jetz *et al.* (2016) destacam o uso de dados espectrais obtidos remotamente para mapear a diversidade funcional de plantas. Isso é possível pois, segundo Cavender-Bares *et al.* (2017), a interação entre a radiação e as propriedades estruturais e químicas das folhas resultam em diferentes assinaturas espectrais, o que permite estimar diferentes níveis de biodiversidade.

Nesse contexto, o estudo de Pinon *et al.* (2024) confirmou a Hipótese da Variação Espectral (HVE) para a Mata Atlântica. Os autores empregaram um sensor hiperespectral de alta resolução, transportado por Aeronave Remotamente Pilotada (ARP), para investigar como as métricas espectrais refletem a diversidade taxonômica no bioma. Por outro lado, a pesquisa de Beccari *et al.* (2024) reconheceu padrões de diversidade funcional em ecossistemas de dunas costeiras no mediterrâneo utilizando um sensor multiespectral, de menor resolução espectral, também embarcado em drone. De modo semelhante, Bazzo *et al.* (2024) utilizaram o mesmo sensor multiespectral para estimar a riqueza de espécies em campos úmidos na Europa.

Embora o sensor multiespectral tenha se mostrado eficaz para detectar componentes da biodiversidade em vegetações herbáceas (Bazzo *et al.*, 2024; Beccari *et al.*, 2024), não se sabe se o mesmo ocorre em ecossistemas florestais com alta biodiversidade e heterogeneidade estrutural como a Mata Atlântica. Esta lacuna é relevante, dado o menor custo de sensores multiespectrais em comparação aos hiperespectrais. Portanto, este estudo apresenta uma nova abordagem ao investigar a capacidade de um sensor multiespectral, transportado por ARP, em identificar padrões de composição funcional, diversidade funcional e diversidade taxonômica na Mata Atlântica. Além disso, esta pesquisa se destaca por considerar os componentes funcionais da biodiversidade no bioma e se constitui base para pesquisas futuras relacionadas à diversidade espectral e funcional no contexto das florestas tropicais, contribuindo para o avanço do conhecimento científico na área.

Diante do exposto, o objetivo deste estudo foi utilizar imagens multiespectrais obtidas com drone para quantificar a composição funcional e a diversidade funcional e taxonômica em plantios de restauração ecológica baseados em distintas combinações de grupos sucessionais na Mata Atlântica, no estado do Rio de Janeiro. Os objetivos específicos foram: 1) Quantificar a composição funcional e a diversidade funcional e taxonômica na escala de comunidade na área em processo de restauração ecológica; 2) Obter imagens multiespectrais com câmera embarcada em drone; 3) Analisar as relações entre os parâmetros de composição funcional e diversidade funcional e taxonômica medidos em campo e os índices de vegetação determinados com base nas imagens multiespectrais, e 4) Ajustar e validar modelos estatísticos para quantificar a composição funcional e a diversidade funcional e taxonômica de áreas em processo de restauração na Mata Atlântica por meio de imagens multiespectrais. As hipóteses testadas foram: 1) As medidas de composição funcional e diversidade funcional e taxonômica são diferentes entre os tratamentos baseados em grupos sucessionais; 2) As medidas dos índices de vegetação obtidos com drone são diferentes entre os tratamentos baseados em grupos sucessionais; e 3) As medidas dos índices de vegetação obtidos com drone são correlacionadas com as medidas de composição funcional e diversidade funcional e taxonômica.

2. REVISÃO DE LITERATURA

2.1. Atributos funcionais, composição e diversidade funcional

Segundo Violle *et al.* (2007), os atributos funcionais são definidos como características fisiológicas, morfológicas e fenológicas, mensuráveis a nível de indivíduo, que afetam a aptidão por meio de seus efeitos no crescimento, na reprodução e na sobrevivência (Violle *et al.*, 2007).

Garnier, Navas e Grigulis (2016) enfatizam ainda que estas características podem ser hereditárias. Nesse sentido, os atributos funcionais podem ser agrupados em dois tipos: 1) **Atributos de resposta**: aqueles que determinam a resposta dos organismos às condições ambientais e influenciam em como as comunidades são formadas; 2) **Atributos de efeito**: os que determinam o efeito dos organismos nas funções do ecossistema e, assim, conduzem os processos ecossistêmicos (Violle *et al.*, 2007; Suding *et al.*, 2008; Laughlin, 2014).

Díaz *et al.* (2004) destacam que, dependendo do conjunto de atributos funcionais, as plantas podem apresentar duas diferentes estratégias de utilização de recursos: tipo aquisitivo e tipo conservativo. As espécies aquisitivas possuem atributos que permitem a rápida aquisição de recursos (Díaz *et al.*, 2004). Desse modo, estas espécies crescem rapidamente e tendem a apresentar madeira menos densa, folhas maiores, assim como um ciclo de vida mais curto (Chave *et al.*, 2009). Muitos desses atributos coincidem com a descrição das espécies pioneiros e secundárias iniciais realizada por Budowski (1965). Por outro lado, os atributos presentes nas espécies conservativas possibilitam a conservação dos recursos dentro de tecidos (Díaz *et al.*, 2004). Estas espécies possuem crescimento lento e geralmente apresentam madeira mais densa, folhas menores e maior longevidade (Chave *et al.*, 2009), o que se assemelha às características das espécies secundárias tardias e clímax definidas por Budowski, 1965.

Ressalta-se que os atributos funcionais podem ser expandidos do nível dos organismos para a escala das populações, comunidades e/ou ecossistemas (Violle *et al.*, 2007; Suding *et al.*, 2008). Violle *et al.* (2007) argumentam que esta ampliação requer funções de integração e propõem o termo “parâmetro funcional da comunidade” para qualquer característica resultante da agregação comunitária de atributos funcionais. Suding *et al.* (2008) apresentam processos de montagem da comunidade a partir das relações entre os atributos de resposta, os atributos de efeito e a abundância das espécies. Os autores concluem que esta estrutura pode auxiliar na previsão dos efeitos das mudanças ambientais no funcionamento do ecossistema. Nesse contexto, de acordo com De Bello *et al.* (2021), a Média Ponderada da Comunidade (CWM - *Community Weighted Mean*) é um índice simples capaz de descrever a composição funcional das comunidades. A CWM corresponde aos valores médios de cada atributo funcional, ponderados pelas abundâncias relativas das espécies, que pode ser expressa também em termos de biomassa, cobertura ou frequência (Violle *et al.*, 2007; De Bello *et al.*, 2021). Basicamente, o valor da CWM representa o valor médio mais provável de ser encontrado se um indivíduo for extraído aleatoriamente da comunidade (De Bello *et al.*, 2021).

A diversidade funcional, por sua vez, pode ser entendida como um componente da biodiversidade que considera a variedade e a distribuição dos atributos funcionais (Mason *et al.*, 2005; Villéger; Mason; Mouillot, 2008). Villéger, Mason e Mouillot (2008) explicam a diversidade funcional do ponto de vista geométrico. De acordo com esta perspectiva, o espaço de nicho funcional é interpretado como um espaço multidimensional formado por vários eixos correspondentes a atributos funcionais. Todas as espécies possuem n valores de atributos funcionais, que podem ser inseridos neste espaço como coordenadas. Portanto, Villéger, Mason e Mouillot (2008) definem a diversidade funcional como a distribuição das espécies e suas abundâncias no espaço de nicho funcional.

Mason *et al.* (2005) ressaltam que a diversidade funcional compreende três principais componentes: 1) **Riqueza funcional**: É definida como a quantidade de nicho ocupado pelas espécies em uma determinada comunidade. A alta riqueza funcional indica que a maioria dos recursos disponíveis para a comunidade são utilizados; 2) **Equabilidade funcional**: Entende-se como a equidade da distribuição da abundância das espécies no espaço do nicho ocupado. Nesse sentido, se a equabilidade funcional de uma comunidade for baixa, significa que algumas partes do espaço do nicho estão ocupadas, mas não totalmente utilizadas. Enquanto o alto valor indica que todo o espaço do nicho é utilizado de modo semelhante, o que reduz as oportunidades para invasores, e 3) **Divergência funcional**: Refere-se à divergência na distribuição de

abundância no espaço do nicho ocupado. Desse modo, se uma comunidade apresenta alta divergência funcional, significa que a diferenciação de nicho é alta e, consequentemente, a competição por recursos é baixa. Além destes, existem outros índices univariados e multivariados capazes de descrever a ocupação e a distribuição das espécies no espaço funcional (Mason *et al.*, 2005; Villéger; Mason; Mouillot, 2008).

2.2. Uso da abordagem funcional na restauração ecológica

Loureiro *et al.* (2023) realizaram uma revisão sistemática a respeito do uso de atributos funcionais das plantas em iniciativas de restauração ecológica no mundo. Os resultados obtidos nesta pesquisa mostram que a utilização da abordagem funcional na restauração aumentou significativamente na última década, o que confirma sua importância teórica. Além disso, estes autores acreditam que os atributos funcionais podem ser aplicados em qualquer etapa da restauração, servindo como uma ferramenta de gestão da comunidade. Nesse contexto, o trabalho desenvolvido por Laughlin (2014) cita diferentes aplicações de modelos quantitativos baseados em atributos funcionais na restauração. Segundo o autor, é possível, por exemplo, utilizar a abordagem funcional no controle de espécies invasoras, inserindo na comunidade espécies com valores de atributos funcionais mais competitivos para excluir as espécies indesejadas. Outro exemplo citado por Laughlin (2014) é a utilização de modelos que permitem prever quais atributos irão potencializar o estabelecimento, o crescimento e a reprodução sob futuras condições climáticas. De modo semelhante, Ostertag *et al.* (2015) apresentaram um método para seleção de espécies na restauração utilizando a abordagem funcional. Para estes autores, os restauradores podem inserir diferentes espécies com os atributos desejados, o que permite prever as interações interespecíficas e as potenciais mudanças nas condições bióticas e abióticas da área.

Sansevero e Garbin (2015) consideram que esta abordagem também desempenha uma importante função no fornecimento de indicadores confiáveis e simplificados para avaliar o sucesso da restauração de florestas tropicais. Adicionalmente, Manhães *et al.* (2022) avaliaram o sucesso da restauração com base na trajetória funcional, calculando as trajetórias dos plantios em direção ou afastamento do ecossistema de referência. Os autores descobriram que apenas o tratamento com todos os grupos ecológicos (espécies pioneiras + espécies secundárias + espécies clímax) se aproximou funcionalmente do ecossistema de referência 20 anos após o plantio. Esta descoberta não só enfatiza a relação entre os atributos funcionais e os grupos ecológicos, como ressalta a importância de monitorar a composição funcional das comunidades florestais plantadas.

Trabalhos recentes também discutem o uso da abordagem funcional pelos profissionais práticos da restauração (Merchant *et al.*, 2022; Gornish *et al.*, 2023). Merchant *et al.* (2022) acreditam que, apesar do potencial do uso dos atributos funcionais na restauração ecológica, frequentemente os mesmos não são considerados na prática. Gornish *et al.* (2023), por sua vez, afirmam que os profissionais utilizam estes atributos de modo distinto dos pesquisadores. Na visão de Gornish *et al.* (2023), é importante que os pesquisadores reconheçam o conhecimento ecológico local e interajam diretamente com quem atua na prática, o que permitirá maior aplicação da abordagem funcional na restauração ecológica.

2.3. Comportamento espectral das folhas

O espectro solar é composto por todos os comprimentos de onda da energia eletromagnética do Sol que incidem na superfície da Terra, incluindo a região ultravioleta, a luz visível, o infravermelho próximo e o infravermelho de ondas curtas (Ollinger, 2011; Ustin; Jacquemoud, 2020). Toda esta faixa de comprimento de onda incidente interage com as folhas

das plantas, produzindo uma assinatura espectral que depende da composição química, da fisiologia, da morfologia, do conteúdo de água e da estrutura interna foliar (Ollinger, 2011; Cavender-Bares *et al.*, 2017; Ustin; Jacquemoud, 2020; Kothari; Schweiger, 2022), conforme pode ser visualizado nas Figuras 1 e 2. Segundo Ollinger (2011), o fundamento biofísico desta interação pode ser dividido em absorção, reflexão e transmissão. Desse modo, os principais absorvedores nas plantas são os pigmentos, que absorvem no visível (entre 400 – 700nm), e o teor de água, que absorve sobretudo no infravermelho médio (> 1400 nm), enquanto a região do infravermelho próximo (aproximadamente 750 – 1400 nm) é caracterizada pela alta reflexão, por influência das propriedades estruturais (Ollinger, 2011).

Nesse contexto, de acordo com Cavender-Bares *et al.* (2017), como os atributos foliares diferem entre genótipos de plantas, espécies e linhagens filogenéticas, os espectros possibilitam detectar diferentes níveis de biodiversidade (Figura 3). O trabalho desenvolvido por Schweiger *et al.* (2018) fornece evidências para esta afirmação, cujos resultados mostram que espécies mais funcionalmente diferentes e mais distamente relacionadas são mais dissimilares espectralmente. Para obter os dados espetrais, estes autores utilizaram um espectrômetro de campo portátil que cobre a faixa de comprimento de onda de 340 a 2.500 nm. Schweiger *et al.* (2018) concluíram que, embora os perfis espetrais foliares não capturem todas as propriedades determinantes do fenótipo de uma planta, eles incorporam mais da variação da função associada à anatomia, química e morfologia foliar, do que os atributos comumente medidos.

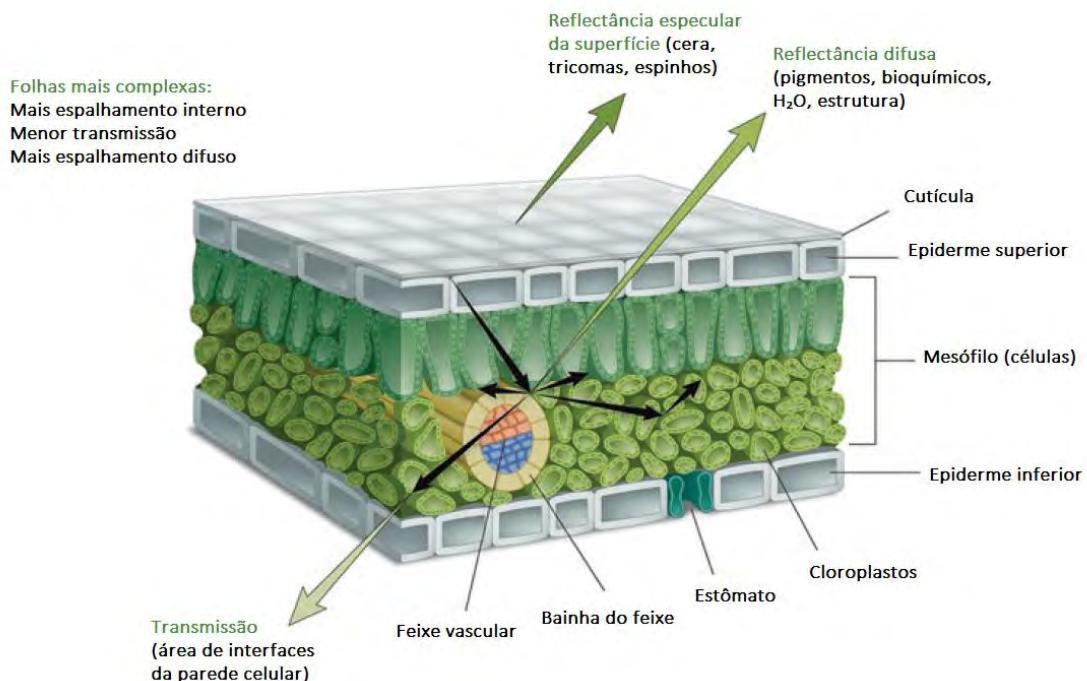


Figura 1. As propriedades estruturais e bioquímicas das folhas regulam a quantidade de radiação incidente refletida, transmitida ou absorvida. Por exemplo, características da camada externa da folha, como presença de cera ou tricomas, influenciam a quantidade de radiação que é refletida e, por consequência, a quantidade de radiação penetrada na folha. Além disso, a espessura do mesófilo associada a outras propriedades provoca diferentes comportamentos de transmissão e absorção da radiação. Fonte: Adaptado de Serbin e Townsend, 2020.

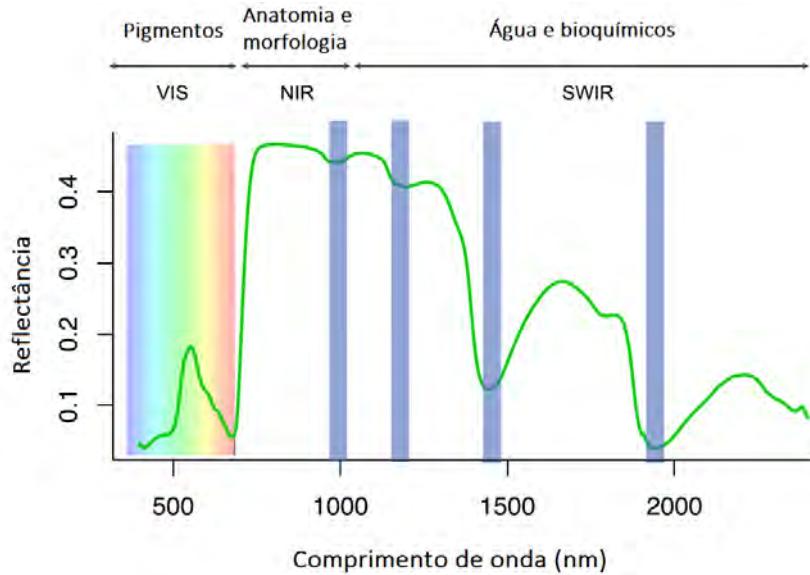


Figura 2. Exemplo de um espectro de reflectância foliar. São mostradas as três principais regiões do espectro (visível, infravermelho próximo e infravermelho de ondas curtas), assim como as principais características químicas e estruturais das folhas que influenciam a reflectância, são elas: os pigmentos, a anatomia e a morfologia foliar, o teor de água e a composição química. As barras azuis indicam as características de absorção da água. VIS: Visível (entre 400 – 700nm); NIR: Infravermelho próximo (entre 700 a 1400 nm); SWIR: Infravermelho de onda curta (entre 1400 a 3000nm). Fonte: Adaptado de Kothari e Schweiger, 2022.

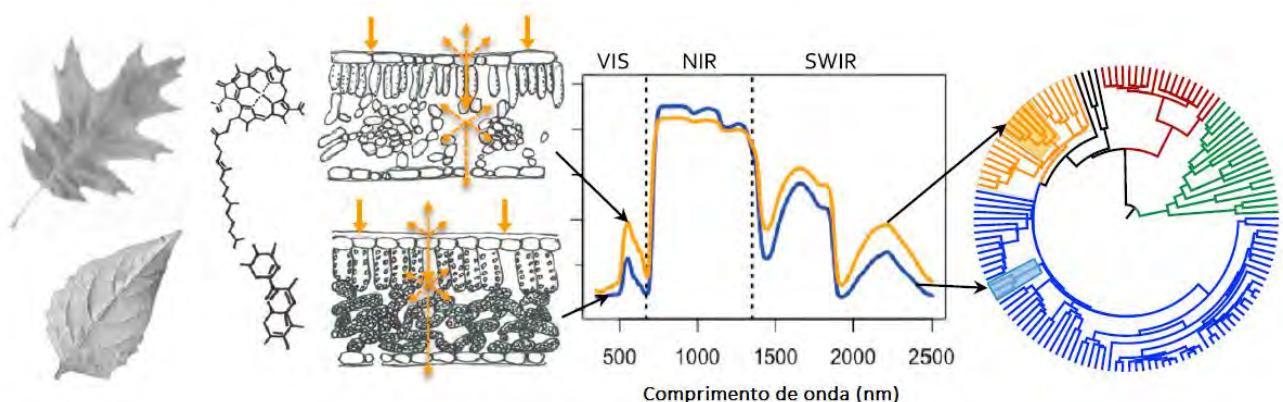


Figura 3. A interação entre a radiação e as propriedades e estruturas químicas das folhas resultam em diferentes assinaturas espectrais entre distintos grupos filogenéticos. Dessa forma, os dados espectrais podem ser utilizados para estimar a biodiversidade. VIS: Visível (entre 400 – 700nm); NIR: Infravermelho próximo (entre 700 a 1400 nm); SWIR: Infravermelho de onda curta (entre 1400 a 3000nm). Fonte: Adaptado de Cavender-Bares *et al.*, 2017.

2.4. Detecção remota da diversidade funcional

Conforme descrito na revisão de Serbin e Townsend (2020), no início do século XX apareceram os primeiros estudos utilizando espetrômetros de imagem em nível de folha para entender o funcionamento das plantas. Posteriormente, diversos sistemas de sensores aerotransportados foram construídos, incluindo plataformas orbitais e suborbitais (Serbin; Townsend, 2020). Atualmente, as técnicas de sensoriamento remoto, quando baseadas na teoria e na prática ecológicas, fornecem novas abordagens para o estudo da biodiversidade, assim como das funções e dos processos ecossistêmicos (Robinson *et al.*, 2022; Kothari; Schweiger,

2022). Desse modo, as pesquisas que utilizam a detecção remota para analisar a vegetação, incluindo a diversidade funcional, estão em constante avanço, conforme evidenciado pelo levantamento realizado por Wang e Gamon (2019) do número de artigos publicados utilizando “Biodiversidade” e “Detecção Remota” como tópico na *Web of Science*. Jetz *et al.* (2016) também destacam o uso de dados espectrais obtidos remotamente para mapear padrões de diversidade funcional. Os autores, inclusive, citam alguns atributos funcionais de plantas que são remotamente observáveis, tais como massa foliar por área, percentual de nitrogênio foliar e percentual de carboidratos não-estruturais.

Nesse contexto, existem duas abordagens comumente utilizadas para estimar os atributos funcionais a partir de espectros, são elas: 1) **Técnicas empíricas** e 2) **Modelagem de transferência radiativa** (Serbin; Townsend, 2020; Kothari; Schweiger, 2022). Os Modelos de Transferência Radiativa (MTR) são baseados em princípios físicos e representam explicitamente as interações entre a radiação eletromagnética e as estruturas da vegetação (Serbin; Townsend, 2020; Kothari; Schweiger, 2022). Desse modo, o MTR mais utilizado é o PROSPECT, desenvolvido por Jacquemoud e Baret (1990), que simula o comportamento espectral das folhas, considerando-as como camadas absorventes e homogêneas (Serbin; Townsend, 2020; Kothari; Schweiger, 2022). Segundo Kothari e Schweiger, invertendo o PROSPECT, é possível estimar pigmentos, conteúdo de matéria seca e conteúdo de água (Figura 2).

No que diz respeito às técnicas empíricas, de acordo com Serbin e Townsend (2020), as metodologias mais utilizadas são o uso de índices espectrais de vegetação (IVs) e a modelagem de regressão de mínimos quadrados parciais (PLSR - *Partial Least-Squares Regression*). Estas técnicas se baseiam nas correlações entre um determinado conjunto de dados e possibilitam o ajuste de modelos para estimar e mapear atributos funcionais de plantas utilizando apenas as medições espectrais (Ollinger, 2011; Serbin; Townsend, 2020; Kothari; Schweiger, 2022). Kotharie e Schweiger (2022) afirmam que a PLSR independe de uma alta compreensão sobre as relações entre as variáveis dependentes e as variáveis independentes, permitindo o uso de preditores colineares. Schweiger *et al.* (2017), por exemplo, utilizaram dados de espectroscopia obtidos remotamente para modelar e prever padrões funcionais no nível da comunidade vegetal usando a PLSR. Os modelos produzidos por Schweiger *et al.* (2017) tiveram alto poder preditivo e os autores concluíram que este método produz coeficientes que podem servir como representantes dos atributos bioquímicos e estruturais da vegetação.

Os índices espectrais de vegetação, por sua vez, são definidos como equações matemáticas, elaboradas com base em bandas espectrais, que permitem analisar e estimar diferentes parâmetros da cobertura vegetal (Formaggio; Sanches, 2017). Ollinger (2011) enfatiza a alta variedade desses índices, resultado de diversos estudos sobre as propriedades de reflectância dos pigmentos foliares. De Almeida *et al.* (2021), por exemplo, calculou quinze diferentes índices de vegetação, a partir de dados espectrais obtidos por um sensor hiperespectral, em uma plantação experimental de restauração florestal. Diversos IVs calculados por De Almeida *et al.* (2021) aumentaram com o aumento da riqueza de espécies nos plantios, demonstrando uma correlação entre estas informações. De modo semelhante, Pinon *et al.* (2024) também encontraram correlações moderadas ($\sim 0,55$) a fortes ($> 0,91$) entre índices de vegetação obtidos com sensor hiperespectral aerotransportado e a diversidade de espécies medida em campo na Mata Atlântica.

Embora os trabalhos citados anteriormente enfatizem o uso de tecnologias hiperespectrais para mapear características químicas e estruturais do dossel das plantas (e.g. Jetz *et al.*, 2016; Schweiger *et al.*, 2017; De Almeida *et al.*, 2021; Pinon *et al.*, 2024), estudos recentes também apontam para o potencial de sensores multiespectrais na avaliação da biodiversidade (e.g. Beccari *et al.*, 2024; Bazzo *et al.*, 2024). Beccari *et al.* (2024) utilizaram um drone com câmera acoplada que obtém imagens em cinco bandas (azul, verde, vermelho,

borda vermelha e infravermelho próximo) para detectar padrões de biodiversidade em ecossistemas de dunas costeiras na Itália. Os resultados encontrados por estes autores indicam que mudanças nas características funcionais das comunidades correspondem a mudanças nos valores das bandas espectrais. Bazzo *et al.* (2024), por sua vez, integraram dados espectrais, estruturais e de textura obtidos com drone e o mesmo sensor multiespectral para estimativa de riqueza de espécies em pastagens úmidas na Alemanha.

No entanto, ressalta-se que tanto Beccari *et al.* (2024) quanto Bazzo *et al.* (2024) estudaram vegetações herbáceas. Não é possível afirmar que o mesmo sensor consiga capturar esses padrões em comunidades florestais com alta biodiversidade como a Mata Atlântica. Além disso, é importante evidenciar as limitações dos estudos que relacionam os dados espectrais obtidos remotamente com a biodiversidade, uma vez que a variação espectral de uma determinada área é afetada por diferentes fatores, como resolução espacial e radiométrica do sensor, sazonalidade, ângulo do terreno e composição da paisagem (Cavender-Bares *et al.*, 2017; Fassnacht *et al.*, 2022). Dessa forma, Kothari e Schweiger (2022) ressaltam os cuidados necessários no uso e na interpretação dos resultados das abordagens empíricas, dado que as relações e o desempenho dos modelos podem mudar entre regiões, ecossistemas, escalas taxonômicas e espécies. Ma *et al.* (2020) argumentam ainda que a definição e as medições em campo dos atributos funcionais e da diversidade funcional podem não corresponder às observações de sensoriamento remoto, devido às possíveis incompatibilidades de escala espacial, temporal e vertical.

Diante disso, Fassnacht *et al.* (2022) recomendam novas investigações nesta área de estudo, a fim de examinar em quais condições os dados espectrais permitem analisar a biodiversidade. De forma semelhante, Ma *et al.* (2020) enfatizam a necessidade de mais esforços para corrigir as incertezas, como novas estratégias de medição em campo, novos algoritmos de sensoriamento remoto e outros conceitos e teorias relacionados à diversidade funcional de plantas.

3. MATERIAL E MÉTODOS

3.1. Área de estudo

O estudo foi realizado na Reserva Biológica de Poço das Antas (RBPA), localizada no município de Silva Jardim, Estado do Rio de Janeiro (Figura 4). A RBPA possui uma área aproximada de 5.000 hectares e está sob influência direta da bacia hidrográfica do rio São João (Lima *et al.*, 2006). De acordo com o mapa de classificação climática elaborado por Alvares *et al.* (2013), o clima da região é Aw (Köppen), caracterizando-se por ser quente e úmido, com a estação chuvosa no verão. Os dados de precipitação coletados entre 2016 a 2022 na estação meteorológica da RBPA mostram que, embora exista uma variação nas precipitações mensais a cada ano, os meses mais secos se concentram no outono e no inverno, enquanto os meses mais chuvosos ocorrem na primavera e no verão (Peixoto *et al.*, 2022). No que diz respeito à vegetação, a RBPA conta com remanescentes de Floresta Ombrófila Densa subdivididos em seis fisionomias: floresta aluvial, floresta submontana, formação pioneira com influência fluvial, capoeira aluvial, capoeira submontana e campo antrópico (Lima *et al.*, 2006), além de diversas áreas de plantios em processo de restauração ecológica (Moraes *et al.*, 2006).

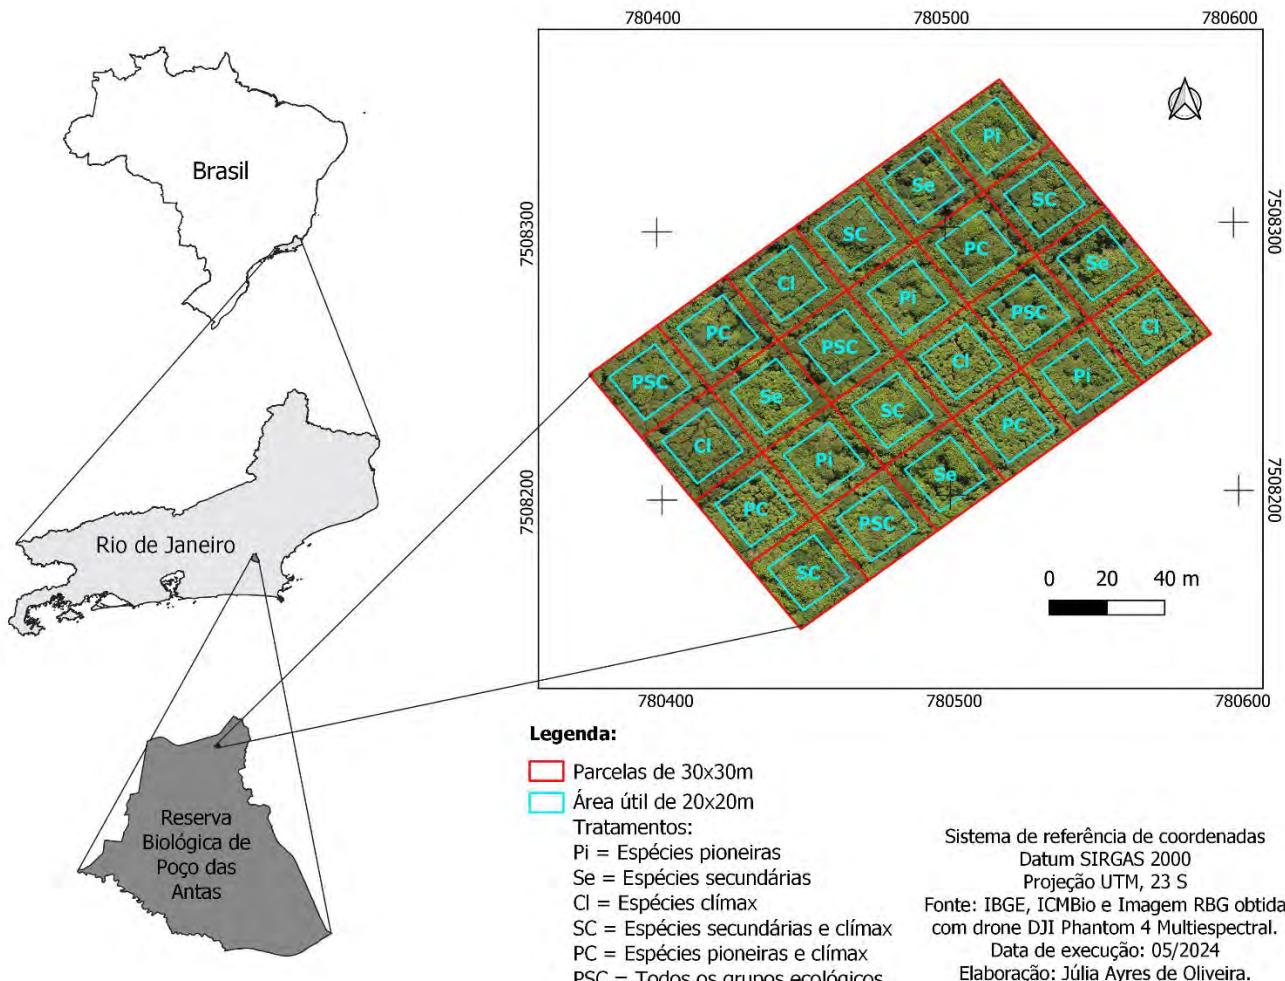


Figura 4. Mapa da localização da Reserva Biológica de Poço das Antas, Silva Jardim, Rio de Janeiro, Brasil. Fonte: Elaborado pela autora, 2024.

Para condução deste trabalho, foi selecionada uma área de plantios do Projeto Revegetação, implantado no ano de 2000, com o objetivo de avaliar diferentes modelos sucessoriais. A implantação dos plantios foi desenvolvida em uma área de 2,16 ha, dividida em 24 parcelas de 30 x 30 m cada. Os tratamentos foram replicados quatro vezes no nível da parcela e consistiram em seis combinações de grupos sucessoriais (sensu Budowski, 1965): 1) PI – espécies pioneiras; 2) Se – espécies secundárias iniciais e tardias; 3) CI – espécies clímax; 4) SC – espécies secundárias tardias e espécies clímax; 5) PC – espécies pioneiras e espécies clímax; e 6) PSC – espécies pioneiras, secundárias iniciais e tardias e espécies clímax. Em toda área experimental, foram plantadas um total de 5.560 mudas com um espaçamento de 2,2 m, riqueza de 26 espécies e 15 famílias botânicas (Tabela 1). Posteriormente, 24 unidades amostrais de 20 m x 20 m foram instaladas dentro das parcelas de 30 m x 30 m (Figura 4). Dessa forma, uma borda de cinco metros de largura foi excluída em cada unidade para evitar o efeito do tratamento vizinho.

Tabela 1. Lista de espécies plantadas por tratamento na área experimental. Tratamentos: Pi: espécies pioneiras; Se: espécies secundárias; Cl: espécies clímax; SC: espécies secundárias tardias e clímax; PC: espécies pioneiras e clímax; PSC: espécies de todos os grupos ecológicos. Fonte: Restrepo-Carvajal *et al.*, 2024.

Família	Nome científico	Grupo	Número de indivíduos plantados					
			Pi	Se	Cl	SC	PC	PSC
Anacardiaceae	<i>Schinus terebinthifolia</i> Raddi	Pi	17	0	0	0	3	0
Anacardiaceae	<i>Tapirira guianensis</i> Aubl.	Se	0	84	0	84	0	0
Bignoniaceae	<i>Handroanthus chrysotrichus</i> (Mart. ex DC.) Mattos	Cl	0	0	0	1	0	0
Bignoniaceae	<i>Handroanthus impetiginosus</i> (Mart. ex DC.) Mattos	Cl	0	0	5	0	0	1
Bignoniaceae	<i>Sparattosperma leucanthum</i> (Vell.) K.Schum.	Pi	9	0	0	0	2	3
Calophyllaceae	<i>Calophyllum brasiliense</i> Cambess.	Cl	0	0	63	0	63	0
Caricaceae	<i>Jacaratia spinosa</i> (Aubl.) A.DC.	Se	0	56	0	56	0	0
Euphorbiaceae	<i>Alchornea glandulosa</i> Poepp.	Pi	311	0	0	0	254	253
Fabaceae	<i>Centrolobium tomentosum</i> Guillem. ex Benth.	Se	0	53	0	33	0	0
Fabaceae	<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	Cl	0	0	21	0	21	0
Fabaceae	<i>Inga vera</i> Willd.	Se	0	256	0	0	0	128
Fabaceae	<i>Plathymenia reticulata</i> Benth.	Cl	0	0	216	215	0	43
Fabaceae	<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	Se	0	3	0	28	0	0
Fabaceae	<i>Pterocarpus rohrii</i> Vahl	Cl	0	0	240	230	0	36
Fabaceae	<i>Swartzia langsdorffii</i> Raddi	Cl	0	0	0	14	0	7
Lamiaceae	<i>Aegiphila integrifolia</i> (Jacq.) Moldenke	Pi	95	0	0	0	109	0
Lauraceae	<i>Nectandra oppositifolia</i> Nees & Mart	Cl	0	0	0	0	0	1
Lecythidaceae	<i>Cariniana legalis</i> (Mart.) Kuntze	Cl	0	0	8	9	0	5
Malvaceae	<i>Pseudobombax majus</i> A.Robyns	Se	0	256	0	0	0	0
	Carv.-Sobr							
Melastomataceae	<i>Pleroma granulosum</i> (Desr.) D. Don	Se	0	224	0	0	0	96
Meliaceae	<i>Cedrela fissilis</i> Vell.	Cl	0	0	11	6	0	3
Meliaceae	<i>Guarea guidonia</i> (L.) Sleumer	Cl	0	0	256	256	0	64
Myrtaceae	<i>Eugenia florida</i> DC.	Cl	0	0	56	0	56	18
Myrtaceae	<i>Plinia edulis</i> (Vell.) Sobral	Cl	0	0	56	0	56	18
Primulaceae	<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	Pi	84	0	0	0	112	0
Verbenaceae	<i>Citharexylum myrianthum</i> Cham.	Pi	384	0	0	0	256	256

3.2. Coleta de dados em campo

3.2.1. Inventário florístico

O inventário florístico foi realizado em agosto de 2023 em cada unidade amostral de 20 x 20 m. A Altura (H) das árvores foi estimada visualmente. O Diâmetro à Altura do Peito (DAP), medido a 1,30 m do solo, foi determinado com auxílio de uma fita métrica. A Área de Copa foi calculada considerando a fórmula de cálculo de área de uma elipse ($\pi \times a \times b$), onde a e b correspondem aos comprimentos do eixo maior e do eixo menor da copa, respectivamente, obtidos com trena. Como critério de inclusão, foram consideradas todas as árvores com DAP igual ou maior que 5 cm. Além disso, a identificação dos indivíduos amostrados foi realizada

em campo e, em seguida, verificada por comparação com exemplares do catálogo Flora e Funga do Brasil (2023) (<http://floradobrasil.jbrj.gov.br/>).

3.2.2. Medição de atributos funcionais por espécie

A coleta dos ramos e a medição dos atributos funcionais foram conduzidas em março de 2024, seguindo o manual de padronização proposto por Pérez-Harguindeguy *et al.* (2013). Todas as espécies presentes na área foram consideradas para a avaliação dos atributos funcionais, utilizando-se como base o inventário florístico realizado em 2023. O número de indivíduos por espécie variou de um a dez, dependendo do número de indivíduos encontrados e das condições de sanidade dos ramos foliares. Evitaram-se ramos com folhas jovens, sombreadas e/ou afetadas por herbívoros e/ou patógenos. Após a coleta, cada ramo foi acondicionado em saco plástico transparente com um pouco de água pulverizada. Todos os sacos plásticos foram colocados em caixa térmica com o objetivo de manter a hidratação até o processamento em laboratório.

A primeira etapa do processamento foi realizada no mesmo dia da coleta, no laboratório da Reserva Biológica de Poço das Antas. Foram selecionadas três folhas por indivíduo para mensurar os atributos foliares. Obteve-se, primeiramente, a massa saturada (g) de cada folha com balança de precisão e, em seguida, foram registradas fotos de todas as folhas para posterior medição de área foliar no software *ImageJ*.

A segunda etapa do processamento foi desenvolvida na Embrapa Agrobiologia (Seropédica/RJ). As folhas foram colocadas em estufa a 70°C por 72 horas e, depois, foram pesadas com balança de precisão para a obtenção da massa seca (g). Realizou-se a Trituração com um moinho analítico *ika® A11 basic* de todas as folhas por espécie. A análise dos conteúdos de carbono e nitrogênio foliar foi realizada pelo Analisador Elementar, enquanto o conteúdo de fósforo foliar foi determinado pelo método colorimétrico. A partir destas medições, foram quantificados os seguintes atributos funcionais:

1) **Área Foliar (Leaf Area - LA)**: É a área unilateral de uma folha individual e está associada a estratégias ecológicas, assim como a fatores alométricos e filogenéticos (Pérez-Harguindeguy *et al.*, 2013). Além disso, a LA influencia no balanço energético e hídrico das folhas (Díaz *et al.*, 2016).

2) **Área Foliar Específica (Specific Leaf Area - SLA)**: É a razão entre a área unilateral de uma folha fresca e sua massa seca (Pérez-Harguindeguy *et al.*, 2013). Este atributo está positivamente correlacionado com o potencial de crescimento relativo das espécies, com a taxa fotossintética e com a concentração de nitrogênio nas folhas, e negativamente relacionado com a longevidade das folhas e com os compostos secundários, como taninos ou lignina (Pérez-Harguindeguy *et al.*, 2013);

3) **Teor de Matéria Seca Foliar (Leaf Dry Matter Content - LDMC)**: É a razão entre a massa seca em estufa de uma folha e sua massa fresca saturada de água (Pérez-Harguindeguy *et al.*, 2013). Tende a ser correlacionada positivamente com a longevidade, com a resistência a perigos físicos e com o tempo de decomposição das folhas, e inversamente relacionada com a área foliar específica e com o potencial de crescimento relativo das espécies (Pérez-Harguindeguy *et al.*, 2013). Desse modo, o LDMC reflete uma troca entre a longevidade e o ganho de carbono (Díaz *et al.*, 2016), e

4) **Concentração foliar de carbono (Cfoliar), nitrogênio (Nfoliar) e fósforo (Pfoliar)**: Quantidades totais de carbono, nitrogênio e fósforo, respectivamente, por unidade de massa seca de folha (Pérez-Harguindeguy *et al.*, 2013). A alta concentração de Cfoliar e Nfoliar está associada à qualidade nutricional. Além disso, a concentração foliar de nitrogênio tende a ser positivamente correlacionada com a taxa fotossintética máxima e com a área foliar específica (Pérez-Harguindeguy *et al.*, 2013). Assim, o teor de Nfoliar também reflete o

equilíbrio entre os benefícios do potencial fotossintético e os custos de aquisição de nitrogênio (Díaz *et al.*, 2016). Com os teores de carbono Cfoliar e Nfoliar, é possível determinar a razão de carbono para nitrogênio foliar (C/N). A razão C/N, assim como o LDMC, representa os custos de alocação de carbono da folha (Sandquist; Cordell, 2007).

3.2.3. Cálculo dos índices de composição, diversidade funcional e taxonômica

Com os dados de atributos funcionais, realizou-se os cálculos da média ponderada da comunidade e dos índices de diversidade funcional por parcela. Além disso, calculou-se os índices de diversidade taxonômica (Tabela 2). Estas análises foram realizadas no software R (R Core Team, 2024), com auxílio do pacote “FD” (Laliberté; Legendre, 2010; Laliberté; Legendre; Shipley, 2014).

Tabela 2. Métricas de composição, diversidade funcional e diversidade taxonômica calculados com os dados obtidos em campo.

Nome	Código	Fonte
Métrica de composição da comunidade		
Média ponderada da comunidade (<i>Community Weighted Mean</i>)	CWM	Violle <i>et al.</i> , 2007; Díaz <i>et al.</i> , 2007
Índices de diversidade funcional		
Riqueza funcional (<i>Functional richness</i>)	FRic	
Equabilidade funcional (<i>Functional evenness</i>)	FEve	Villéger, Mason e Mouillot, 2008
Divergência funcional (<i>Functional divergence</i>)	FDiv	
Dispersão funcional (<i>Functional dispersion</i>)	FDis	Laliberté e Legendre, 2010
Entropia quadrática de Rao	Rao	Rao, 1982
Índices de diversidade taxonômica		
Riqueza	S	
Equabilidade	E	
Índice de Shannon-Weaver	H'	Shannon e Weaver, 1949

A CWM é calculada para cada atributo funcional como a média dos valores dos atributos na comunidade, ponderada pela abundância relativa das espécies (Violle *et al.*, 2007; De Bello *et al.*, 2021). De acordo com Díaz *et al.* (2007), essa métrica é frequentemente interpretada como o valor do atributo dominante em uma comunidade. No que diz respeito aos índices de diversidade funcional, a FRic representa o espaço funcional total ocupado pelas espécies em uma comunidade (Villéger; Mason; Mouillot, 2008); a FEve quantifica a equidade da distribuição da abundância das espécies no espaço funcional ocupado (Villéger; Mason; Mouillot, 2008); a FDiv indica a divergência da distribuição da abundância das espécies no espaço funcional ocupado (Villéger; Mason; Mouillot, 2008); e a FDis e a Rao buscam, de modo distinto, estimar a dispersão ou o espalhamento das espécies no espaço de atributos funcionais, considerando suas abundâncias relativas (Laliberté; Legendre, 2010). Os índices de diversidade taxonômica, por sua vez, não consideram o espaço funcional, mas a identificação taxonômica das espécies presentes na área de estudo.

Ressalta-se que neste estudo foram testadas duas abordagens para os cálculos da média ponderada da comunidade e dos índices de diversidade funcional por parcela. Na primeira abordagem, considerou-se o número de indivíduos por espécie como medida de abundância relativa para a CWM e todos os índices de diversidade funcional, com exceção da FRic, que independe desta informação. Na segunda abordagem, a medida de abundância relativa foi o produto da soma da área de copa e altura por espécie. Dessa forma, espécies que possuem

indivíduos maiores, em termos de área de copa e altura, receberam uma ponderação maior nos cálculos. Além disso, em ambas as abordagens, foi adotada a padronização para que os valores de todos os atributos funcionais tivessem média igual a 0 e desvio padrão igual a 1 (e.g. Petchey; Gaston, 2002; Petchey; Gaston, 2006). A Figura 5 esquematiza todas as etapas metodológicas da coleta de dados em campo.

Dados de campo

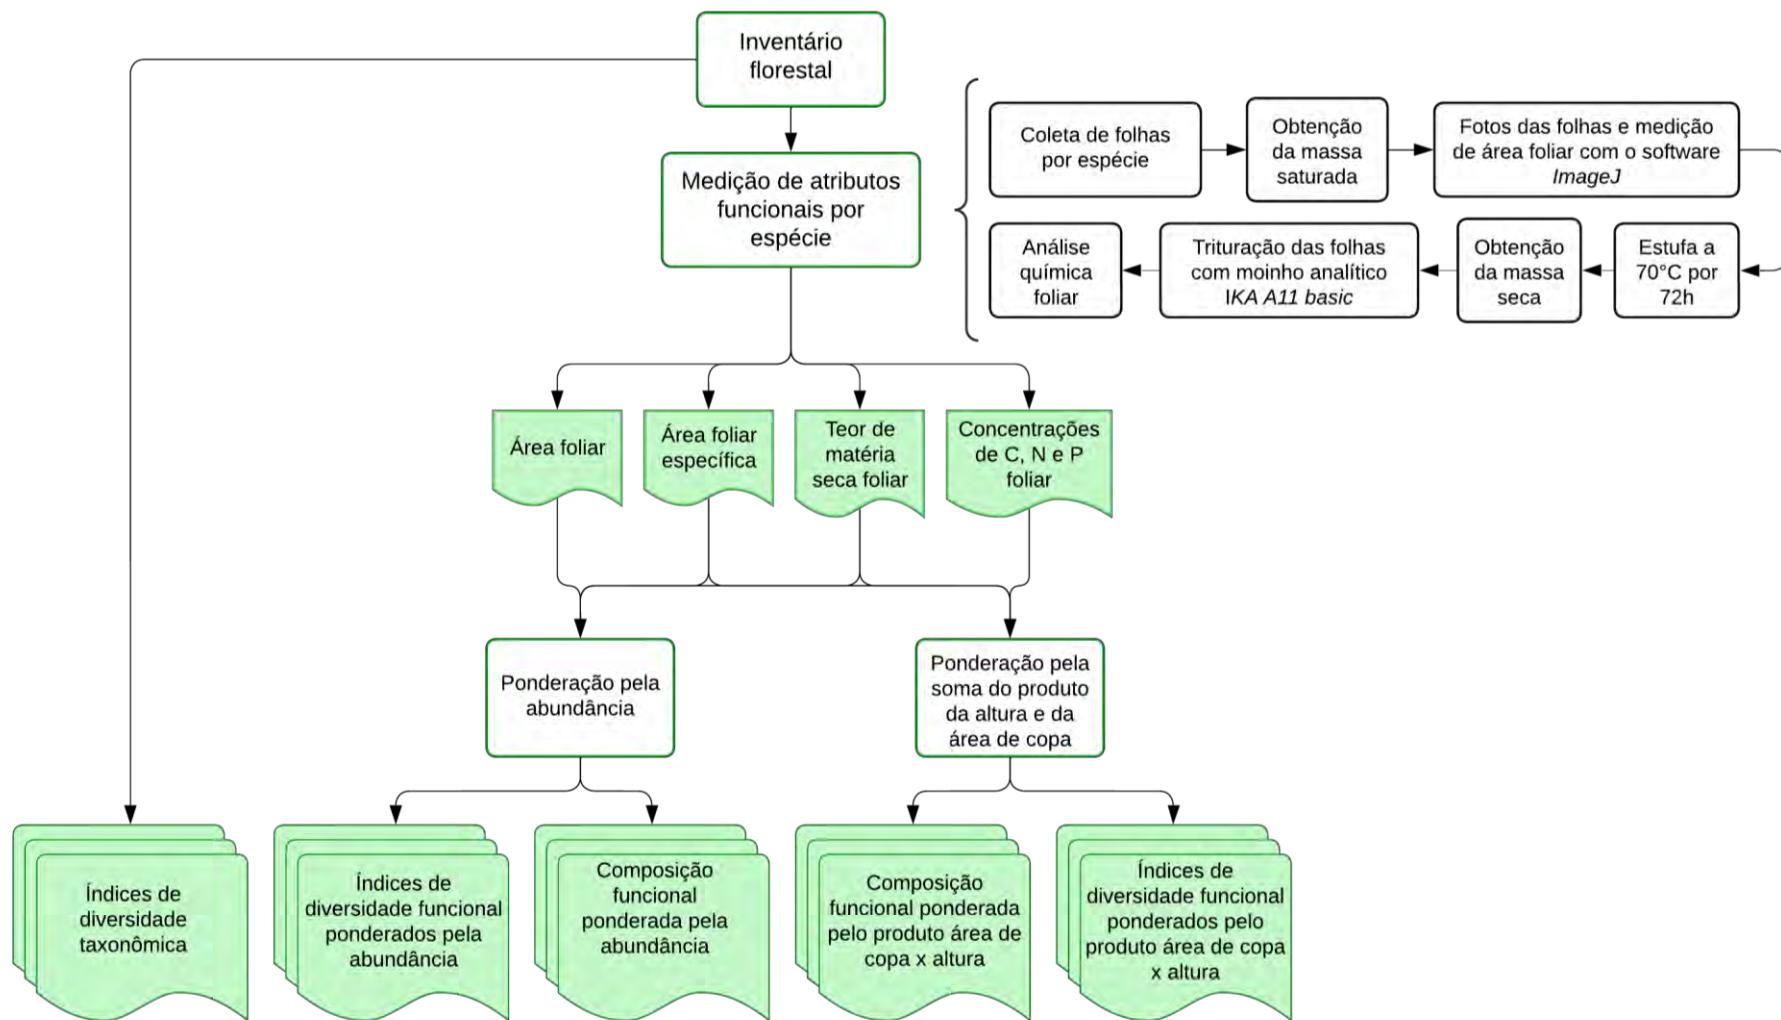


Figura 5. Fluxograma metodológico para quantificar os atributos funcionais, a composição funcional e os índices de diversidade funcional e taxonômica na área de estudo. Fonte: Elaborado pela autora, 2024.

3.3. Coleta de dados remotos

3.3.1. Levantamento das imagens multiespectrais

Os dados espectrais da área de estudo foram obtidos com auxílio de uma aeronave remotamente pilotada modelo *DJI Phantom 4 multiespectral* equipada com seis sensores CMOS 1/2.9", incluindo um sensor RGB para imagens de luz visível e cinco sensores monocromáticos para imagens multiespectrais nas faixas de cores azul ($450\text{ nm} \pm 16\text{ nm}$), verde ($560\text{ nm} \pm 16\text{ nm}$), vermelho ($650\text{ nm} \pm 16\text{ nm}$), borda vermelha ($730\text{ nm} \pm 16\text{ nm}$) e infravermelho próximo ($840\text{ nm} \pm 26\text{ nm}$) (DJI, 2019). O levantamento das imagens foi realizado às 11h20min do dia 04 de abril de 2024, com base no plano de voo elaborado no aplicativo *DJI Ground Station Pro - GS Pro*. Os parâmetros determinados incluem altura de voo de 120 m, velocidade de voo de 7,3 m/s e taxas de sobreposição lateral e longitudinal de 70 e 75%, respectivamente. Assim, atingiu-se uma distância de amostragem do solo (GSD) de 6,3 cm/pixel.

3.3.2. Coleta de coordenadas e voo complementar

Para garantir a precisão espacial dos dados, em novembro de 2024 foram inseridos 3 Pontos de Controle em Superfície (PCS) na área de voo (Figura 6) com a técnica de Posicionamento por Ponto Preciso, utilizando um receptor GNSS (*Global Navigation Satellite System*) *Stonex® S8 Plus*. Além disso, com a mesma técnica, foram determinadas as coordenadas dos vértices de todas as parcelas. Estas coordenadas e os desvios-padrão correspondentes são apresentados no Anexo A. Em seguida, um segundo voo foi realizado no dia 11 de novembro de 2024, com o objetivo de gerar um ortofotomosaico georreferenciado. Os parâmetros deste segundo voo foram os mesmos do primeiro, exceto pela área de cobertura, que foi aumentada para assegurar a captura de imagens dos PCS previamente coletados. Ressalta-se que as imagens desse segundo voo não foram utilizadas para a análise da vegetação e serviram exclusivamente para a criação de um ortofotomosaico de base, que posteriormente foi usado para georreferenciar as imagens obtidas no primeiro voo.

3.3.3. Pré-processamento das imagens

O pré-processamento das imagens levantadas nos dois voos foi conduzido com suporte do software *Agisoft Metashape®* 2.1.4 (Agisoft LLC, 2024), onde foram realizadas as seguintes etapas: eliminação das imagens de baixa qualidade; alteração do sistema de coordenadas e *datum* (Geográfica/WGS84 para UTM/SIRGAS 2000); calibração radiométrica pela função de calibração de reflectância do sensor de irradiância integrado na ARP (DJI, 2019); alinhamento das imagens gerando nuvem de pontos não densificada; filtragem de erros grosseiros; otimização das câmeras; geração da nuvem de pontos densificada, do Modelo Digital de Elevação e do ortofotomosaico.

Ressalta-se que a correção geométrica das imagens obtidas com o segundo voo foi realizada também no *Agisoft Metashape®* (Agisoft LLC, 2024), utilizando os PCS como referência. O resultado desta etapa foi a geração de um ortofotomosaico georreferenciado com erro médio de ajuste igual a 1,47 cm (Figura 6). A correção geométrica das imagens obtidas com o primeiro voo, por sua vez, foi realizada com auxílio da ferramenta “Georreferenciador” do software QGIS Desktop 3.34.7 (QGIS.org, 2024) e usando como base o ortofotomosaico georreferenciado produzido com o segundo voo. O parâmetro de transformação foi o polinomial 1 e o algoritmo de reamostragem selecionado foi a alocação de vizinho mais próximo. Como

resultado, obteve-se um ortofotomosaico georreferenciado com erro médio de 11,62 cm (Figura 7).

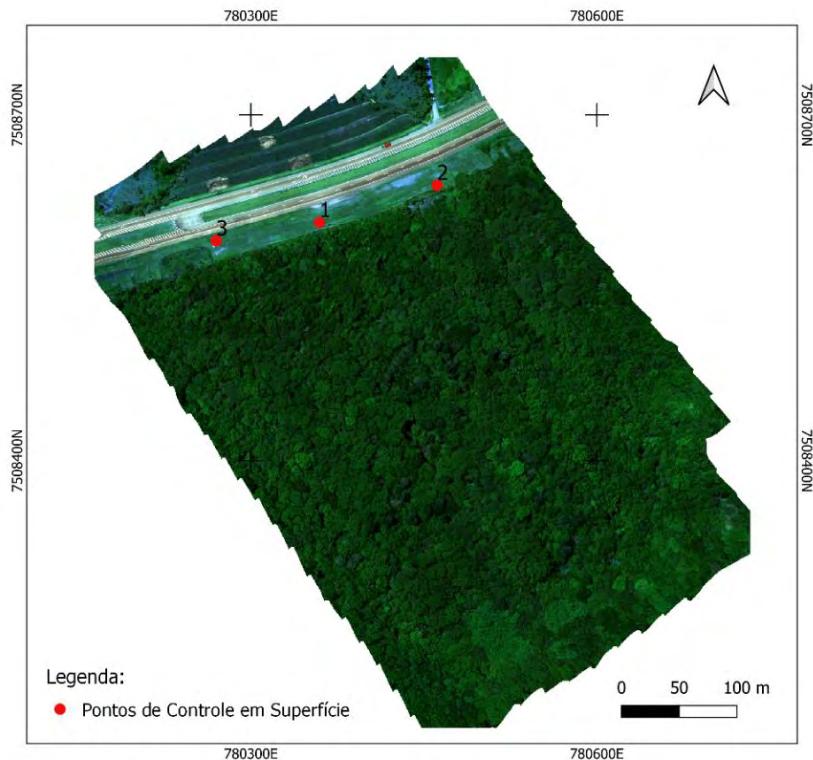


Figura 6. Ortofotomosaico produzido com as imagens levantadas no segundo voo, no dia 11 de novembro de 2024, na Reserva Biológica de Poço das Antas, Rio de Janeiro, Brasil. Os Pontos de Controle em Superfície são apresentados na cor vermelha. Fonte: Elaborado pela autora, 2024.

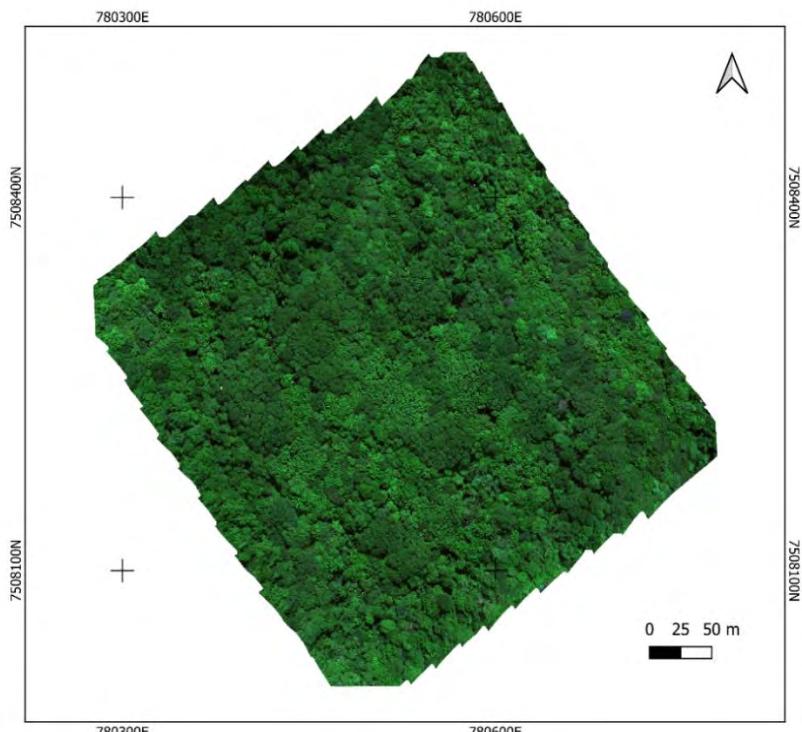


Figura 7. Ortofotomosaico produzido com as imagens levantadas no primeiro voo, no dia 04 de abril de 2024, na Reserva Biológica de Poço das Antas, Rio de Janeiro, Brasil. Fonte: Elaborado pela autora, 2024.

3.3.4. Remoção dos pixels sombreados

Conforme evidenciado por Pinon *et al.* (2024), as sombras reduzem a reflectância e podem mascarar os sinais espectrais relacionados à diferenciação de espécies. Diante disto, optou-se por remover do ortofotomosaico do primeiro voo os pixels sombreados ou não relacionados à vegetação. Para isso, realizou-se a classificação baseada em objeto utilizando o algoritmo de aprendizado de máquina *Random Forest* (RF). A primeira etapa da classificação é a segmentação do ortofotomosaico, onde os pixels são subdivididos em um conjunto de segmentos de acordo com suas propriedades, como suas informações espaciais, texturais e espectrais (Souza; Rodrigues, 2023). Neste estudo, a segmentação foi realizada com o módulo *i.segment* do GRASS no software QGIS Desktop 3.34.7 (QGIS.org, 2024) e produziu um arquivo vetorial de polígonos, em que cada polígono corresponde a um segmento.

Em seguida, em posse do ortofotomosaico e do arquivo vetorial de polígonos produzido anteriormente, foram extraídas a média e o desvio-padrão das informações espectrais de cada banda do ortofotomosaico em todos os polígonos. Este procedimento foi realizado a partir da criação de um *workflow* com o uso do Modelador Gráfico do QGis e com a ferramenta “Estatística Zonal”. Como resultado, obteve-se um arquivo vetorial de polígonos com uma tabela de atributos correspondente, que atribui a cada polígono uma identidade única, definida com base na análise estatística dos padrões espectrais das bandas.

Posteriormente, foram definidas duas classes: 1) vegetação e 2) sombras. Selecionou-se manualmente 20 amostras de cada classe no arquivo vetorial, a partir da interpretação visual do ortofotomosaico e considerando a distribuição das classes na área. As amostras foram subdivididas em duas camadas vetoriais, sendo uma para treino do algoritmo, composta por 70% das amostras, e outra para validação, com os 30% restantes. Utilizou-se a ferramenta “Seleção Aleatória Dentro de Subconjuntos” para selecionar quais amostras foram consideradas em cada camada. O treinamento e a validação do algoritmo RF foram realizados no módulo *TrainVectorClassifier* do pacote de programação Orfeo ToolBox (OTB). As análises estatísticas das informações espectrais de cada amostra foram aplicadas como recursos de treinamento. Produziu-se um modelo de treinamento com Índice Kappa Global (K) igual a 1, gerado pela matriz de confusão de validação no OTB. Esse modelo foi aplicado em todo o ortofotomosaico com o módulo *VectorClassifier* do OTB e gerou uma camada vetorial com a divisão das classes. Por fim, o ortofotomosaico foi recortado a partir desta camada. Os pixels sombreados foram classificados como “*no data*”, permanecendo na imagem os pixels iluminados e representativos da vegetação (Figura 8).

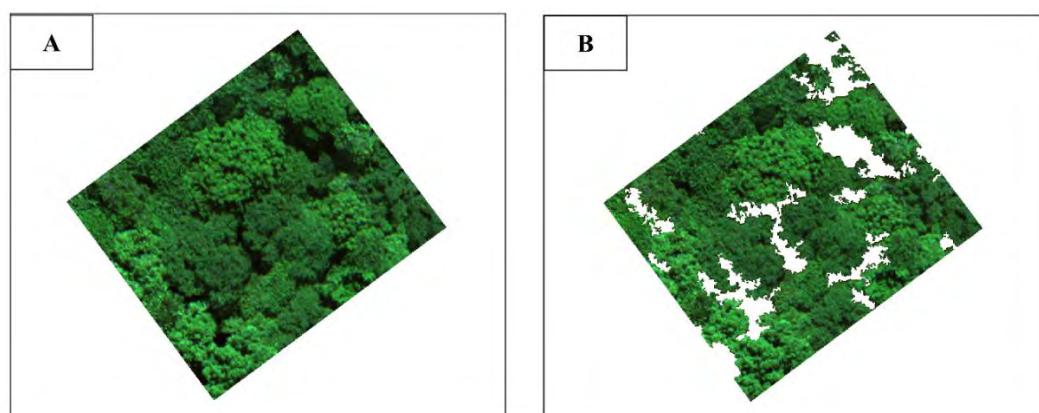


Figura 8. Representação da remoção dos pixels sombreados no ortofotomosaico. (A) Ortofotomosaico produzido a partir das imagens levantadas com sensor multiespectral; (B) Imagem gerada a partir da remoção dos pixels sombreados com classificação com algoritmo Random Forest. Fonte: Elaborado pela autora, 2024.

3.3.5. Cálculo dos índices de vegetação

Para o cálculo dos índices de vegetação, foram consideradas duas abordagens: 1) a partir do ortofotomosaico contendo apenas os pixels iluminados, e 2) a partir do ortofotomosaico original, contendo todos os pixels. Desse modo, calculou-se 12 índices de vegetação (Tabela 3), utilizando-se a ferramenta “Calculadora Raster” do software QGIS Desktop 3.34.7 (QGIS.org, 2024). Posteriormente, com suporte da operação “Estatística Zonal”, foram obtidos a média e o desvio-padrão de cada índice nas parcelas experimentais.

Tabela 3. Índices de vegetação calculados utilizando dados espectrais obtidos com drone.

Índice de vegetação	Equação	Referência
Índices normalizados		
Blue Normalized Difference Vegetation Index (BNDVI)	$BNDVI = \frac{(NIR - B)}{(NIR + B)}$	Yang <i>et al.</i> , 2004
Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = \frac{(NIR - G)}{(NIR + G)}$	Gitelson; Kaufman; Merzlyak, 1996
Normalized Difference Red Edge (NDRE)	$NDRE = \frac{(NIR - RedEdge)}{(NIR + RedEdge)}$	Barnes <i>et al.</i> , 2000
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{(NIR - R)}{(NIR + R)}$	Rouse <i>et al.</i> , 1974
Normalized Green Red Difference Index (NGRDI)	$NGRDI = \frac{(Green - R)}{(Green + R)}$	Tucker, 1979
Índice Não Linear (NLI)	$NLI = \frac{(NIR^2 - R)}{(NIR^2 + R)}$	Goel; Qin, 1994
Visible Difference Vegetation Index (VDVI)	$VDVI = \frac{(2 * G - R - B)}{(2 * G + R + B)}$	Wang <i>et al.</i> , 2015
Índices não-normalizados		
Chlorophyll Red-Edge Index (CI.RedEdge)	$CL.RedEdge = \frac{NIR}{RedEdge} - 1$	Gitelson; Gritz; Merzlyak, 2003; Gitelson; Keydan; Merzlyak, 2006
Enhanced Vegetation Index (EVI)	$EVI = 2,5 * \left(\frac{NIR - R}{NIR + 6 * R - 7,5 * B + 1} \right)$	Huete <i>et al.</i> , 1997; Huete <i>et al.</i> , 2002
Excess Green Index (ExG)	$ExG = 2 * G - R - B$	Woebbecke <i>et al.</i> , 1995
Simple Ratio (SR)	$SR = \frac{NIR}{R}$	Jordan, 1969
Triangle Greenness Index (TGI)	$TGI = G - 0,39 * R - 0,61 * B$	Hunt Jr. <i>et al.</i> , 2013

em que: R é a reflectância proveniente do canal vermelho da região do visível; G é a reflectância proveniente do canal verde da região do visível; B é a reflectância proveniente do canal azul da região do visível; RedEdge é a reflectância proveniente do canal da borda do vermelho, e NIR é a reflectância proveniente do canal do infravermelho próximo.

Os índices de vegetação (IVs) calculados podem ser divididos em duas categorias: os normalizados e os não-normalizados. Os IVs normalizados utilizam a diferença entre duas bandas espectrais dividida pela soma das mesmas. Ressalta-se que a vantagem da normalização é a capacidade de minimizar os efeitos de fatores externos, como variações sazonais de iluminação (Rouse *et al.*, 1974). Além disso, os IVs podem ser divididos em outras duas categorias, aqueles que utilizam a banda do visível (azul, verde e vermelho) e os multiespectrais. O NDVI, por exemplo, é um índice multiespectral normalizado amplamente utilizado, proposto por Rouse *et al.* (1974). Este índice está correlacionado com a biomassa verde acima do solo, mas tende a exibir sinais saturados em condições de alta biomassa (Huete, 1988). O NLI, por outro lado, pode ser mais sensível em casos de vegetação densa (Goel; Qin, 1994). Os demais índices multiespectrais normalizados permitem examinar as contribuições das bandas azul (BNDVI), verde (GNDVI) e borda do vermelho (NDRE). Ressalta-se que o GNDVI é considerado mais sensível à concentração de clorofila do que o NDVI (Gitelson; Kaufman; Merzlyak, 1996). Por fim, o NGRDI e o VDVI são capazes de distinguir a vegetação utilizando apenas a banda visível.

No que diz respeito aos índices não-normalizados, pode-se destacar o SR, índice multiespectral baseado no princípio de que as folhas das plantas absorvem mais luz vermelha do que infravermelha (Jordan, 1969). O EVI, que também se relaciona com a biomassa verde, é considerado resistente ao solo e à atmosfera, e possui uma sensibilidade aprimorada em regiões de alta biomassa (Huete *et al.*, 1997; Huete *et al.*, 2002). O Cl.RedEdge está relacionado ao conteúdo de clorofila foliar, e assim, fornece informações sobre o estado fisiológico das plantas (Gitelson; Gritz; Merzlyak, 2003; Gitelson; Keydan; Merzlyak, 2006). O ExG foi elaborado para distinguir material vegetal vivo de um fundo não vegetal (Woebbecke *et al.*, 1995) e, por fim, o TGI expressa relação com o conteúdo de clorofila nas folhas das copas (Hunt Jr. *et al.*, 2013). A Figura 9 esquematiza todas as etapas metodológicas da coleta de dados remotos e os Apêndices A e B exibem os mapas com os índices de vegetação calculados.

Dados remotos

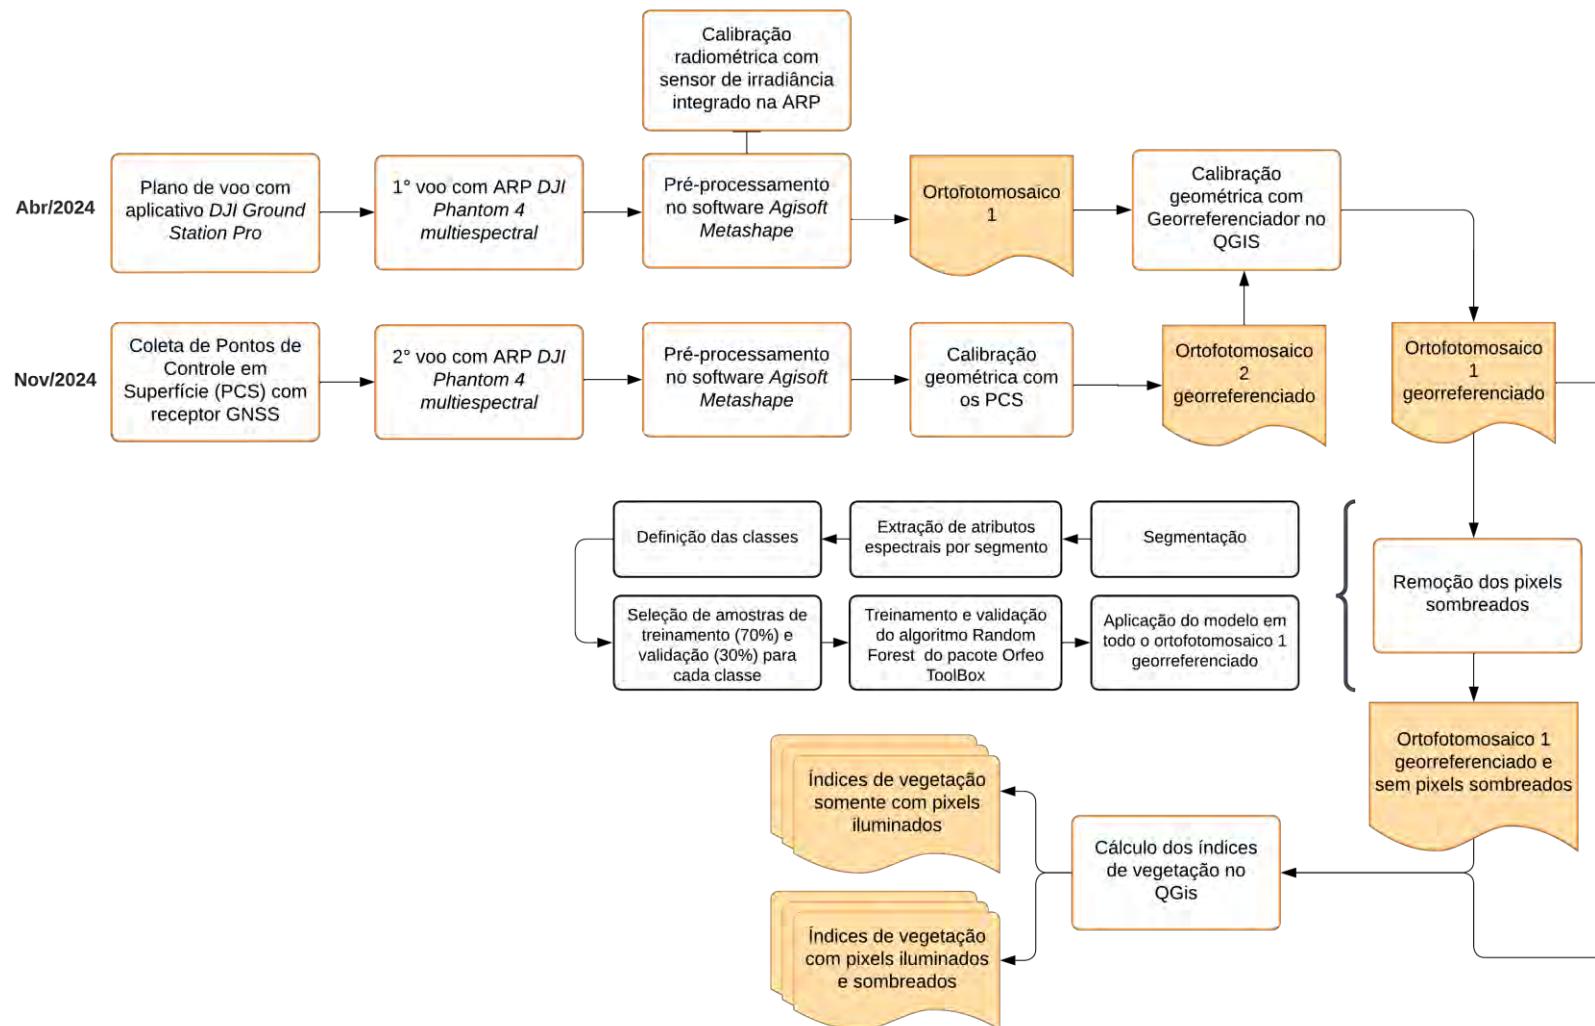


Figura 9. Fluxograma metodológico para calcular os índices espectrais de vegetação com sensor multiespectral aerotransportado na área de estudo. Fonte: Elaborado pela autora, 2024.

3.4. Análise dos dados

As análises estatísticas foram realizadas no software R (R Core Team, 2024) e a Figura 10 esquematiza esta etapa. Com o objetivo de responder a hipótese 1 (as medidas de composição funcional, diversidade funcional e diversidade taxonômica são diferentes entre os tratamentos baseados em grupos sucessionais) e a hipótese 2 (as medidas dos índices de vegetação obtidos com drone são diferentes entre os tratamentos baseados em grupos sucessionais), os diferentes plantios baseados em grupos sucessionais foram comparados em relação aos índices de composição, diversidade funcional, diversidade taxonômica, e à média e ao desvio-padrão dos IVs. Inicialmente, foi verificada a normalidade dos resíduos pelo teste de Shapiro-Wilk e a homogeneidade das variâncias pelo teste de Bartlett, ambos ao nível de significância de 5%. Como os pressupostos não foram atendidos para todas as variáveis, optou-se pelo teste não-paramétrico de Kruskal-Wallis, seguido do teste de Conover para determinar quais grupos diferem entre si, considerando o nível de significância de 5%. Essas análises foram realizadas com auxílio das funções do pacote “stats” do R (R Core Team, 2024).

Em seguida, para explorar as variáveis e identificar padrões, foram aplicadas a Análise de Agrupamento Hierárquico e a Análise de Componentes Principais (PCA). O número ideal de clusters foi determinado com base na soma dos quadrados dentro dos clusters. O Agrupamento Hierárquico foi conduzido utilizando a métrica de dissimilaridade Euclidiana para calcular a matriz de distância e a ligação entre clusters foi realizada pelo método aglomerativo de Ward. A estrutura do agrupamento foi visualizada por meio de dendrogramas. Para a PCA, os dados foram padronizados e os resultados foram visualizados em biplots. Foram utilizadas as funções dos pacotes “stats” e “factoextra” (Kassambara; Mundt, 2020) nestas análises.

Com o objetivo de avaliar a hipótese 3 (as medidas dos índices de vegetação obtidos com drone são correlacionadas com as medidas de composição funcional, diversidade funcional e diversidade taxonômica), a média e o desvio padrão de cada IV por parcela foi correlacionada com os índices de composição funcional, diversidade funcional e diversidade taxonômica por meio da correlação de Spearman. Para cada par de variáveis, foi realizado o teste de significância associado ao coeficiente de correlação, com o nível de significância de 5%. As análises foram realizadas com auxílio das funções “stats” e “Hmisc” (Harrell Jr, 2024). Além disso, foram realizadas análises de regressão linear simples e múltipla. Nos modelos de regressão simples, as variáveis respostas foram selecionadas com base na Análise de Agrupamento Hierárquico, a fim de incluir pelo menos uma variável por grupo. As variáveis preditoras foram selecionadas considerando as maiores correlações de Spearman com os dados de campo e, quando possível, com a priorização dos índices de vegetação normalizados. Além disso, para os modelos de regressão simples, foram consideradas todas as abordagens (variável resposta ponderada pela abundância e ponderada pelo produto entre a área de copa e a altura; variável preditora com sombras e sem sombras).

Nos modelos de regressão múltipla, por sua vez, a seleção das variáveis respostas priorizou o componente funcional da biodiversidade. As variáveis preditoras foram selecionadas utilizando o método de regressão LASSO (*Least Absolute Shrinkage and Selection Operator*), conforme sugerido por Fonti e Belitser (2017) e, ainda, desconsiderando as variáveis com alta multicolinearidade, determinada com o fator de inflação da variância. Ressalta-se que o método de regressão LASSO é capaz de listar as variáveis mais relevantes para um determinado modelo a partir de uma penalização ao valor absoluto dos coeficientes das variáveis (Fonti; Belitser, 2017). Nesta etapa, foram utilizadas as funções dos pacotes “caret” (Kuhn, 2008) e “car” (Fox; Weisberg, 2019).

Por fim, para todos os modelos de regressão linear simples e múltipla, os pressupostos de normalidade dos resíduos e de homogeneidade das variâncias foram verificados pelos testes

de Shapiro-Wilk e de Breusch-Pagan (ambos com um nível de significância de 5%), respectivamente. A significância dos coeficientes foi avaliada usando o teste *t* com um nível de significância de 5%. A comparação dos modelos foi realizada considerando o valor do coeficiente de determinação e o valor do AIC (*Akaike Information Criterion*). Os modelos com o menor valor de AIC e o maior valor de R^2 foram considerados os que melhor explicam a variabilidade da variável resposta. Para estas análises foram utilizadas funções dos pacotes “stats” e “lmtest” (Zeileis; Hothorn, 2002). O pacote “ggplot2” (Wickham, 2016) foi utilizado para visualização gráfica dos resultados.

Análise de dados

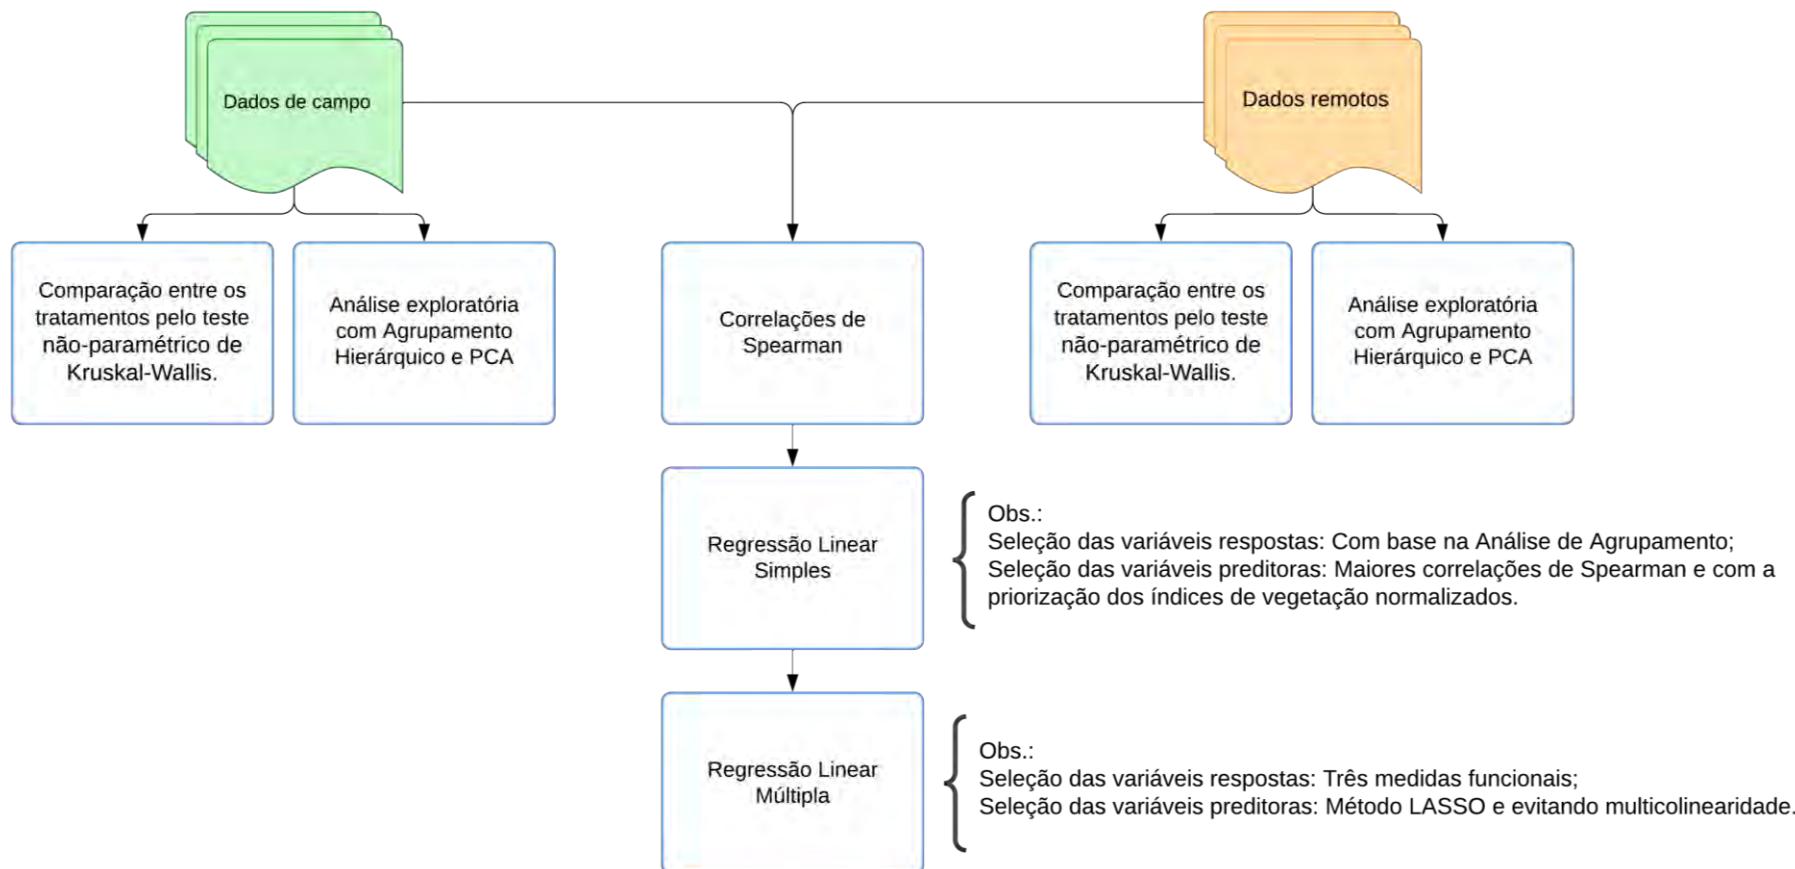


Figura 10.Fluxograma metodológico da análise dos dados obtidos em campo e remotamente. Fonte: Elaborado pela autora, 2024.

4. RESULTADOS

4.1. Composição e diversidade da comunidade de plantas

Um total de 1065 indivíduos arbóreos, distribuídos em 50 espécies e 26 famílias botânicas foram registradas em toda área experimental (Apêndice C). As famílias mais abundantes foram Meliaceae (329 indivíduos), Fabaceae (181), Euphorbiaceae (128) e Melastomataceae (81). Os Apêndices D - I apresentam a abundância das espécies presentes em cada tratamento, assim como a soma da área basal e da área de copa por espécie. Além disso, o Apêndice J exibe os valores dos atributos funcionais obtidos por espécie.

Os resultados do teste não-paramétrico de Kruskall-Wallis indicaram que os tratamentos apresentaram diferenças estatísticas significativas em relação à Riqueza Taxonômica ($H = 17,08$, $p = 0,0038$), à Equabilidade ($H = 14,06$; $p = 0,0152$), ao Índice de Shannon-Weaver ($H = 13,92$; $p = 0,0160$), às Médias do Teor de Matéria Seca Foliar, tanto a ponderada pela abundância ($H = 13,20$; $p = 0,0216$) quanto a ponderada pelo produto entre a área de copa e a altura ($H = 14,24$; $p = 0,0142$), e à Média da Área Foliar, ponderada pela abundância ($H = 12,32$; $p = 0,0307$) e pelo produto entre a área de copa e a altura ($H = 17,66$; $p = 0,0034$). Por outro lado, não foram observadas diferenças entre os tratamentos para os dados de diversidade funcional. As Figuras 11, 12 e 13 apresentam os boxplots dos índices de diversidade taxonômica, de composição funcional e de diversidade funcional, respectivamente, assim como as letras das grupos de acordo com as comparações múltiplas do teste Conover.

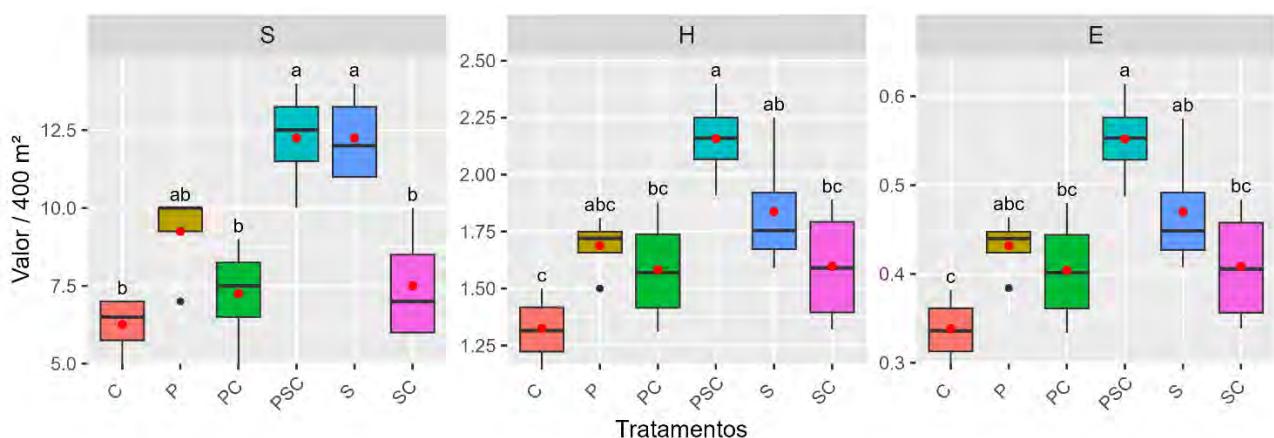


Figura 11. Boxplots das variáveis taxonômicas: Riqueza (S), Índice de Shannon-Weaver (H) e Equabilidade (E). Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$) no teste de Conover. Fonte: Elaborado pela autora, 2024.

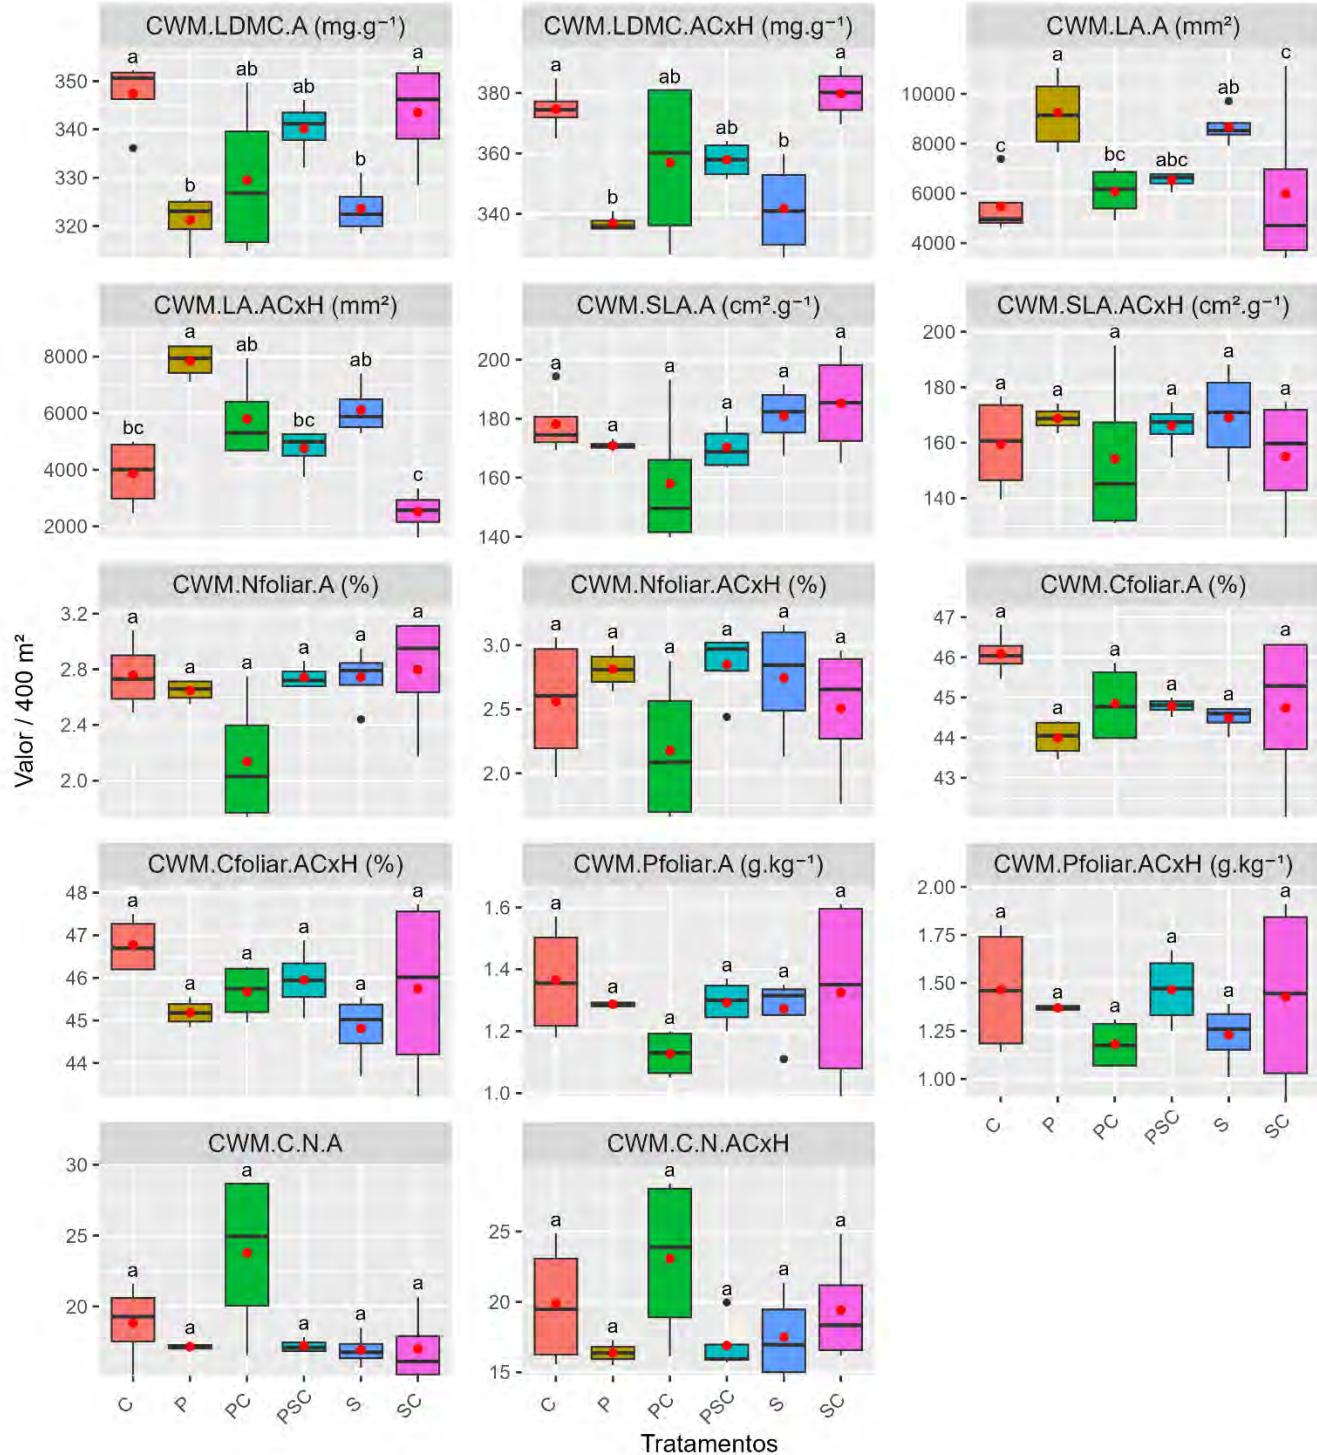


Figura 12. Boxplots das medidas de composição funcional ponderadas pela comunidade: Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Códigos: “A” = Ponderado pela abundância e “ACxH” = Ponderado pelo produto entre área de copa e altura. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$) no teste de Conover. Fonte: Elaborado pela autora, 2024.

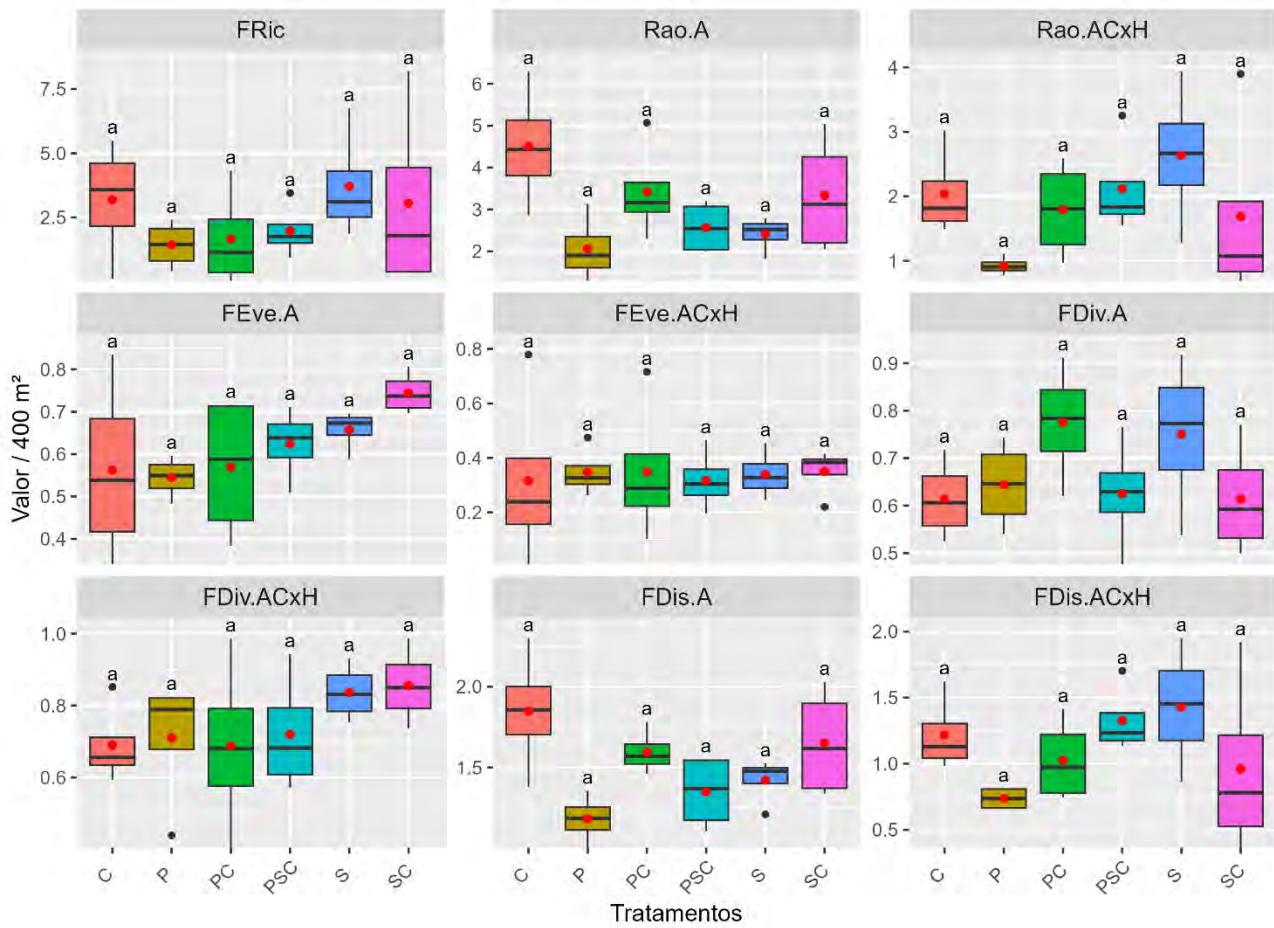


Figura 13. Boxplots dos índices de diversidade funcional: Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), e Dispersão funcional (FDis). Códigos: “A” = Ponderado pela abundância e “ACxH” = Ponderado pelo produto entre área de copa e altura. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$) no teste de Conover. Fonte: Elaborado pela autora, 2024.

As Figuras 14 e 15, geradas a partir da Análise de Agrupamento Hierárquico, apresentam como as medidas de composição funcional, diversidade funcional e diversidade taxonômica se agrupam com base em sua similaridade. As variáveis ponderadas pela abundância (Figura 14) foram organizadas em quatro clusters principais. As Médias do Carbono Foliar (CWM.Cfoliar.A), do Teor de Matéria Seca Foliar (CWM.LDMC.A) e da Equabilidade Funcional (FEve.A) formaram um grupo bem definido. Além disso, a Média da Área Foliar (CWM.LA.A) se destacou por apresentar características similares à Riqueza Funcional (FRic) e aos dados de diversidade taxonômica (S, H e E). Nas variáveis ponderadas pelo produto entre a área de copa e a altura (Figura 15) também houve a formação de quatro clusters principais. Nesse caso, destacou-se o grupo distinto apenas com a Entropia Quadrática de Rao (Rao.ACxH) e a Dispersão Funcional (FDis.ACxH).

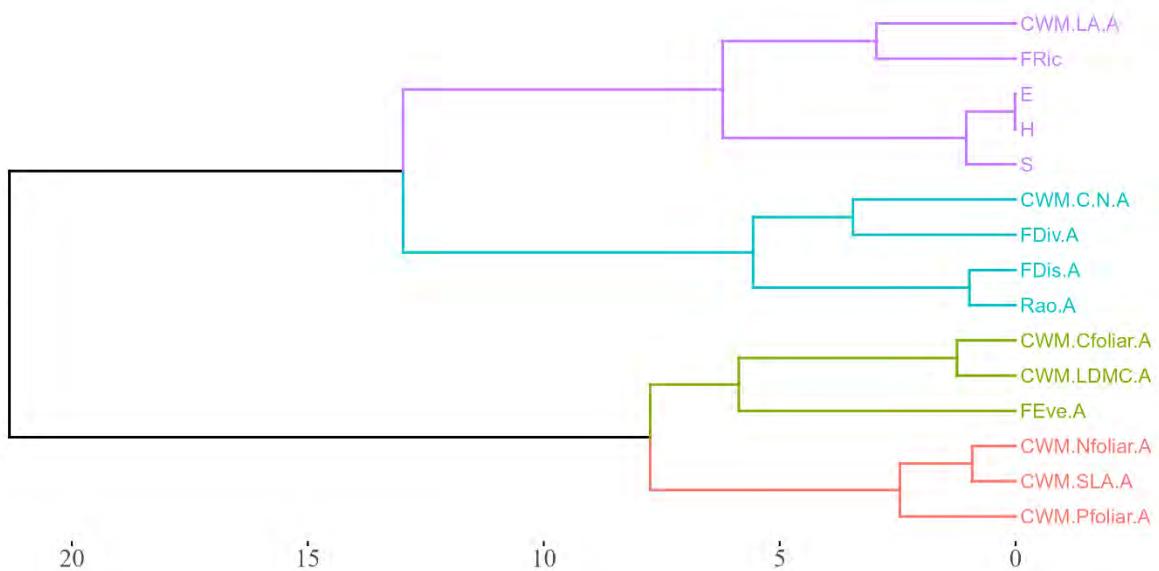


Figura 14. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “A” = Ponderado pela abundância. Fonte: Elaborado pela autora, 2024.

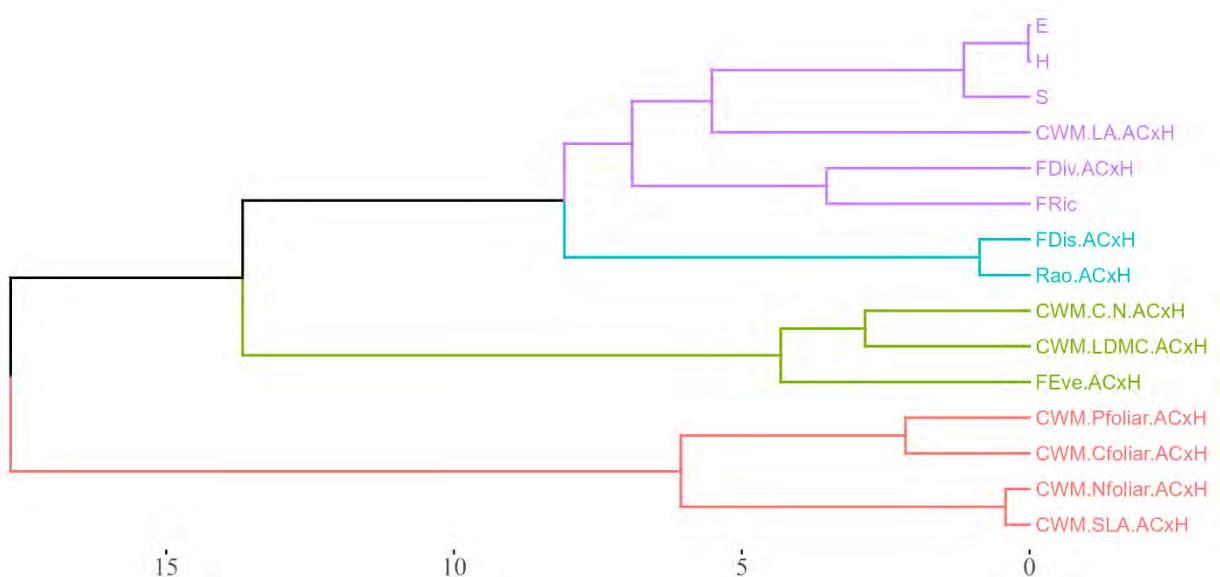


Figura 15. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “ACxH” = Ponderado pelo produto entre a área de copa e a altura. Fonte: Elaborado pela autora, 2024.

A Figura 16 representa a Análise de Componentes Principais (*Principal Component Analysis* – PCA) das medidas de composição e diversidade funcional ponderadas pela abundância, assim como da Riqueza Funcional e dos índices de diversidade taxonômica. Observou-se tendência de agrupamento, o que sugere que os índices mais correlacionados estão associados aos mesmos componentes principais. O primeiro componente da PCA explicou 33,1% da variabilidade total dos dados e foi influenciado principalmente pelas Médias Ponderadas de Carbono Foliar (CWM.Cfoliar), com peso de 0,39, e de Fósforo Foliar (CWM.Pfoliar), com peso de 0,35. Por outro lado, o segundo componente explicou 27,4% da variabilidade e teve forte influência da Média Ponderada da Razão Carbono/Nitrogênio (CWM.C.N), com peso igual a 0,45.

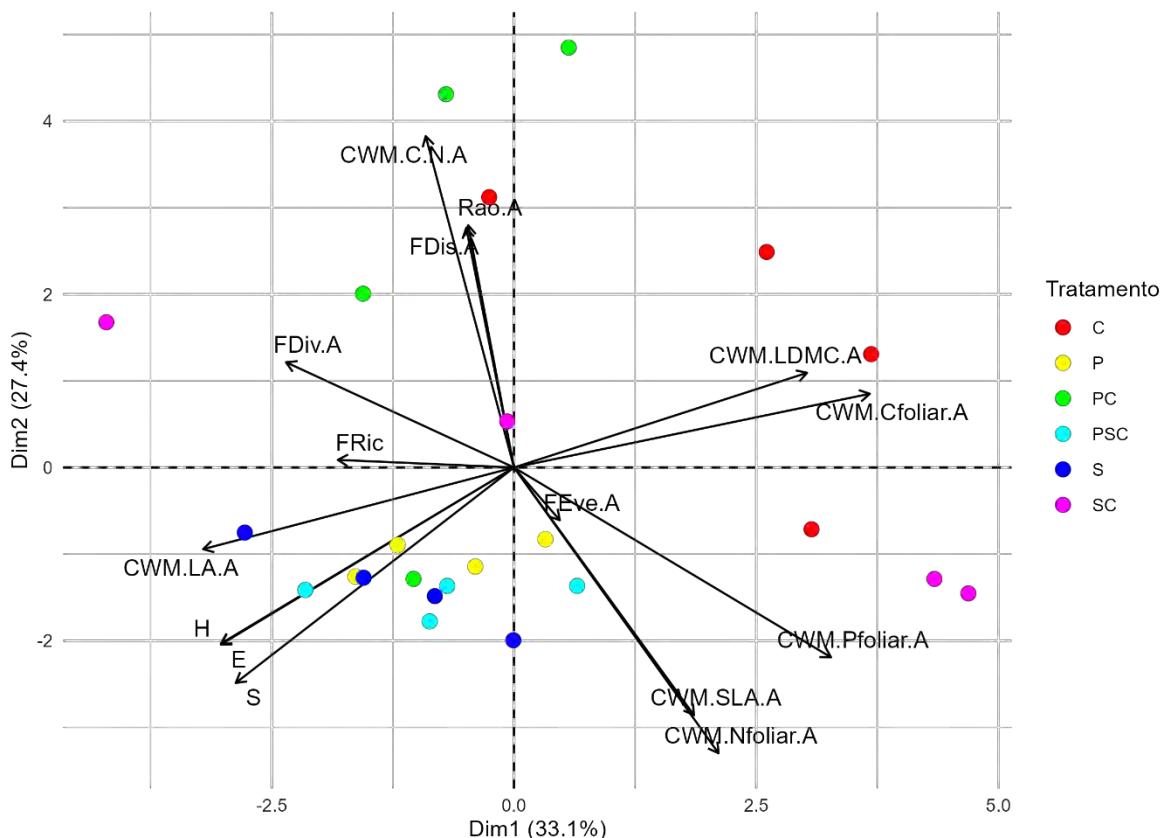


Figura 16. Análises de Componentes Principais. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEve), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “A” = Ponderado pela abundância. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.

A Análise de Componentes Principais das medidas funcionais ponderadas pelo produto entre a área de copa e altura, assim como da Riqueza Funcional e dos índices de diversidade taxonômica, é apresentada na Figura 17. O primeiro componente da PCA explicou 29,5% da variabilidade dos dados e teve forte influência da Média Ponderada do Teor de Matéria Seca Foliar (CWM.LDMC), com peso de 0,35. O segundo componente, por sua vez, explicou 28% da variabilidade, com influência das Médias Ponderadas de Fósforo Foliar (CWM.Pfoliar), com peso de 0,44, e de Nitrogênio Foliar (CWM.Nfoliar), com peso igual a 0,42.

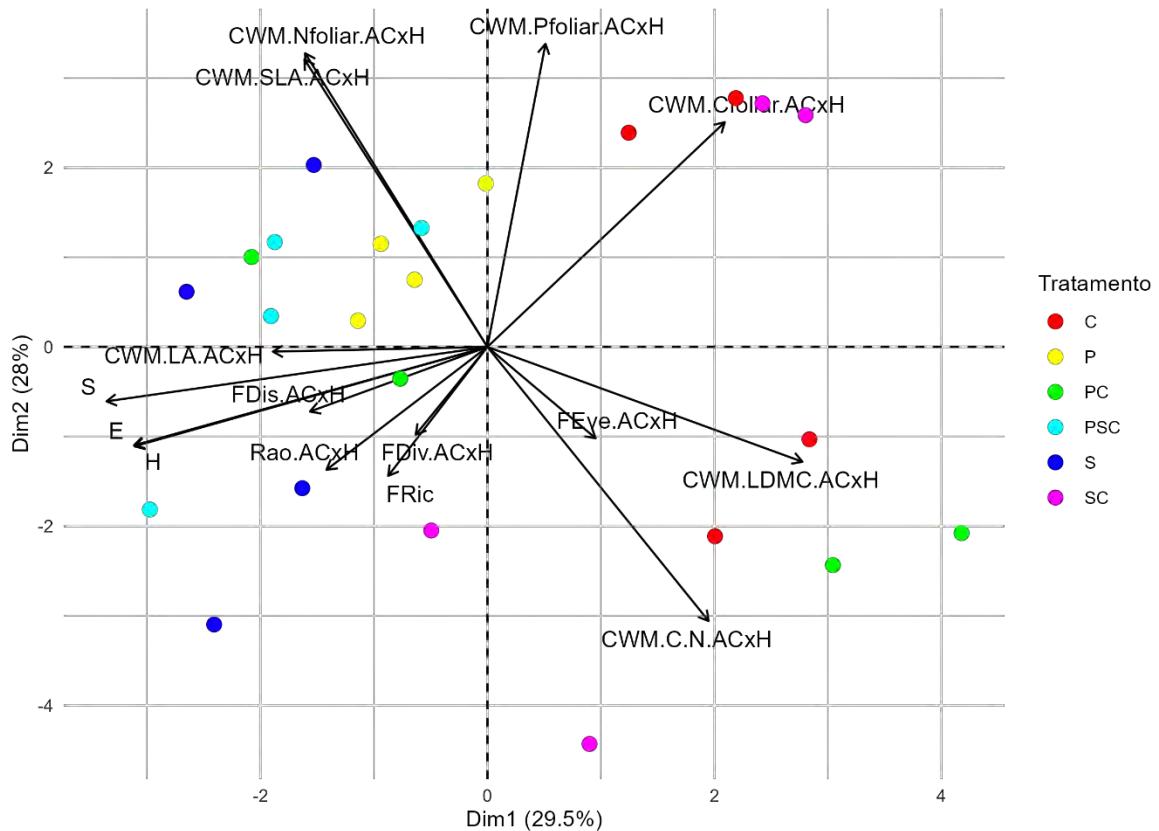


Figura 17. Análises de Componentes Principais. Variáveis: Riqueza (S), Índice de Shannon-Weaver (H), Equabilidade (E), Riqueza funcional (FRic), Entropia quadrática de Rao (Rao), Equabilidade funcional (FEye), Divergência funcional (FDiv), Dispersão funcional (FDis), Média do Teor de Matéria Seca Foliar (CWM.LDMC), Média da Área Foliar (CWM.LA), Média da Área Foliar Específica (CWM.SLA), Média do Teor de Nitrogênio Foliar (CWM.Nfoliar), Média do Teor de Carbono Foliar (CWM.Cfoliar), Média do Teor de Fósforo Foliar (CWM.Pfoliar), e Média da Razão Carbono/Nitrogênio (CWM.C.N). Código: “ACxH” = Ponderado pelo produto entre a área de copa e a altura. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.

4.2. Índices de vegetação obtidos com drone

No que diz respeito aos índices de vegetação, apenas a média do *Simple Ratio* calculada a partir do ortofotomosaico original, contendo todos os pixels iluminados e sombreados (SR.tp.mean), apresentou diferenças estatísticas significativas ($H = 12,83$; $p = 0,0250$) entre os tratamentos pelo teste não-paramétrico de Kruskall-Wallis. A Figura 18 apresenta o boxplot deste índice com as letras dos grupos de acordo com as comparações múltiplas do teste de Conover.

O dendrograma gerado para a média e o desvio-padrão dos índices obtidos com todos os pixels iluminados e sombreados (Figura 19) mostrou a formação de quatro grupos. As médias do *Green Normalized Difference Vegetation Index* (GNDVI), do *Normalized Difference Red Edge* (NDRE) e do *Chlorophyll Red-Edge Index* (CI.RedEdge), por exemplo, apresentaram maior similaridade. Além disso, as médias do *Enhanced Vegetation Index* (EVI), do *Simple Ratio* (SR), do Índice Não Linear (NLI), do *Blue Normalized Difference Vegetation Index* (BNDVI) e do *Normalized Difference Vegetation Index* (NDVI) formaram outro grupo. Percebeu-se, ainda, que estas mesmas variáveis continuam agrupadas no dendrograma com os índices obtidos sem os pixels sombreados (Figura 20).

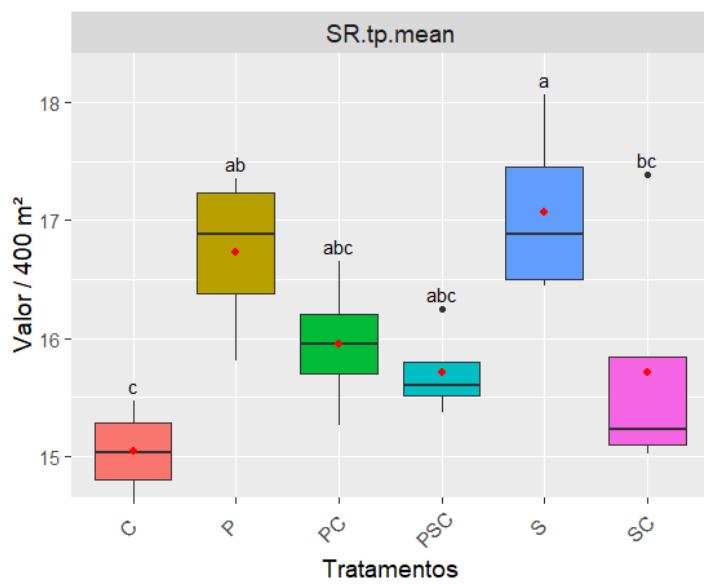


Figura 18. Boxplot da média índice de vegetação *Simple Ratio* calculado com o ortofotomosaico original, contendo todos os pixels iluminados e sombreados. Código: “tp” = todos os pixels. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias e SC = Secundárias + Clímax. As médias são representadas pelos pontos vermelhos. Barras seguidas pela mesma letra não diferem significativamente entre si ($p > 0,05$). Fonte: Elaborado pela autora, 2024.

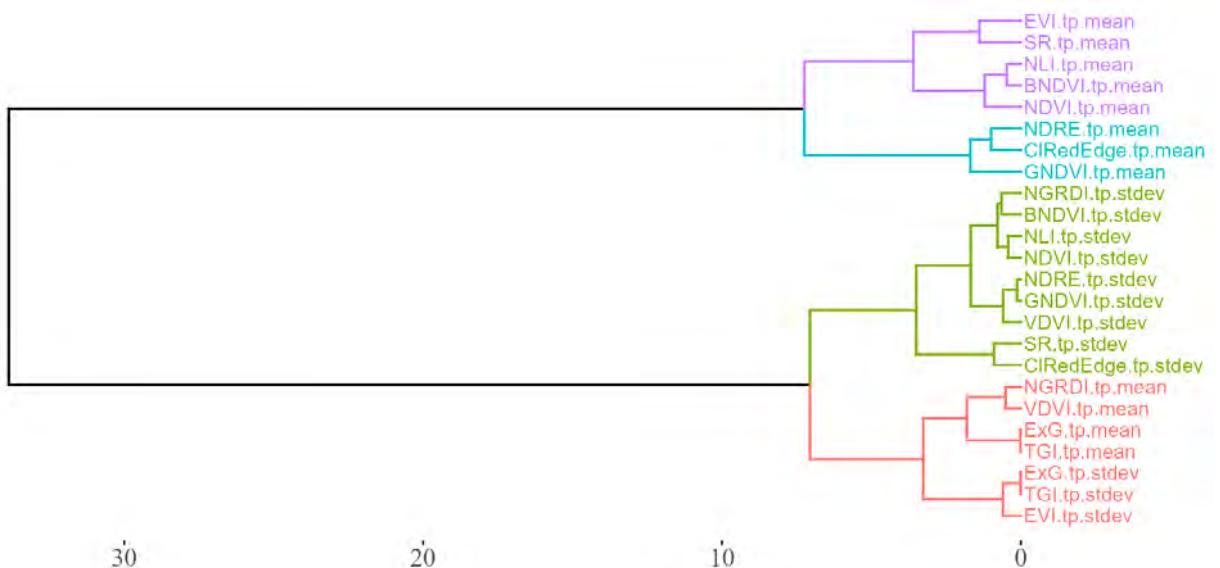


Figura 19. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “tp” = calculado a partir do ortofotomosaico com todos os pixels; “mean” = média, “stdev” = desvio-padrão. Fonte: Elaborado pela autora, 2024.

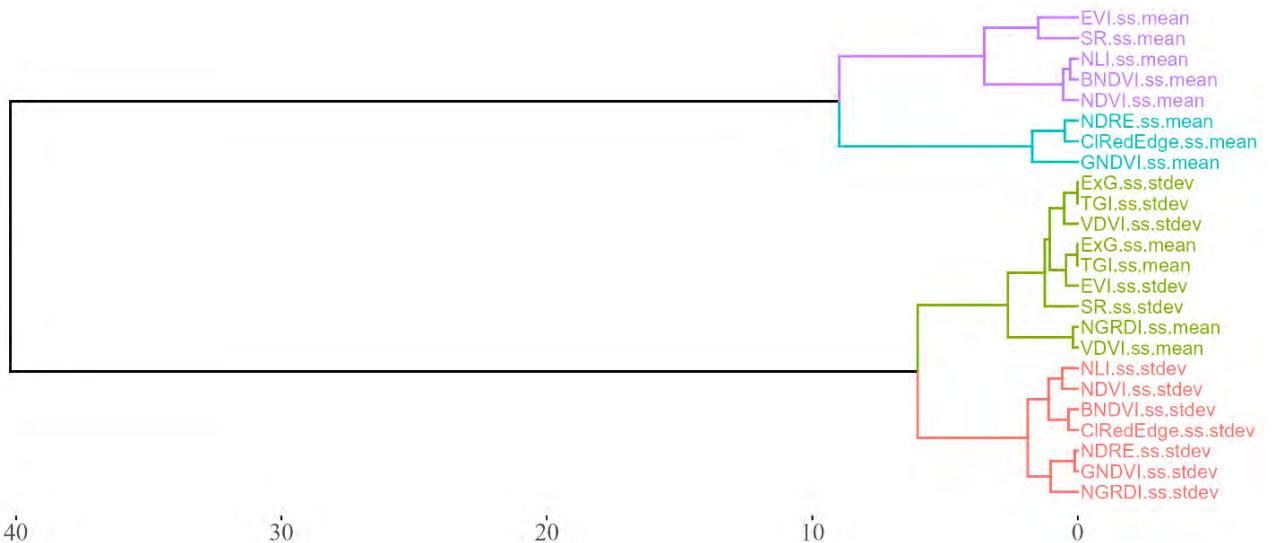


Figura 20. Dendrograma gerado pela análise de agrupamento hierárquico. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; “mean” = média, “stdev” = desvio-padrão. Fonte: Elaborado pela autora, 2024.

A Figura 21 representa a Análise de Componentes Principais dos índices de vegetação calculados a partir do ortofotomosaico com todos os pixels. O primeiro componente da PCA explicou 54,4% da variabilidade total dos dados e foi influenciado, entre outros parâmetros, pelos desvios-padrão do GNDVI (0,27), do NDRE (0,26) e do VDVI (0,26). O segundo componente, por sua vez, explicou 23% da variabilidade e teve forte influência das médias do NDVI (0,34), do NLI (0,34) e do BNDVI (0,33). Além disso, a PCA dos índices de vegetação calculados a partir do ortofotomosaico sem as sombras é apresentada na Figura 22. Nesse caso, o primeiro componente da PCA explicou 61,7% da variabilidade total dos dados e teve influência, por exemplo, dos desvios-padrão do GNDVI (0,25) e do NDRE (0,25). Por outro lado, o segundo componente explicou 23,8% da variabilidade, com forte influência das médias do NDVI (0,39) e do SR (0,41).

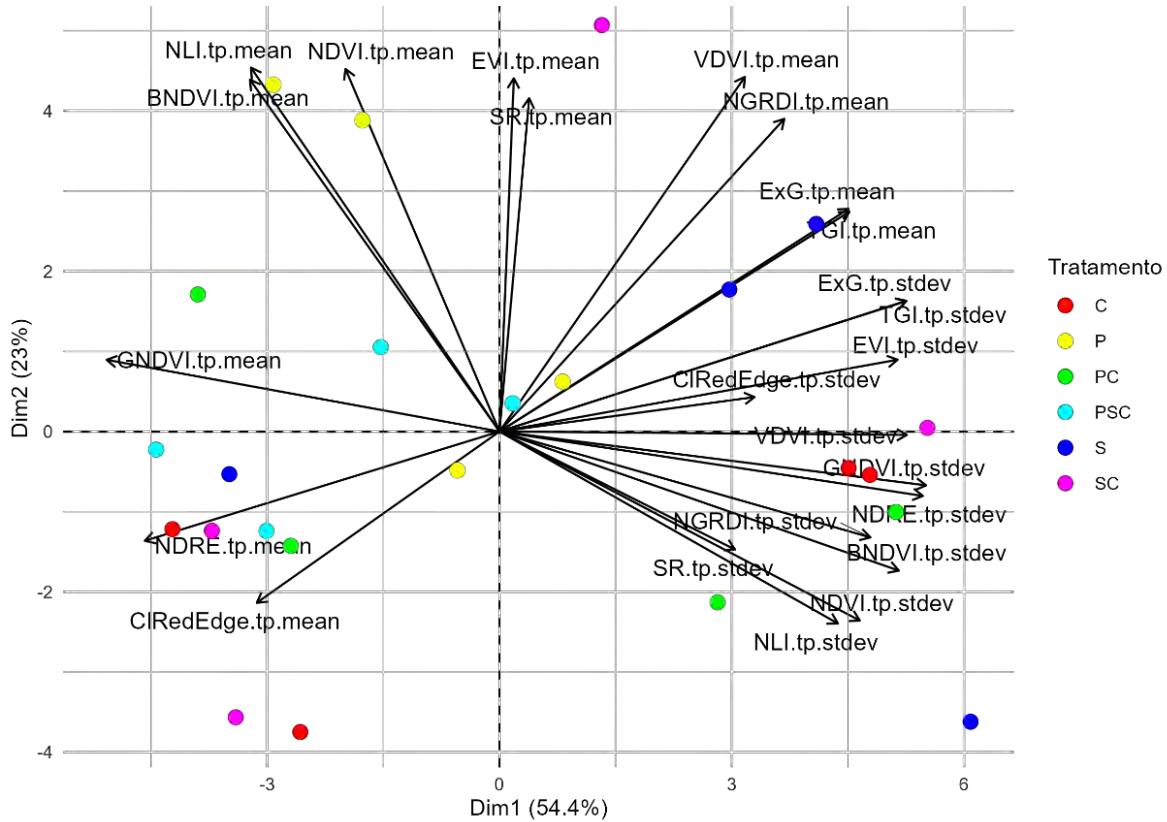


Figura 21. Análises de Componentes Principais. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), *Índice Não Linear* (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “tp” = Calculado a partir do ortofotomosaico com todos os pixels; “mean” = média, “stdev” = desvio-padrão. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.

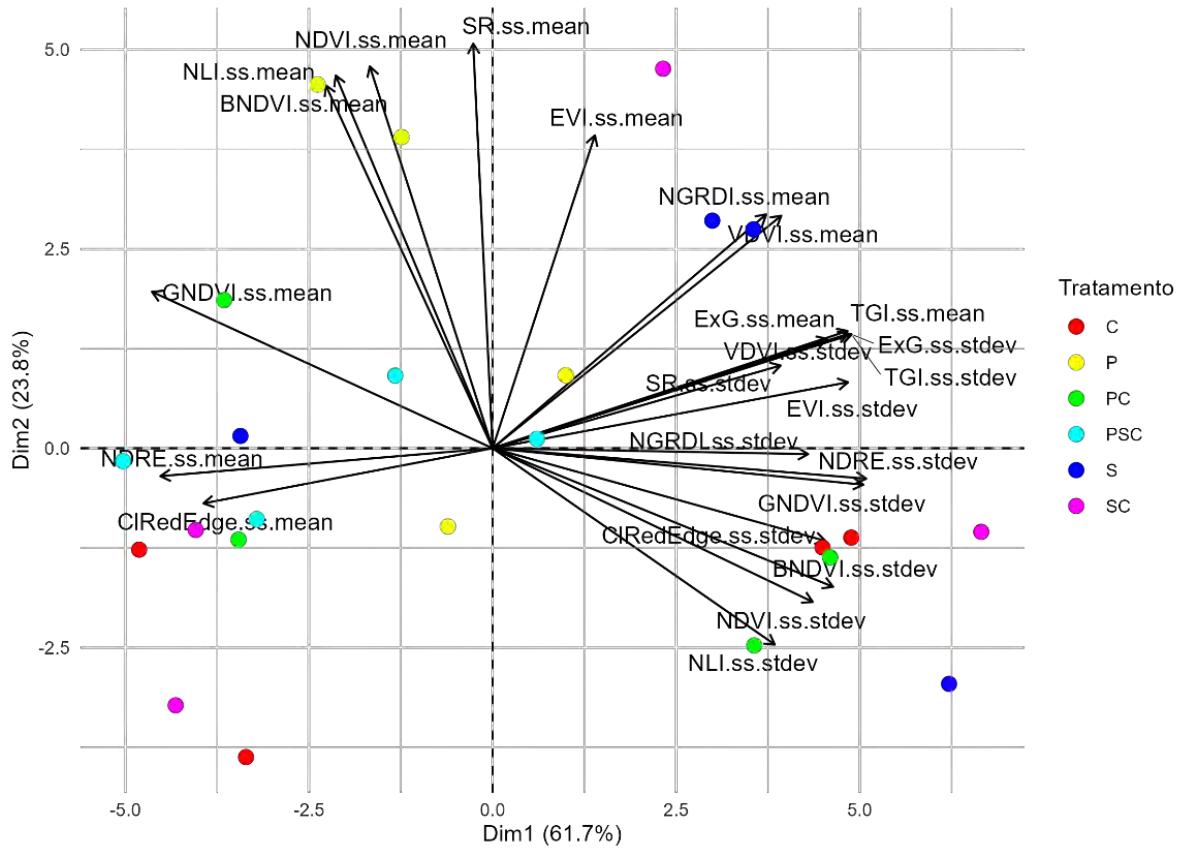


Figura 22. Análises de Componentes Principais. Variáveis: *Blue Normalized Difference Vegetation Index* (BNDVI), *Green Normalized Difference Vegetation Index* (GNDVI), *Normalized Difference Red Edge* (NDRE), *Normalized Difference Vegetation Index* (NDVI), *Normalized Green Red Difference Index* (NGRDI), Índice Não Linear (NLI), *Visible Difference Vegetation Index* (VDVI), *Chlorophyll Red-Edge Index* (CI.RedEdge), *Enhanced Vegetation Index* (EVI), *Excess Green Index* (ExG), *Simple Ratio* (SR), *Triangle Greenness Index* (TGI). Código: “ss” = Calculado a partir do ortofotomosaico sem as sombras; “mean” = média, “stdev” = desvio-padrão. Tratamentos: C = Clímax, P = Pioneiras, PC = Pioneiras + Clímax, PSC = Pioneiras + Secundárias + Clímax, S = Secundárias, e SC = Secundárias + Clímax. Fonte: Elaborado pela autora, 2024.

4.3. Correlações de Spearman

As correlações de Spearman entre os valores de diversidade taxonômica, diversidade funcional e composição funcional medidos em campo e as médias dos índices de vegetação obtidos com drone são mostradas na Figura 23. Percebeu-se que, de modo geral, as associações foram mais significativas para os dados de composição funcional, em ambas as abordagens de ponderação aplicadas. Destaca-se a correlação inversamente proporcional ($\rho = -0,85$) entre a Média do Teor de Fósforo ponderada pelo produto entre a área de copa e a altura (CWM.Pfoliar.ACxH) com a média do *Visible Difference Vegetation Index* calculado com os pixels iluminados (VDVI.ss.mean). Além disso, a Média da Área Foliar ponderada pelo produto entre a área de copa e altura (CWM.LA.ACxH) se correlacionou positivamente ($\rho = 0,65$) com a média do *Simple Ratio* calculado com todos os pixels (SR.tp.mean). No que diz respeito aos dados de diversidade funcional, os que foram ponderados pela abundância apresentaram mais associações significativas com as médias dos índices de vegetação. A Dispersão Funcional (FDis.A), por exemplo, se correlacionou com a média do *Green Normalized Difference Vegetation Index* (GNDVI), tanto o obtido com todos os pixels ($\rho = -0,63$) quanto o obtido com os pixels iluminados ($\rho = -0,61$). Os dados de diversidade taxonômica, por outro lado,

apresentaram correlações baixas ($\rho \sim 0,40$), porém significativas, com as médias do *Simple Ratio* e *Normalized Difference Vegetation Index*.

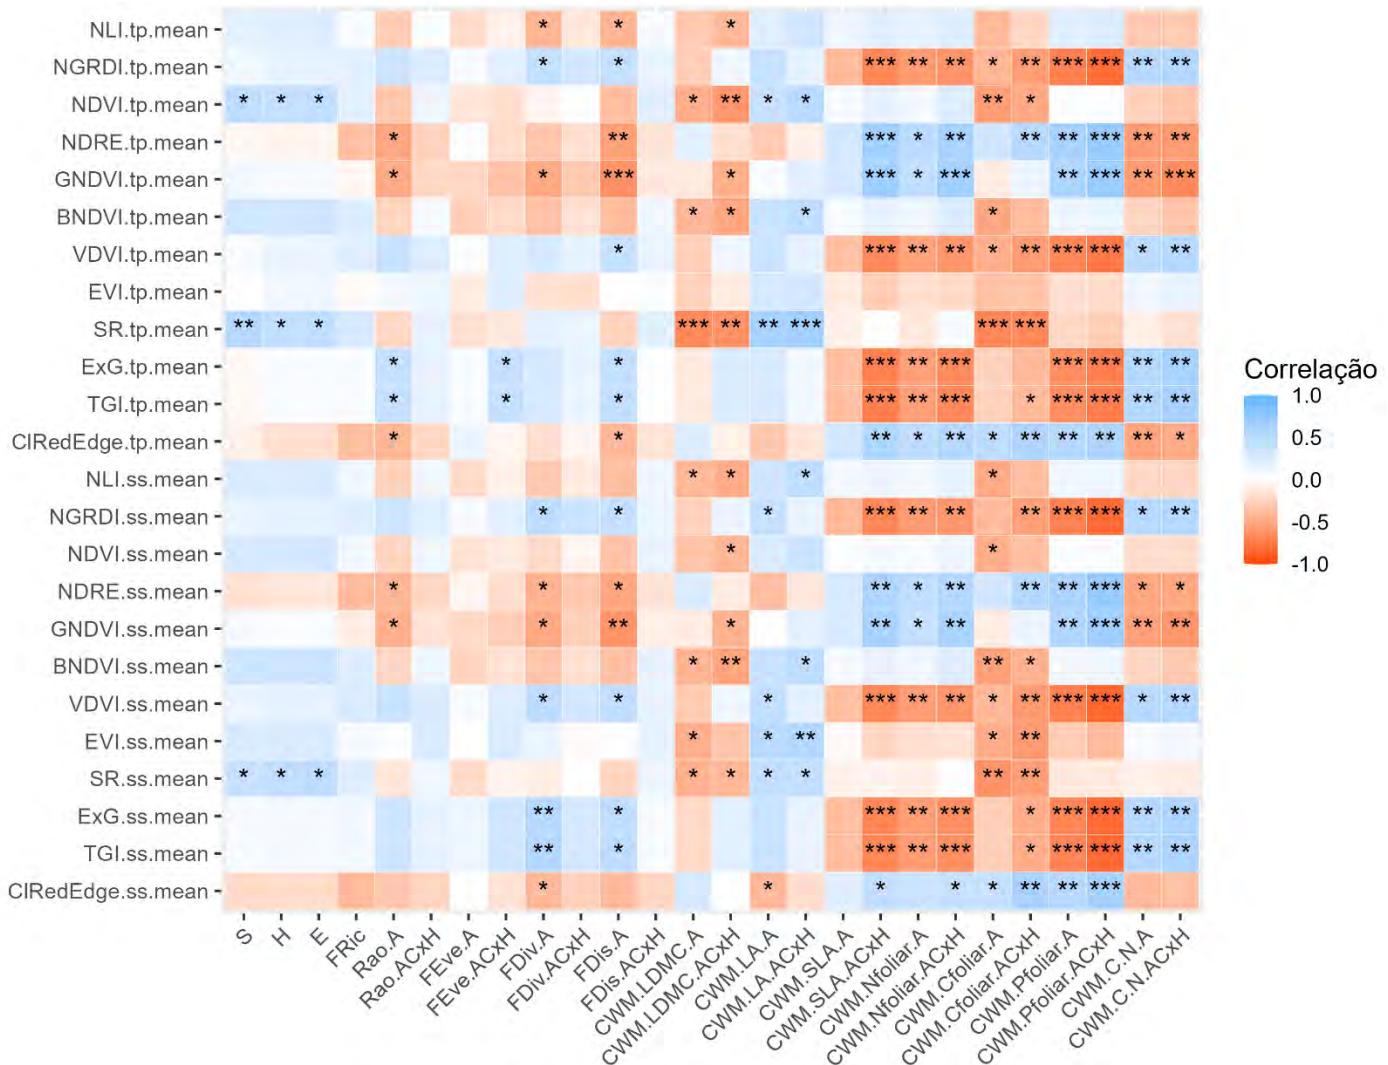


Figura 23. Correlações de Spearman entre os valores de diversidade taxonômica, diversidade funcional e composição funcional medidos em campo e a média dos os índices de vegetação obtidos com drone. Códigos: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels. Os valores significativos são marcados com asteriscos ($p < 0.001$, “***”, $p < 0.01$, “**”, $p < 0.05$, “*”). Fonte: Elaborado pela autora, 2024.

Na Figura 24 abaixo é apresentada as correlações de Spearman entre os valores de diversidade taxonômica, diversidade funcional e composição funcional com os desvios-padrão dos índices de vegetação. Assim como aconteceu com as médias, as associações foram mais significativas entre os desvios-padrão dos índices de vegetação com os dados de composição funcional, nas duas abordagens de ponderação. A Média do Teor de Fósforo Foliar ponderada pelo produto entre a área de copa e a altura (CWM.Pfoliar.ACxH) se correlacionou ($\rho = -0,85$) com os desvios-padrão do *Excess Green Index* (ExG.tp.stdev) e do *Triangle Greenness Index* (TGI.tp.stdev), ambos obtidos com todos os pixels. Além disso, a Média da Área Foliar Específica ponderada pelo produto entre a área de copa e a altura (CWM.SLA.ACxH) se correlacionou ($\rho = -0,78$) com o desvio-padrão do *Simple Ratio* calculado com pixels iluminados (SR.ss.stdev). Entre os dados de diversidade funcional, destacam-se a Divergência

Funcional (FDiv) e a Dispersão Funcional (FDis), ambas ponderadas pela abundância, que se correlacionaram positivamente com diversos índices. No entanto, os dados de diversidade taxonômica não apresentaram correlações significativas com o desvio-padrão dos índices de vegetação calculados.

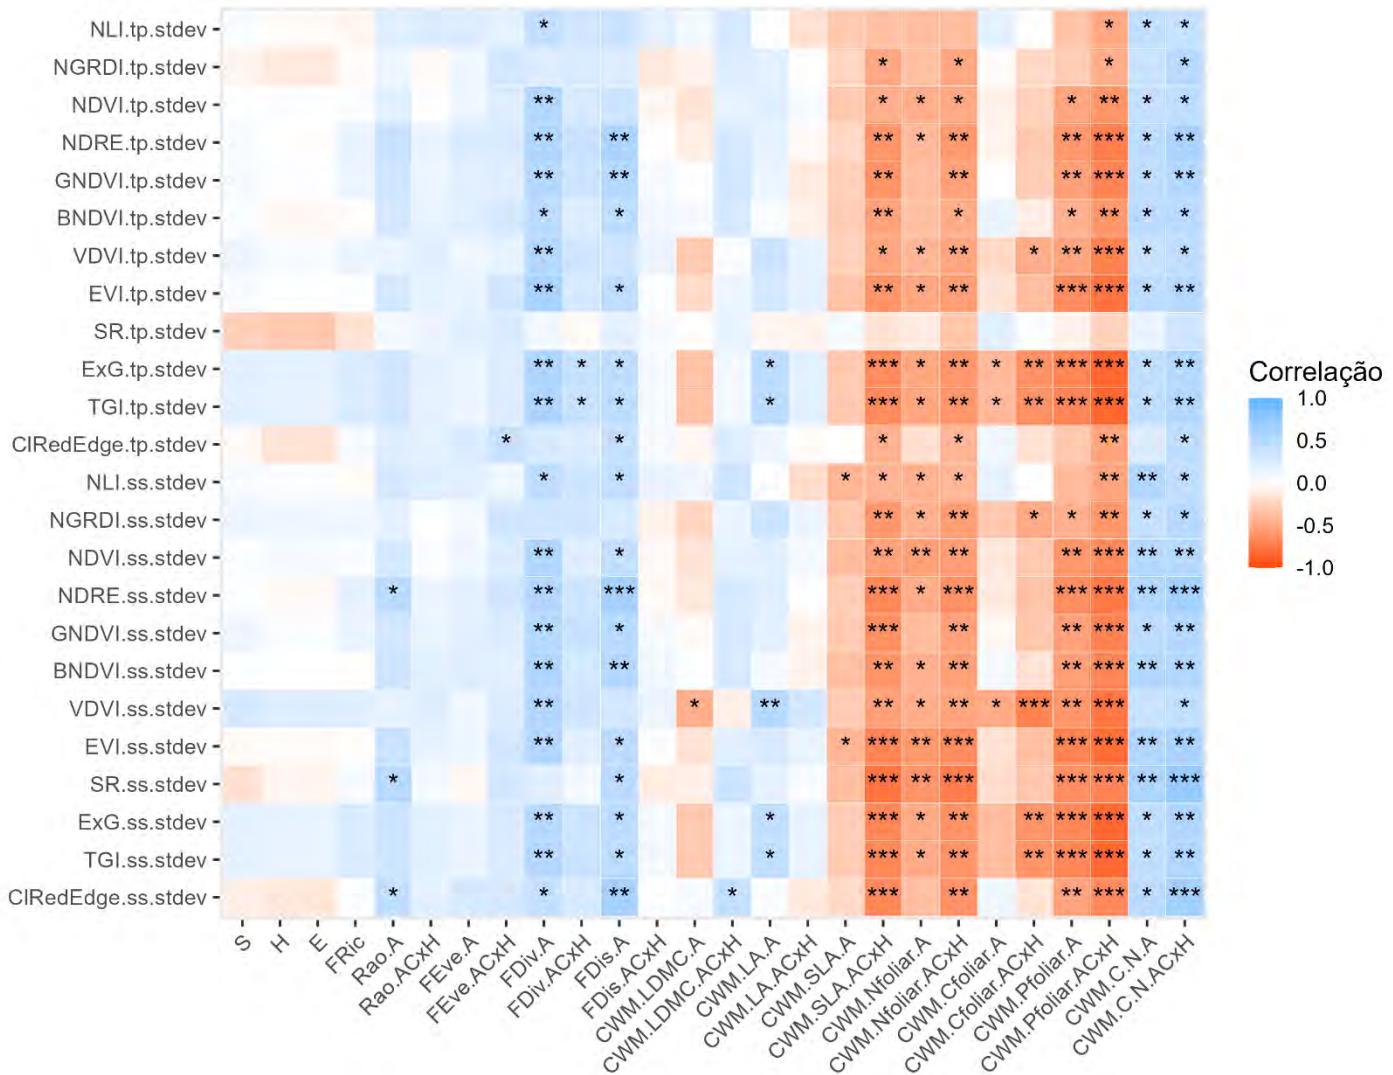


Figura 24. Correlações de Spearman entre os valores de diversidade taxonômica, diversidade funcional e composição funcional medidos em campo e o desvio-padrão dos os índices de vegetação obtidos com drone. Códigos: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels. Os valores significativos são marcados com asteriscos ($p < 0.001$, “***”, $p < 0.01$, “**”, $p < 0.05$, “*”). Fonte: Elaborado pela autora, 2024.

4.4. Regressão Linear Simples

Para as análises de regressão simples, foram selecionadas seis variáveis respostas, considerando as Análises de Agrupamento (Figuras 14 e 15) e as correlações de Spearman (Figuras 23 e 24), são elas: Riqueza Taxonômica (S), Índice de Shannon-Weaver (H), Dispersão Funcional (FDis), Divergência Funcional (FDiv), Média Ponderada do Fósforo Foliar (CWM Pf) e Média Ponderada do Teor de Matéria Seca Foliar (CWM LDMC). Desse modo, foram selecionadas duas medidas de diversidade taxonômica, duas medidas de diversidade funcional

e duas medidas de composição funcional, sendo uma química e outra morfológica. Os modelos de regressão ajustados para cada variável resposta são apresentados a seguir.

4.4.1. Riqueza taxonômica (S)

Ajustou-se dois modelos de regressão linear simples entre a Riqueza Taxonômica e a média do *Simple Ratio* (Figura 25), considerando tanto o índice obtido com todos os pixels (SR.tp.mean) quanto o obtido apenas com os pixels iluminados (SR.ss.mean). Quando utilizada a variável preditora SR.tp.mean, o modelo foi significativo ($p = 0,04$), assim como o coeficiente angular ($p = 0,03$). O coeficiente de determinação (R^2) foi de 0,18, o que indicou que aproximadamente 18% da variação na variável resposta foi explicada pelo modelo, e o valor de AIC foi de 117. Por outro lado, quando utilizada a variável preditora SR.ss.mean, o modelo e os coeficientes linear e angular não foram significativos ($p > 0,05$).

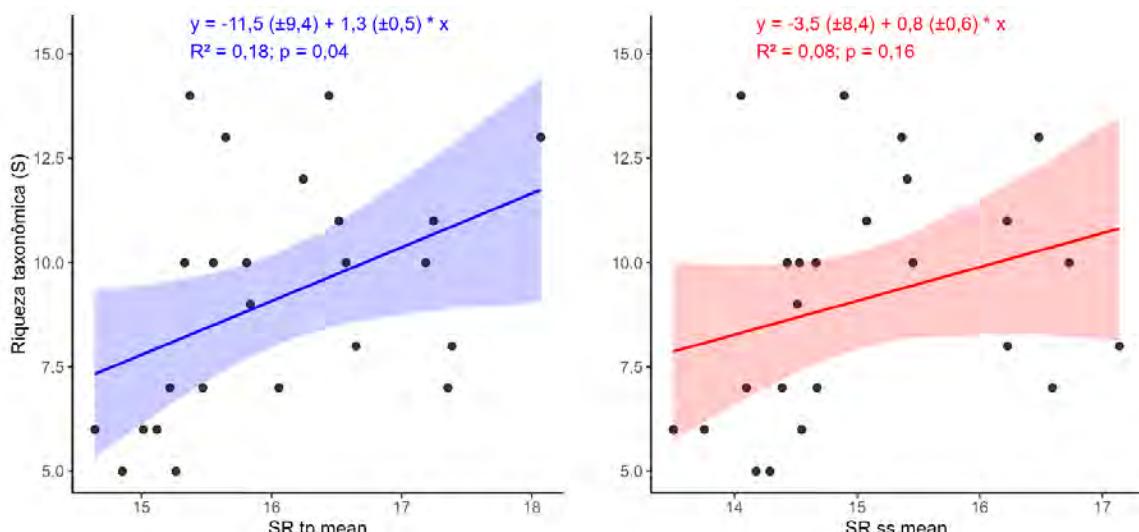


Figura 25. Modelos de regressão linear simples entre a Riqueza Taxonômica (S) e a média do *Simple Ratio*, considerando tanto o índice obtido com todos os pixels (SR.tp.mean) quanto o obtido apenas com os pixels iluminados (SR.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado, a área sombreada indica o intervalo de confiança de 95%, e a cor azul indica que o modelo foi significativo ($p \leq 0,05$), enquanto a cor vermelha indica que o modelo não foi significativo ($p > 0,05$). Fonte: Elaborado pela autora, 2024.

4.4.2. Índice de Shannon-Weaver (H)

Os modelos de regressão linear simples entre o Índice de Shannon-Weaver (H) e as médias do *Simple Ratio*, obtida com todos os pixels (SR.tp.mean) e com os pixels iluminados (SR.ss.mean), são apresentados na Figura 26. Em ambos os casos, os modelos e os coeficientes linear e angular não foram significativos ($p > 0,05$).

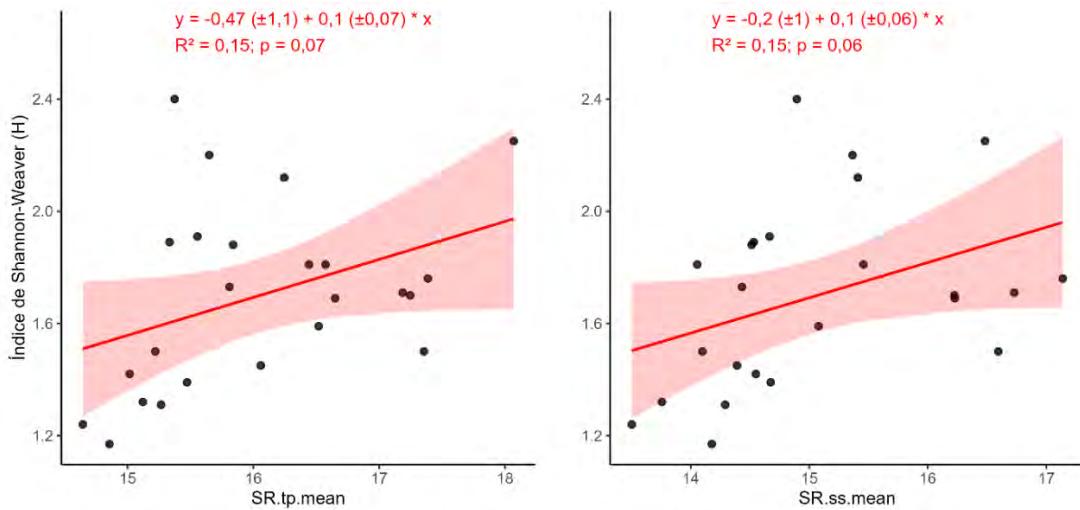


Figura 26. Modelos de regressão linear simples entre o Índice de Shannon-Weaver (H) e a média do *Simple Ratio*, considerando tanto o índice obtido com todos os pixels (SR.tp.mean) quanto o obtido apenas com os pixels iluminados (SR.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.

4.4.3. Dispersão Funcional (FDis)

Ajustou-se dois modelos de regressão linear simples entre a Dispersão Funcional ponderada pela abundância (FDis.A) e o desvio padrão do *Normalized Difference Red Edge* (Figura 27), considerando tanto o índice obtido com todos os pixels (NDRE.tp.stdev) quanto o obtido apenas com os pixels iluminados (NDRE.ss.stdev). Ressalta-se que a FDis ponderada pelo produto entre a área de copa e a altura não foi considerada como variável resposta porque não se correlacionou com este índice de vegetação. Além disso, os dois modelos e seus coeficientes angulares foram significativos ($p < 0,05$). Quando utilizada a variável preditora NDRE.tp.stdev, o coeficiente de determinação (R^2) foi de 0,28 e o valor de AIC foi de 9,5. Por outro lado, quando utilizada a variável preditora NDRE.ss.stdev, o R^2 foi 0,35 e o valor de AIC foi de 7.

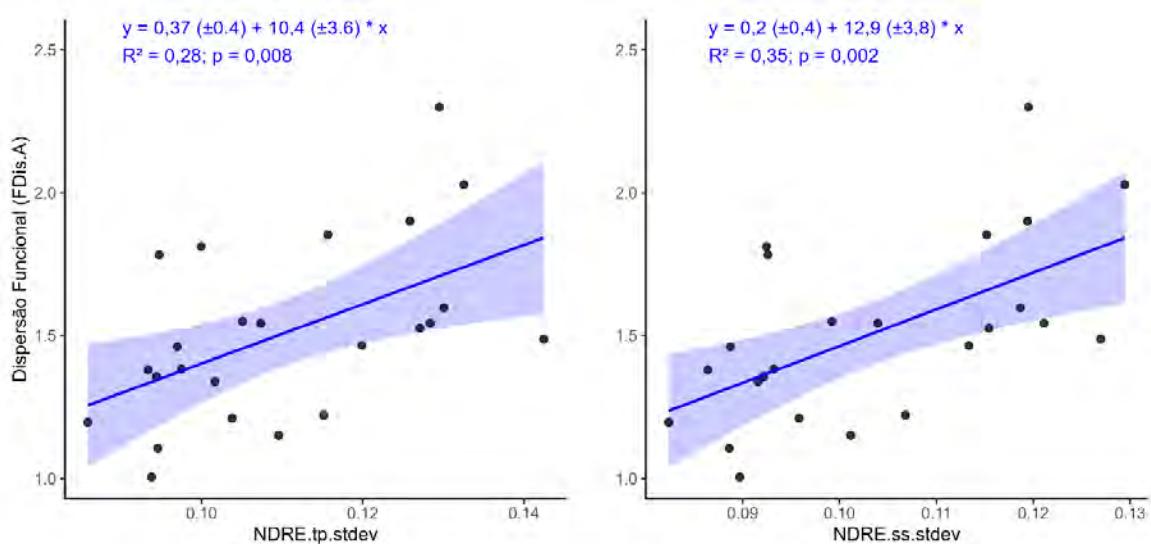


Figura 27. Modelos de regressão linear simples entre a Dispersão Funcional ponderada pela abundância (FDis.A) e o desvio-padrão do *Normalized Difference Red Edge*, considerando tanto o índice obtido

com todos os pixels (NDRE.tp.stdev) quanto o obtido apenas com os pixels iluminados (NDRE.ss.stdev). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.

4.4.4. Divergência Funcional (FDiv)

Os modelos de regressão linear simples entre a Divergência Funcional ponderada pela abundância (FDiv.A) e o desvio padrão do *Normalized Difference Red Edge*, considerando tanto o índice obtido com todos os pixels (NDRE.tp.stdev) quanto o obtido apenas com os pixels iluminados (NDRE.ss.stdev) são apresentados na Figura 28. A FDiv ponderada pelo produto entre a área de copa e a altura não foi considerada como variável resposta porque não se correlacionou com este índice de vegetação. Os dois modelos ajustados e seus coeficientes angulares foram significativos ($p < 0,05$). Com a variável preditora NDRE.tp.stdev, o coeficiente de determinação (R^2) foi de 0,36 e o valor de AIC foi de -37. Com a variável preditora NDRE.ss.stdev, por sua vez, o R^2 foi 0,30 e o valor de AIC foi de -35.

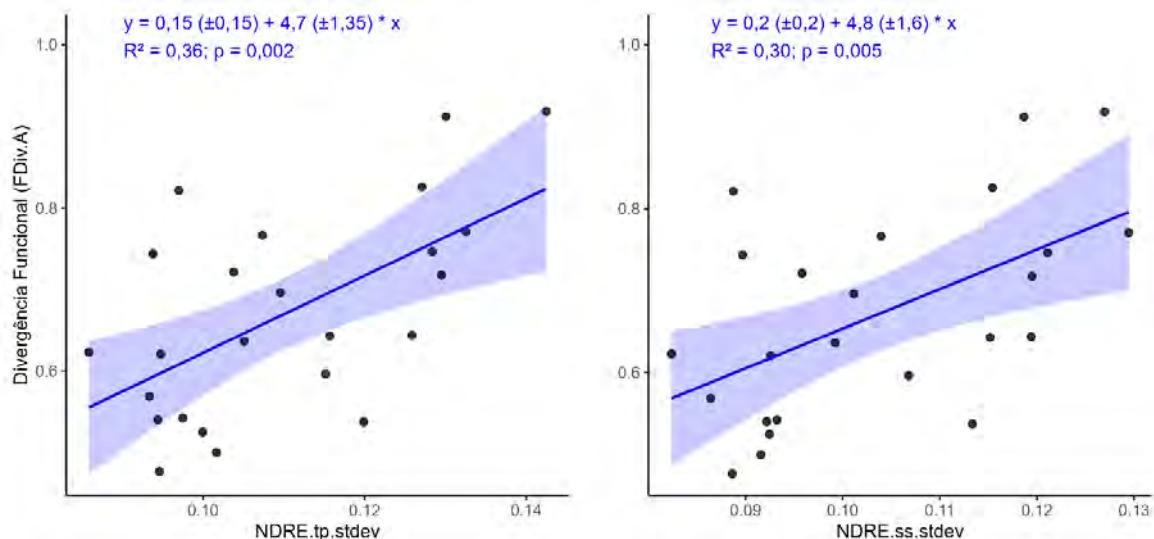


Figura 28. Modelos de regressão linear simples entre a Divergência Funcional ponderada pela abundância (FDiv.A) e o desvio-padrão do *Normalized Difference Red Edge*, considerando tanto o índice obtido com todos os pixels (NDRE.tp.stdev) quanto o obtido apenas com os pixels iluminados (NDRE.ss.stdev). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.

4.4.5. Média Ponderada de Fósforo Foliar (CWM.Pfoliar)

Ajustou-se quatro modelos de regressão linear simples entre a Média de Fósforo Foliar, ponderada pela abundância (CWM.Pfoliar.A) e ponderada pelo produto entre a área de copa e a altura (CWM.Pfoliar.ACxH), e a média do *Normalized Green Red Difference Index*, considerando tanto o índice obtido com todos os pixels (NGRDI.tp.mean) quanto o obtido apenas com os pixels iluminados (NGRDI.ss.mean). Os quatro modelos ajustados e seus coeficientes angulares e lineares foram significativos ($p < 0,05$). Quando utilizada a variável resposta CWM.Pfoliar.A e a variável preditora NGRDI.tp.mean, o coeficiente de determinação (R^2) foi de 0,58 e o valor de AIC foi de -34,5. Quando utilizada a variável resposta CWM.Pfoliar.A e a variável preditora NGRDI.ss.mean, o R^2 foi de 0,57 e o AIC foi igual a -33,9. Por outro lado, com a variável resposta CWM.Pfoliar.ACxH e a variável preditora NGRDI.tp.mean, o R^2 foi 0,69 e o valor de AIC foi de -17,8. Por fim, com a variável resposta

CWM.Pfoliar.ACxH e a variável preditora NGRDI.ss.mean, o R^2 também foi 0,69 e o AIC foi igual a -17,7. A Figura 29 apresenta estes quatro modelos.

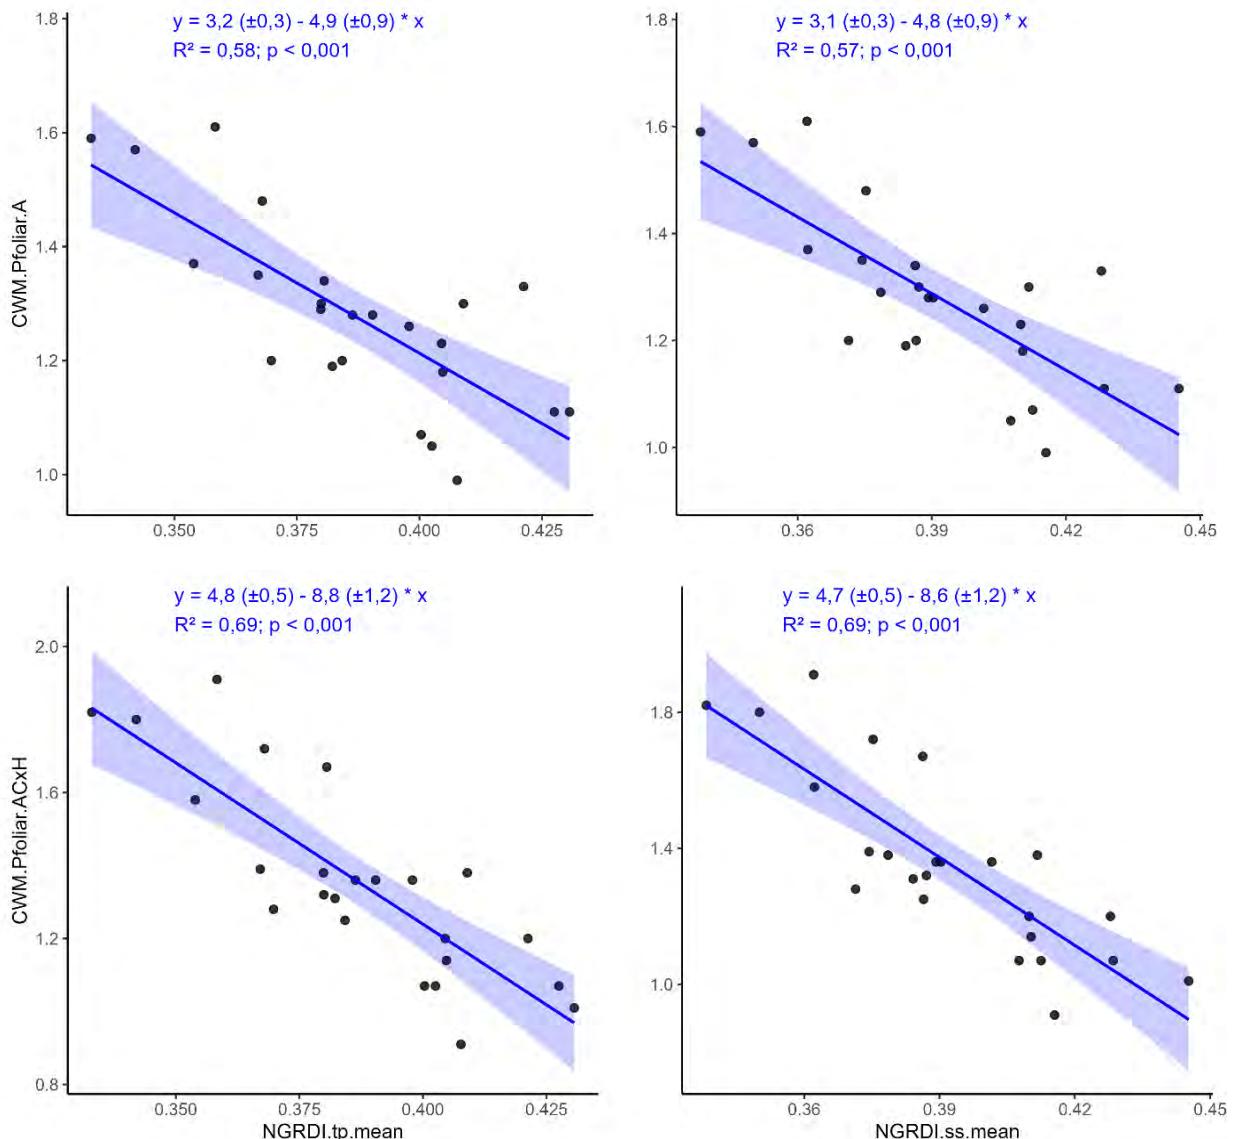


Figura 29. Modelos de regressão linear simples entre a Média do Fósforo Foliar, ponderada pela abundância (CWM.Pfoliar.A) e ponderada pelo produto entre a área de copa e a altura (CWM.Pfoliar.ACxH), e a média do *Normalized Green Red Difference Index*, considerando tanto o índice obtido com todos os pixels (NGRDI.tp.mean) quanto o obtido apenas com os pixels iluminados (NGRDI.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado e a área sombreada indica o intervalo de confiança de 95%. Fonte: Elaborado pela autora, 2024.

4.4.6. Média Ponderada do Teor de Matéria Seca Foliar (CWM.LDMC)

Foram ajustados quatro modelos de regressão linear simples entre a Média do Teor De Matéria Seca Foliar, ponderada abundância (CWM.LDMC.A) e ponderada pelo produto entre a área de copa e a altura (CWM.LDMC.ACxH), e a média do *Normalized Difference Vegetation Index (NDVI)*, considerando tanto o índice obtido com todos os pixels (NDVI.tp.mean) quanto o obtido apenas com os pixels iluminados (NDVI.ss.mean). No entanto, o modelo da variável CWM.LDMC.A em função do NDVI.ss.mean não foi significativo ($p > 0,05$). Quando

utilizada a variável resposta CWM.LDMC.A e a variável preditora NDVI.tp.mean, o coeficiente de determinação (R^2) foi de 0,21. Com CWM.LDMC.ACxH e o NDVI.tp.mean, o R^2 foi igual a 0,26 e o AIC igual a 210. Por fim, com a variável CWM.LDMC.ACxH e o NDVI.ss.mean, o R^2 foi de 0,17 e o AIC de 213. A Figura 30 apresenta estes quatro modelos.

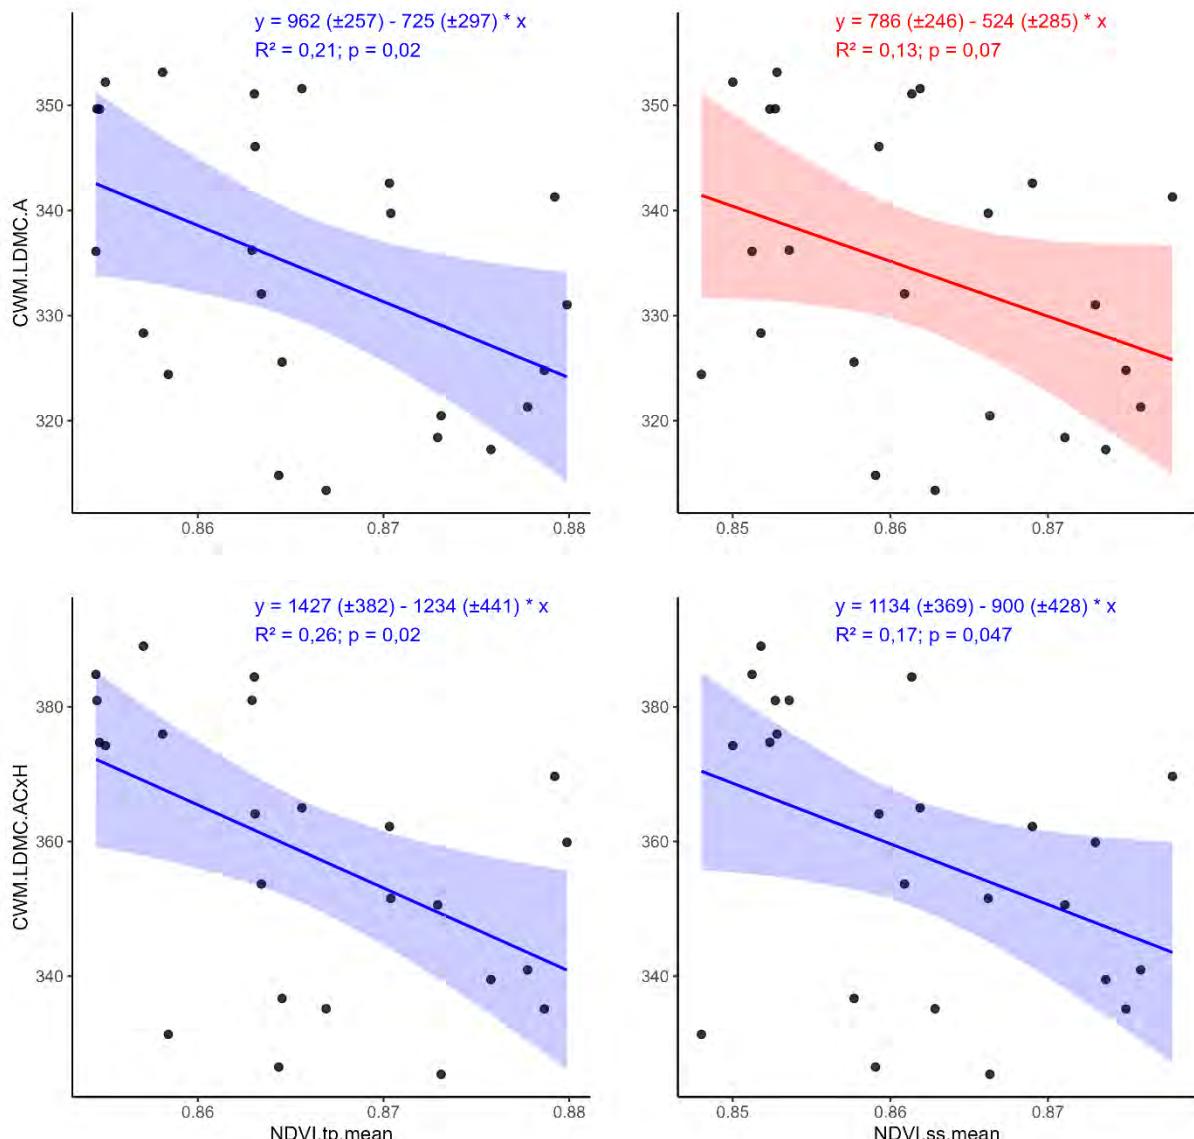


Figura 30. Modelos de regressão linear simples entre a Média do Teor de Matéria Seca Foliar, ponderada pela abundância (CWM.LDMC.A) e ponderada pelo produto entre a área de copa e a altura (CWM.LDMC.ACxH), e a média do *Normalized Difference Vegetation Index*, considerando tanto o índice obtido com todos os pixels (NDVI.tp.mean) quanto o obtido apenas com os pixels iluminados (NDVI.ss.mean). Os pontos representam os dados observados, a linha representa o modelo ajustado, a área sombreada indica o intervalo de confiança de 95%, e a cor azul indica que o modelo foi significativo ($p \leq 0,05$), enquanto a cor vermelha indica que o modelo não foi significativo ($p > 0,05$). Fonte: Elaborado pela autora, 2024.

4.5. Regressão Linear Múltipla

Para as análises de regressão múltipla, foram selecionadas três variáveis respostas, priorizando o componente funcional da biodiversidade, são elas: Divergência Funcional (FDiv),

Média Ponderada de Fósforo Foliar (CWM.Pfoliar) e Média Ponderada do Teor De Matéria Seca Foliar (CWM.LDMC). Os modelos de regressão ajustados para cada variável resposta são apresentados a seguir.

4.5.1. Divergência Funcional (FDiv)

Foram testadas diferentes combinações de variáveis preditoras em modelos de regressão linear múltipla para a Divergência Funcional, tanto a ponderada pela abundância (FDiv.A) quanto a ponderada pelo produto entre a área de copa e a altura (FDiv.ACxH). Como variáveis preditoras, foram considerados tanto os índices de vegetação calculados com todos os pixels quanto os calculados apenas com os pixels iluminados. Os modelos significativos ($p < 0,05$) são apresentados na Tabela 4. Todos os coeficientes angulares e lineares foram significativos ($p < 0,05$). É importante destacar que, embora a variável resposta não tenha se correlacionado significativamente com todos os índices de vegetação, a combinação das variáveis preditoras permitiu o ajuste de modelos significativos.

Tabela 4. Modelos de regressão linear múltipla ajustados para a Divergência Funcional em função dos índices de vegetação obtidos com drone.

Equação	R ²	Valor-p	AIC
$FDiv.A = 7931 (\pm 2808) + 13 (\pm 2,5) * VDVI.tp.stdev - 7931 (\pm 2808) * NLI.tp.mean - 13 (\pm 3,5) * NGRDI.tp.stdev - 0,3 (\pm 0,08) * ClRedEdge.tp.stdev$	0,72	<0,001	-52
$FDiv.A = 0,8 (\pm 0,3) + 17,5 (\pm 4) * NDVI.ss.stdev - 14 (\pm 4) * NGRDI.ss.stdev + 9 (\pm 3) * VDVI.ss.stdev$	0,61	<0,001	-45
$FDiv.ACxH = 1,3 (\pm 0,4) - 0,0001 (\pm 0,00006) * EVI.tp.mean + 0,0009 (\pm 0,0004) * ExG.tp.stdev$	0,28	0,03	-21
$FDiv.ACxH = -30000 (\pm 13100) - 0,0003 (\pm 0,0001) * EVI.ss.mean + 26830 (\pm 9175) * NDVI.ss.stdev + 29950 (\pm 13100) * NLI.ss.mean$	0,33	0,04	-21

em que: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels; R² = coeficiente de determinação; Valor-p = significância do modelo em um nível de 5%; AIC = *Akaike Information Criterion*.

4.5.2. Média Ponderada de Fósforo Foliar (CWM.Pfoliar)

Foram ajustados quatro modelos de regressão linear múltipla significativos para a Média de Fósforo Foliar, considerando tanto a variável ponderada pela abundância (CWM.Pfoliar.A), quanto a ponderada pelo produto entre a área de copa e a altura (CWM.Pfoliar.ACxH), conforme pode ser visualizado na Tabela 5. Além disso, considerou-se como variáveis preditoras os índices calculados com todos os pixels e os calculados apenas com os pixels iluminados. Os modelos e seus coeficientes angulares e lineares foram significativos ($p < 0,05$).

Tabela 5. Modelos de regressão linear múltipla ajustados para a Média Ponderada de Fósforo Foliar (CWM Pfoliar) em função dos índices de vegetação obtidos com drone.

Equação	R ²	Valor-p	AIC
$CWM.Pfoliar.A = 3 (\pm 0,3) - 5 (\pm 0,8) * NGRDI.tp.mean - 6 (\pm 3) * NDVI.tp.stdev$	0,65	<0,001	-37
$CWM.Pfoliar.A = 3 (\pm 0,3) - 4 (\pm 0,9) * NGRDI.ss.mean - 7 (\pm 3) * NDVI.ss.stdev$	0,65	<0,001	-37
$CWM.Pfoliar.ACxH = 5 (\pm 0,4) - 8 (\pm 1) * NGRDI.tp.mean - 13 (\pm 4) * NDVI.tp.stdev$	0,81	<0,001	-27
$CWM.Pfoliar.ACxH = 5 (\pm 0,5) - 7 (\pm 1) * NGRDI.ss.mean - 9 (\pm 4) * BNDVI.ss.stdev$	0,75	<0,001	-21

em que: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels; R² = coeficiente de determinação; Valor-p = significância do modelo em um nível de 5%; AIC = *Akaike Information Criterion*.

4.5.3. Média Ponderada do Teor de Matéria Seca Foliar (CWM.LDMC)

Diferentes combinações de variáveis preditoras foram testadas nos modelos de regressão linear múltipla para a Média do Teor de Matéria Seca Foliar, tanto a ponderada pela abundância (CWM.LDMC.A) quanto a ponderada pelo produto entre a área de copa e a altura (CWM.LDMC.ACxH). No entanto, foram gerados apenas dois modelos significativos, quando utilizada a variável resposta CWM.LDMC.ACxH, conforme apresentado na Tabela 6. Os dois modelos e seus coeficientes angulares e lineares foram significativos (p < 0,05). Ressalta-se que a Riqueza Taxonômica, embora seja uma medida de campo, foi aplicada como uma variável preditora no segundo modelo.

Tabela 6. Modelos de regressão linear múltipla ajustados para a Média Ponderada de Fósforo Foliar (CWM LDMC) em função dos índices de vegetação obtidos com drone.

Equação	R ²	Valor-p	AIC
$CWM.LDMC.ACxH = 838 (\pm 127) - 9 (\pm 4) * SR.tp.mean - 477 (\pm 185) * GNDVI.tp.mean$	0,46	0,001	205
$CWM.LDMC.ACxH = 1222 (\pm 337) - 3 (\pm 1) * S - 977 (\pm 397) * BNDVI.ss.mean$	0,42	0,003	212

em que: “A” = Ponderado pela abundância; “ACxH” = Ponderado pelo produto entre área de copa e altura; “ss” = Calculado a partir do ortofotomosaico sem os pixels sombreados; e “tp” = calculado a partir do ortofotomosaico com todos os pixels; R² = coeficiente de determinação; Valor-p = significância do modelo em um nível de 5%; AIC = *Akaike Information Criterion*.

5. DISCUSSÃO

5.1. Comparações entre os tratamentos

Os tratamentos exibiram diferenças na composição de apenas dois atributos funcionais: a Média Ponderada da Área Foliar (CWM.LA) e a Média Ponderada do Teor de Matéria Seca Foliar (CWM.LDMC), nas duas abordagens de ponderação aplicadas. Os altos valores de CWM.LA no tratamento com espécies pioneiras estão em consonância com o fato de que estas espécies apresentam a estratégia de utilização de recursos do tipo aquisitiva, com maiores taxas de crescimento e, portanto, folhas maiores (Díaz *et al.*, 2004; Chave *et al.*, 2009). As espécies clímax, por sua vez, apresentaram menores valores de CWM.LA e maiores valores de CWM.LDMC, dada sua estratégia conservativa (Díaz *et al.*, 2004; Chave *et al.*, 2009). No que diz respeito aos índices de diversidade taxonômica, todos apresentaram diferenças estatísticas significativas entre os tratamentos. O tratamento composto por todos os grupos ecológicos apresentou a maior média para Riqueza Taxonômica (S), Equabilidade (E) e Índice de Shannon-Weaver (H'). Por outro lado, o tratamento com espécies clímax apresentou as menores médias de diversidade taxonômica.

Não foram observadas diferenças entre os tratamentos para os índices de diversidade funcional. A suposição comum era que o tratamento com todos os grupos ecológicos apresentaria a maior diversidade funcional, assim como encontrado no estudo de Manhães *et al.* (2022), desenvolvido nesta mesma área experimental. No entanto, é importante destacar que Manhães *et al.* (2022) incluíram atributos funcionais não mensurados no presente estudo, como massa seca de sementes e densidade específica da madeira, o que provavelmente influenciou nas diferenças encontradas. Além disso, passaram-se quatro anos desde a coleta de dados de Manhães *et al.* (2022). É possível que o resultado encontrado para os atuais valores também seja resultado de mudanças na vegetação, como a regeneração natural e a mortalidade de árvores.

A média do índice de vegetação *Simple Ratio* (SR), calculado a partir do ortofotomosaico com todos os pixels, foi o único dado remoto que apresentou diferenças estatísticas entre os tratamentos. O SR é um índice multiespectral criado por Jordan (1969) e pode ser obtido a partir da divisão da reflectância proveniente do canal do infravermelho próximo (NIR) pela reflectância no canal vermelho da região do visível (R). Este índice, portanto, baseia-se no princípio de que as folhas absorvem mais luz vermelha do que infravermelha (Jordan, 1969), o que significa que quanto maior o valor do SR, mais folhas estão presentes no dossel. Nesse sentido, a pesquisa desenvolvida por De Almeida *et al.* (2021) classificou o SR como um índice estrutural. Os resultados obtidos por estes autores mostraram que o SR aumentou com o aumento da riqueza e, além disso, apresentou uma correlação significativa e positiva com o índice de área foliar derivado de dados LiDAR.

No presente estudo, percebeu-se que o boxplot dos valores de SR entre os tratamentos apresentou uma distribuição semelhante aos boxplots dos valores de CWM.LA. Para ambas as variáveis, o tratamento composto por espécies pioneiras e o tratamento composto por espécies secundárias apresentaram as maiores médias, enquanto o tratamento composto por espécies clímax apresentou a menor média. Desse modo, as semelhanças observadas indicaram uma associação entre estes dados, como foi encontrado por De Almeida *et al.* (2021). Ressalta-se, contudo, que o SR calculado somente com os pixels iluminados não apresentou diferenças estatísticas entre os tratamentos, o que indica que as sombras foram importantes nessas comparações.

5.2. Correlação e modelos entre os componentes da biodiversidade e os índices de vegetação obtidos com sensor multiespectral

As médias ponderadas dos atributos funcionais (CWM), valores que indicam a composição funcional ou o valor do atributo dominante da comunidade (Díaz *et al.*, 2007; De Bello *et al.*, 2021), foram as medidas de campo mais fortemente correlacionadas aos índices de vegetação obtidos remotamente, nas duas abordagens de ponderação consideradas. No entanto, foram observadas mais correlações significativas quando a CWM foi ponderada pelo produto entre a área de copa e a altura. A Média Ponderada de Área Foliar Específica (CWM.SLA), por exemplo, apresentou apenas duas correlações significativas com os índices de vegetação quando ponderada pela abundância. Por outro lado, quando ponderada pelo produto entre a área de copa e a altura, foram encontradas 36 correlações significativas, com valores variando de -0,78 a 0,66. Nesse contexto, o estudo de Dechant *et al.* (2024) comparou mapas globais de atributos funcionais foliares e também avaliou dois diferentes métodos de expansão dos atributos ao nível da parcela: a CWM e a Média Ponderada do Topo-do-dossel (TWM - *Top-of-Canopy Weighted Mean*), cujo cálculo considera apenas as espécies dominantes no dossel. Os resultados de Dechant *et al.* (2024) mostraram que a TWM apresentou diferenças mais acentuadas entre alguns atributos funcionais em comparação à CWM, como a área foliar específica e o nitrogênio foliar. Assim, percebe-se que a CWM ponderada apenas pela abundância das espécies pode ser limitada em determinados casos, especialmente para trabalhos que utilizam o sensoriamento remoto, enquanto outros métodos de aumento de escala dos atributos funcionais podem ser superiores.

Dentre os dados de composição funcional, destacou-se a Média de Fósforo Foliar ponderada pelo produto entre a área de copa e altura (CWM.Pfoliar.ACxH), cujas correlações de Spearman com os índices de vegetação foram as mais fortes, variando de -0,85 a 0,71. Além disso, os ajustes dos modelos de regressão linear foram melhores para esta variável resposta, com R^2 de até 0,81 no modelo múltiplo. Este resultado era inesperado, uma vez que o sensor multiespectral utilizado neste estudo captura as bandas influenciadas principalmente pelos pigmentos foliares, anatomia e morfologia foliar, em vez dos componentes químicos (Kothari; Schweiger, 2022). No entanto, é importante destacar possíveis relações existentes entre o fósforo e a taxa fotossintética, o que pode influenciar nos pigmentos e na anatomia foliar. Estudos com cultivares agrícolas apontam para uma maior produção de biomassa foliar com o aumento das concentrações de fósforo (e.g. Sánchez *et al.*, 2009; Zhang *et al.*, 2018). Pérez-Harguindeguy *et al.* (2013) também descreveram as associações entre a taxa fotossintética, a concentração de nitrogênio foliar e a área foliar específica. Todas estas relações explicam o agrupamento das Médias Ponderadas de Fósforo Foliar, de Nitrogênio Foliar e de Área Foliar Específica na Análise de Agrupamento Hierárquico e na Análise de Componentes Principais. Desse modo, os resultados demonstram que as plantas com maiores concentrações de fósforo e nitrogênio, apresentam maior produção de biomassa foliar e, portanto, as maiores áreas foliares específicas.

Nesse sentido, era esperado que as correlações de Spearman entre CWM.Pfoliar, CWM.Nfoliar e CWM.SLA fossem positivas com as médias dos índices de vegetação, visto que os mesmos foram elaborados para serem sensíveis à presença de clorofila (e.g. Rouse *et al.*, 1974; Huete, 1988; Gitelson; Kaufman; Merzlyak, 1996). De fato, foram encontradas correlações positivas e significativas entre estes dados e as médias de alguns IVs, como o Cl.RedEdge, índice fortemente correlacionado ao conteúdo de clorofila foliar (Gitelson; Gritz; Merzlyak, 2003; Gitelson; Keydan; Merzlyak, 2006). Contudo, também foram encontradas algumas associações inversamente proporcionais, com as médias do NRGDI, do TGI e do VDVI, por exemplo, o que é difícil de interpretar. Estes resultados sugerem que a interação

entre os elementos químicos, a biomassa foliar e os índices de vegetação pode ser mais complexa.

Ao contrário das médias ponderadas dos atributos funcionais, os índices de diversidade funcional apresentaram mais correlações significativas com os índices de vegetação quando foram ponderados pela abundância. Além disso, para estes dados, foram encontradas mais correlações significativas e positivas com os desvios-padrão dos índices de vegetação do que com as médias. Este resultado é semelhante ao encontrado por Pinon *et al.* (2024), em que o desvio-padrão foi a medida mais associada à diversidade na região NIR. De acordo com estes autores, provavelmente isto acontece porque o desvio-padrão representa as variações absolutas na reflectância que, por sua vez, refletem as variações morfológicas e químicas geradas pela diversidade de plantas. No entanto, para os dados de diversidade taxonômica, foram encontradas apenas três correlações significativas com as médias dos índices de vegetação. Além do mais, neste estudo os modelos de regressão linear simples para a Riqueza Taxonômica e para o Índice de Shannon-Weaver tiveram ajustes inferiores ($R^2 = 0,18$) quando comparados aos modelos de Pinon *et al.* (2024), cujos coeficientes de determinação chegaram até 0,83. Ressalta-se, porém, que os resultados obtidos por Pinon *et al.* (2024) foram encontrados quando utilizadas métricas hiperespectrais como variáveis-preditora, em vez de índices de vegetação.

No que diz respeito às abordagens de cálculo dos índices de vegetação (com todos os pixels vs. apenas com os pixels iluminados), não foi possível determinar neste estudo a superioridade de uma abordagem em relação à outra. Observou-se que algumas variáveis-resposta apresentaram modelos de regressão linear simples de melhor ajuste quando utilizado um IV obtido com todos os pixels. A Média do Teor de Matéria Seca Foliar, por exemplo, quando em função do NDVI.tp.mean produziu um modelo superior ($R^2 = 0,26$; AIC = 210) do que quando utilizado o NDVI.ss.mean ($R^2 = 0,17$; AIC = 213). Por outro lado, outras variáveis-resposta mostraram resultados superiores com a segunda abordagem, como a Dispersão Funcional em função do NDRE.ss.stdev ($R^2 = 0,35$; AIC = 7) em comparação com o NDRE.tp.stdev ($R^2 = 0,28$; AIC = 9,8).

Nesse contexto, novamente resultados do presente estudo diferiram dos resultados de Pinon *et al.* (2024). Os autores observaram um efeito negativo dos pixels sombreados, que produziram correlações inferiores em comparação aos pixels iluminados. É possível que esta variação esteja relacionada às características das variáveis-resposta, como a composição e a idade da vegetação, ou aos métodos de extração dos pixels sombreados. Neste estudo, foi realizada a classificação baseada em objeto utilizando o algoritmo de aprendizado de máquina *Random Forest*. Pinon *et al.* (2024), por sua vez, mascarou os pixels com valores de NDVI abaixo de 0,84. Ressalta-se, no entanto, que não há um consenso na literatura quanto ao melhor método de remoção de sombras das imagens multiespectrais e hiperespectrais. De Almeida *et al.* (2021), por exemplo, removeu as sombras com o cálculo da geometria solar. Beccari *et al.* (2024), por outro lado, removeu todos os pixels não relacionados à vegetação por meio de um processo de classificação espectral linear não supervisionado. Logo, constata-se que a escolha do método para remoção de sombras depende do contexto da pesquisa, como os equipamentos e os softwares disponíveis. A confirmação dos efeitos dos pixels sombreados nos índices de vegetação pode vir a partir de trabalhos que comparem estas diferentes abordagens.

5.3. Principais implicações e limitações do estudo

Este estudo contribui significativamente para a detecção remota da composição funcional, da diversidade funcional e da diversidade taxonômica na Mata Atlântica, e se destaca ao investigar a capacidade de um sensor multiespectral no bioma. Os métodos e os modelos propostos nesta pesquisa poderão servir como base para novos estudos e, assim, contribuir para o avanço do conhecimento científico e fomentar inovações e aplicações práticas. Além disso,

este estudo converge com as discussões propostas por Robinson *et al.* (2022) e McKenna *et al.* (2023), que argumentam que o sensoriamento remoto é uma ferramenta promissora para o monitoramento da restauração ecológica.

No entanto, apesar do potencial demonstrado, algumas limitações devem ser reconhecidas. A frequência de aquisição de dados de campo e de dados remotos foi baixa, levando à ausência de dados multitemporais. Segundo o estudo de Fajardo e Siefert (2016), os atributos foliares das espécies podem variar ao longo das estações. Fassnacht *et al.* (2022) também discutem que as superfícies vegetadas podem apresentar variações diárias, sazonais ou aleatórias nas características ópticas, o que influencia nas medidas de reflectância captadas pelos sensores remotos. Desse modo, a maior frequência de aquisição de dados tende a aumentar a precisão nos estudos de detecção remota da biodiversidade, principalmente no que diz respeito ao componente funcional. De modo semelhante, a incorporação de outras métricas, como características estruturais e texturais, podem melhorar a previsão da diversidade a partir do sensoriamento remoto. Bazzo *et al.* (2024), por exemplo, concluíram que modelos que combinam índices de vegetação, altura do dossel e características texturais apresentam maior precisão preditiva da riqueza de espécies em ecossistemas de campo na Europa.

Além disso, o tamanho (400 m^2) e o número de parcelas ($n = 24$) podem ter representado outra limitação neste presente estudo. Conforme discutido por Pinon *et al.* (2024), espera-se que parcelas maiores e em maior número reduzam o risco de subamostragem da variabilidade ecológica, ao mesmo tempo em que diminuem a probabilidade de vieses estatísticos. Outro fator limitante a ser considerado é a resolução espectral. Pontius, Schaberg e Hanavan (2020) ressaltam que o uso de sensores multiespectrais pode ser limitado para alguns usos, visto que esses sensores capturam poucas bandas de informações espetrais. Nesse contexto, o uso de um sensor com alta resolução ou a combinação de sensores pode superar esta limitação, embora também implique em um maior custo. De acordo com o estudo do De Almeida *et al.* (2021), a fusão de um sensor hiperespectral e um LiDAR permite o monitoramento efetivo dos atributos estruturais da floresta e da diversidade taxonômica de árvores em plantios em processo de restauração.

Em síntese, esta pesquisa reforça o potencial do sensoriamento remoto na elaboração de modelos preditivos dos componentes da biodiversidade, assim como evidencia os desafios e limitações da abordagem aplicada. Destaca-se que a aplicação de técnicas de sensoriamento remoto para investigar a relação entre dados espetrais, composição funcional, diversidade funcional e diversidade taxonômica é uma linha de pesquisa relativamente recente, especialmente na Mata Atlântica. Embora estudos demonstrem seu potencial (e.g. De Almeida *et al.*, 2021; Pinon *et al.*, 2024), diversas lacunas precisam ser preenchidas. Além disso, conforme McKenna *et al.* (2023) enfatizam, o uso do sensoriamento remoto para avaliação de áreas em processo de restauração ecológica deve atender a critérios como viabilidade tecnológica e econômica, praticidade física, robustez científica e métodos replicáveis. Portanto, pesquisas futuras que incluam novas teorias e variáveis, como sazonalidade, diferentes tamanhos de parcelas e a combinação de diferentes sensores, são incentivadas (Ma *et al.*, 2020; Fassnacht *et al.*, 2022; Pinon *et al.*, 2024).

6. CONCLUSÕES

Confirmou-se a hipótese de que as medidas dos índices de vegetação obtidos com drone são correlacionadas com as medidas de composição funcional e os índices de diversidade funcional e taxonômica obtidos em campo. As correlações com as médias e os desvios-padrão dos índices de vegetação foram mais fortes e significativas para os dados de composição funcional quando ponderados pelo produto entre a área de copa e a altura. Os índices de diversidade funcional, por outro lado, apresentaram mais correlações significativas quando

ponderados pela abundância. Além disso, para estes dados, foram encontradas mais correlações significativas e positivas com o desvio-padrão dos índices de vegetação do que com as médias.

Não foi possível determinar qual melhor abordagem de cálculo dos índices de vegetação (com todos os pixels vs. apenas com os pixels iluminados). Observou-se que para algumas variáveis-resposta, os modelos de regressão linear apresentaram melhor ajuste quando utilizado um IV obtido com todos os pixels, enquanto para outras variáveis-resposta, os resultados foram superiores com a segunda abordagem. Os melhores modelos ajustados de regressão linear simples ($R^2 = 0,69$) e múltipla ($R^2 = 0,81$) foram para a Média Ponderada de Fósforo Foliar (CWM.Pfoliar). Esta pesquisa reforça o potencial do sensoriamento remoto e contribui para a detecção remota da composição funcional, da diversidade funcional e da diversidade taxonômica na Mata Atlântica.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGISOFT LLC. **AgiSoft Metashape (Versão 2.1.4)**. Software, 2024. Disponível em <http://www.agisoft.com/downloads/installer/>.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- BARNES, E. *et al.* Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. **Proceedings of the Fifth International Conference on Precision Agriculture**, Bloomington, MN, USA, v. 1619, p. 6, 2000.
- BAZZO, C. O. G. *et al.* Integration of UAV-sensed features using machine learning methods to assess species richness in wet grassland ecosystems. **Ecological Informatics**, v. 83, 2024.
- BECCARI, E. *et al.* Plant Spectral Diversity from High-Resolution Multispectral Imagery Detects Functional Diversity Patterns in Coastal Dune Communities. **J Vegetation Science**, v. 35, n. 2, 2024.
- BELLARD, C. *et al.* Vulnerability of biodiversity hotspots to global change. **Glob Ecol Biogeogr**, v. 23, p. 1376–1386, 2014.
- BUDOWSKI, G. Distribution of tropical American rain forest species in the light of successional processes. **Turrialba**, v. 15, n. 1, p. 40–42, 1965.
- CALMON, M. *et al.* Pacto pela Restauração da Mata Atlântica: um movimento pela valorização da floresta. In: FUJIHARA, M. A., CAVALCANTI, R, GUIMARÃES, A., GARLIPP, R. (eds.) **O valor das florestas**. Terra das Artes Editora, São Paulo, p. 330–335, 2009.
- CAVENDER-BARES, J. A. *et al.* Applying Remote Sensing to Biodiversity Science. In: J. Cavender-Bares, J. A. Gamon, & P. A. Townsend (Eds.). **Remote sensing of plant biodiversity**. Springer, p. 13–42, 2020.
- CAVENDER-BARES, J. *et al.* Harnessing plant spectra to integrate the biodiversity sciences across biological and spatial scales. **American Journal of Botany**, v. 104, n. 7, p. 966–969, 2017.

CHAVE, J. *et al.* Towards a worldwide wood economics spectrum. **Ecology Letters**, v. 12, p. 351–366, 2009.

CHAZDON, R. L. *et al.* A policy-driven knowledge agenda for global forest and landscape restoration. **Conservation Letters**, v. 10, n. 1, p. 125-132, 2017.

CROUZEILLES, R. *et al.* There is hope for achieving ambitious Atlantic Forest restoration commitments. **Perspectives in Ecology and Conservation**, v. 17, p. 80-83, 2019.

DE 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, 2021.

DE BELLO, F. *et al.* **Handbook of trait-based ecology: from theory to R tools**. Cambridge University Press, 2021.

DECHANT, B. *et al.* Intercomparison of global foliar trait maps reveals fundamental differences and limitations of upscaling approaches. **Remote Sensing of Environment**, v. 311, 2024.

DÍAZ, S. *et al.* Incorporating plant functional diversity effects in ecosystem service assessments. **Proceedings of the National Academy of Sciences**, v. 104, n. 52, p. 20684-20689, 2007.

DÍAZ, S. *et al.* The global spectrum of plant form and function. **Nature**, v. 529, p. 167–171, 2016.

DÍAZ, S. *et al.* The plant traits that drive ecosystems: evidence from three continents. **Journal of Vegetation Science**, v. 15, p. 295–304, 2004.

DJI. Phantom 4 multiespectral. **User Manual**, 2019. Disponível em: <https://www.dji.com/br/p4-multispectral>. Acesso em: 13 de maio de 2024.

FAJARDO, A.; SIEFERT, A. Phenological variation of leaf functional traits within species. **Oecologia**, v. 180, p. 951–959, 2016.

FASSNACHT, F. E. *et al.* About the link between biodiversity and spectral variation. **Applied Vegetation Science**, v. 25, n. 1, 2022.

FONTI, V.; BELITSER, E. Feature selection using LASSO. **VU Amsterdam research paper in business analytics**, v. 30, p. 1-25, 2017.

FORMAGGIO, A. R.; SANCHES, I. D. A. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017.

FOX, J.; WEISBERG, S. **An R Companion to Applied Regression**. 3. ed. Thousand Oaks, CA: Sage, 2019. Disponível em: <https://socialsciences.mcmaster.ca/jfox/Books/Companion/>.

GANN, G. D. *et al.* International principles and standards for the practice of ecological restoration. Second edition. **Restoration Ecology**, v. 27, n. S1, p. S1–S46, 2019.

GARNIER, E.; NAVAS, M. L.; GRIGULIS, K. **Plant functional diversity: organism traits, community structure, and ecosystem properties**. Oxford University Press, 2016.

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 Letter**, v. 33, 2006.

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. **J. Plant Physiol.**, v. 160, p. 271–282, 2003.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sens. Environ.**, v. 58, p. 289-298, 1996.

GOEL, N. S.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. **Remote Sensing Reviews**, v. 10, n. 4, p. 309-347, 1994.

GORNISH, E. S. *et al.* Functional traits are used in restoration practice: a response to Merchant *et al.* (2022). **Restoration Ecology**, v. 31, n. 7, 2023.

HARRELL, F. **Hmisc: Harrell Miscellaneous** (R package version 5.2-0). 2024. Disponível em: <https://CRAN.R-project.org/package=Hmisc>.

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

HUETE, A. *et al.* A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, p. 440-451, 1997.

HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.

HUNT Jr., E. R. *et al.* A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013.

JACQUEMOUD, S.; BARET, F. PROSPECT: A model of leaf optical properties spectra. **Remote sensing of environment**, v. 34, n. 2, p. 75-91, 1990.

JETZ, W. *et al.* Monitoring plant functional diversity from space. **Nature plants**, v. 2, 2016.

JORDAN, C.F. Derivation of leaf-area index from quality of light on the Forest floor. **Ecology** v. 50, n. 663, 1969.

KASSAMBARA, A.; MUNDT, F. **factoextra: Extract and Visualize the Results of Multivariate Data Analyses**. Versão 1.0.7. 2020. Disponível em: <https://CRAN.R-project.org/package=factoextra>.

KOTHARI, S.; SCHWEIGER, A. K. Plant spectra as integrative measures of plant phenotypes. **Journal of Ecology**, v. 110, p. 2536–2554, 2022.

KUHN, M. Building Predictive Models in R Using the caret Package. **Journal of Statistical Software**, v. 28, n. 5, p. 1–26, 2008.

LALIBERTÉ, E.; LEGENDRE, P. A distance-based framework for measuring functional diversity from multiple traits. **Ecology**, v. 91, p. 299–305, 2010.

LALIBERTÉ, E.; LEGENDRE, P.; SHIPLEY, B. **FD: measuring functional diversity from multiple traits, and other tools for functional ecology**. Versão 1.0-12.3. 2014. Disponível em: <https://cran.r-project.org/package=FD>.

LAUGHLIN, D. C. Applying trait-based models to achieve functional targets for theory-driven ecological restoration. **Ecology Letter**, v. 17, n. 7, p. 771-784, 2014.

LIMA, H. C. *et al.* Caracterização fisionômica-florística e mapeamento da vegetação da Reserva Biológica Poço das Antas, Silva Jardim, Rio de Janeiro, Brasil. **Rodriguésia**, v. 57, n. 3, p. 369-389, 2006.

LOUREIRO, N. *et al.* Use of the trait-based approach in ecological restoration studies: a global review. **Trees**, v. 37, n. 5, p. 1287-1297, 2023.

MA X. *et al.* Monitoring Plant Functional Diversity Using the Reflectance and Echo from Space. **Remote Sensing**, v. 12, n. 8, p.1248, 2020.

MANHÃES, A. P. *et al.* Functional trajectory for the assessment of ecological restoration success. **Restoration Ecology**, v. 30, n. 8, 2022.

MASON, N. WH. *et al.* Functional richness, functional evenness and functional divergence: the primary components of functional diversity. **Oikos**, v. 111, n. 1, p. 112-118, 2005.

MCKENNA, P. B. *et al.* Measuring and monitoring restored ecosystems: can remote sensing be applied to the ecological recovery wheel to inform restoration success? **Restoration Ecology**, v. 31, n. 1, 2023.

MERCHANT, T. K. *et al.* Four reasons why functional traits are not being used in restoration practice. **Restoration Ecology**, v. 31, n. 3, 2022.

MORAES, L. F. D. *et al.* Plantio de espécies arbóreas nativas para a restauração ecológica na Reserva Biológica de Poço das Antas, Rio de Janeiro, Brasil. **Rodriguesia**, v. 57, n. 3, p. 477-489, 2006.

MYERS, N. *et al.* Biodiversity hotspots for conservation priorities. **Nature**, 403, 853–858, 2000.

OLLINGER, S. V. Sources of variability in canopy reflectance and the convergent properties of plants. **New Phytologist**, v. 189, n. 2, p. 375-394, 2011.

OSTERTAG, R. *et al.* Using plant functional traits to restore Hawaiian rainforest. **Journal of Applied Ecology**, v. 52, n. 4, p. 805-809, 2015.

PANTALEÃO, L. C. *et al.* Linking plant functional traits to soil properties in tropical forest restoration. **Forest Ecology and Management**, v. 563, p. 121976, 2024.

PEIXOTO, G. L. *et al.* (orgs). **Plano de Manejo Integrado do Fogo da Reserva Biológica de Poço das Antas**. MMA. ICMBio, 2022.

PÉREZ-HARGUINDEGUY, N. *et al.* New handbook for standardised measurement of plant functional traits worldwide. **Australian Journal of Botany**, v. 61, n. 34, p. 167234, 2013.

PETCHEY, O. L.; GASTON, K. J. Functional diversity (FD), species richness and community composition. **Ecology Letters**, v. 5, n. 3, p. 402–411, 2002.

PETCHEY, O. L.; GASTON, K. J. Functional diversity: back to basics and looking forward. **Ecology Letters**, v. 9, n. 6, p. 741– 758, 2006.

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.

PONTIUS, J., SCHABERG, P., HANAVAN, R. Remote Sensing for Early, Detailed, and Accurate Detection of Forest Disturbance and Decline for Protection of Biodiversity. In: J. Cavender-Bares, J. A. Gamon, & P. A. Townsend (Eds.). **Remote sensing of plant biodiversity**. Springer, p. 121–154, 2020.

QGIS.org. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project, 2024. Disponível em: <http://qgis.osgeo.org>. Acesso em: 22 de junho de 2024.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, 2024. Disponível em: <https://www.R-project.org>.

RAO, C. R. Diversity and dissimilarity coefficients: A unified approach. **Theoretical Population Biology**, v. 21, p. 24-43, 1982.

RESTREPO-CARVAJAL, I. C. *et al.* Testing for priority effects of tree plantings on natural regeneration in restoration sites in the Brazilian Atlantic Forest. **Applied Vegetation Science**, v. 27, n. 1, 2024.

REZENDE, C. L. *et al.* From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. **Perspect. Ecol. Conserv.**, v. 16, p. 208–214. doi:10.1016/j.pecon.2018.10.002, 2018.

RIBEIRO, M. C. *et al.* The Brazilian Atlantic Forest: how much is left, and how is the remaining forest distributed? Implications for conservation. **Biol. Conserv.**, v. 142, p. 1141-1153, doi: 10.1016/j.biocon.2009.02.021, 2009.

ROBINSON, J. M. *et al.* Existing and emerging uses of drones in restoration ecology. **Methods in Ecology and Evolution**. v. 13, n. 9, p. 1899–1911, 2022.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the Great Plains with ERTS. **NASA Spec. Publ.**, p. 351, 309, 1974.

SÁNCHEZ, E. *et al.* Nitrogen metabolism in roots and leaves of green bean plants exposed to different phosphorus doses. **Phyton-International Journal of Experimental Botany**, v. 78, 2009.

SANDQUIST, D. R.; CORDELL, S. Functional diversity of carbon-gain, water-use, and leaf-allocation traits in trees of a threatened lowland dry forest in Hawaii. **American Journal of Botany**, n. 94, p. 1459–1469, 2007.

SANSEVERO, J. B. B.; GARBIN, M. L. Restoration success of tropical forests: the search for indicators. In: LATAWIEC, A. E; AGOL, D. (Eds.). **Sustainability Indicators**. De Gruyter Open Ltd. Warsaw, Poland, 2015.

SCARANO, F. R.; CEOTTO, P. Brazilian Atlantic forest: impact, vulnerability, and adaptation to climate change. **Biodiversity and Conservation**, v. 24, n. 9, p. 2319-2331, 2015.

SCHIMEL, D. S.; ASNER, G. P.; MOORCROFT, P. Observing changing ecological diversity in the Anthropocene. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 129-137, 2013.

SCHWEIGER, A. K. *et al.* How to predict plant functional types using imaging spectroscopy: linking vegetation community traits, plant functional types and spectral response. **Methods Ecol. Evol.**, v. 8, p. 86-95, 2017.

SCHWEIGER, A. K. *et al.* Plant spectral diversity integrates functional and phylogenetic components of biodiversity and predicts ecosystem function. **Nature Ecology & Evolution**. v. 2., p. 976-998, 2018.

SERBIN, S. P.; TOWNSEND, P. A. Scaling functional traits from leaves to canopies. In: J. Cavender-Bares, J. A. Gamon, & P. A. Townsend (Eds.). **Remote sensing of plant biodiversity**. Springer, p. 43–82, 2020.

SHANNON, C. E.; WEAVER, W. The mathematical theory of communication. **Urbana: University of Illinois Press**, 1949.

SOS Mata Atlântica; INPE. **Atlas dos remanescentes florestais da Mata Atlântica: período 2020-2021**. São Paulo, 2022.

SOUZA, F. E. S.; RODRIGUES, J. I. J. Evaluation of Machine Learning Algorithms in the Classification of Multispectral Images from the Sentinel-2A/2B Orbital Sensor for Mapping the Environmental Dynamics of Ria Formosa (Algarve, Portugal). **ISPRS International Journal of Geo-Information**, v. 12, n. 9, p. 361, 2023.

SUDING, K.N. *et al.* Scaling environmental change through the community-level: a trait-based response-and-effect framework for plants. **Glob. Change Biol.**, v. 14, p. 1125–1140, 2008.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

USTIN, S. L.; JACQUEMOUD, S. How the Optical Properties of Leaves Modify the Absorption and Scattering of Energy and Enhance Leaf Functionality. In: J. Cavender-Bares, J. A. Gamon, & P. A. Townsend (Eds.). **Remote sensing of plant biodiversity**. Springer, p. 349–384, 2020.

VILLÉGER, S.; MASON, N. WH.; MOUILLOT, D. New multidimensional functional diversity indices for a multifaceted framework in functional ecology. **Ecology**, v. 89, n. 8, p. 2290-2301, 2008.

VIOLLE, C. *et al.* Let the concept of trait be functional! **Oikos**, v. 116, p. 882-892, 2007.

WANG, R.; GAMON, J. A. Remote sensing of terrestrial plant biodiversity. **Remote Sensing of Environment**, v. 231, 2019.

WANG, X. *et al.* Extraction of vegetation information from visible unmanned aerial vehicle images. **Nongye Gongcheng Xuebao / Transactions of the Chinese Society of Agricultural Engineering**, v. 31, n. 5, p. 152–159, 2015.

WICKHAM, H. **ggplot2: Elegant Graphics for Data Analysis**. Springer-Verlag, 2016.

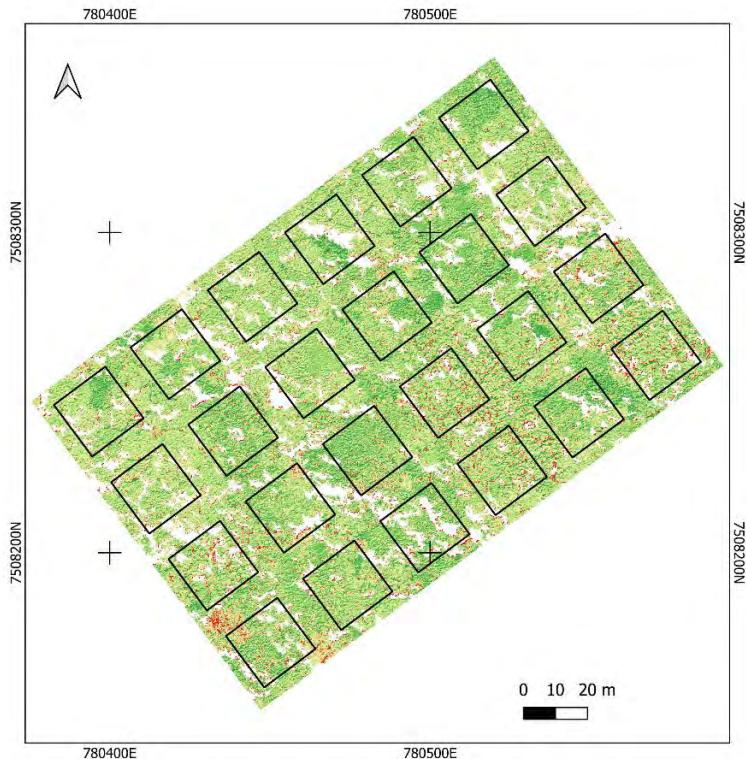
WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259-269, 1995.

YANG, C. *et al.* Airborne hyperspectral imagery and yield monitor data for mapping cotton yield variability. **Precis. Agric.**, v. 5, p. 445-461, 2004.

ZEILEIS, A.; HOTHORN, T. Diagnostic Checking in Regression Relationships. **R News**, v. 2, n. 3, p. 7-10, 2002. Disponível em: <https://CRAN.R-project.org/doc/Rnews/>.

ZHANG, W. *et al.* The role of phosphorus supply in maximizing the leaf area, photosynthetic rate, coordinated to grain yield of summer maize. **Field Crops Research**, v. 219, p. 113-119, 2018.

APÊNDICE A – MAPAS COM OS ÍNDICES DE VEGETAÇÃO CALCULADOS A PARTIR DO ORTOFOTOMOSAICO APENAS COM OS PIXELS ILUMINADOS.
 (continua)

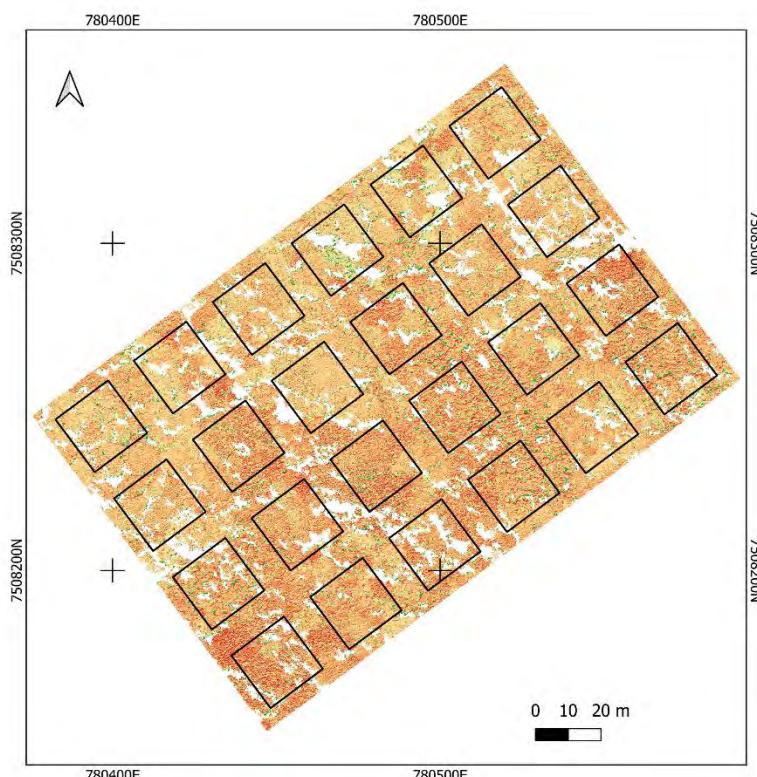


Blue Normalized Difference Vegetation Index (BNDVI)

$$\text{BNDVI} = (\text{NIR} - \text{B}) / (\text{NIR} + \text{B})$$

Área útil de 20x20m
BNDVI
0.7042
0.7618
0.8194
0.877
0.9345

Sistema de referência de coordenadas
 Datum SIRGAS 2000
 Projeção UTM, 23 S
 Data de execução: 12/2024
 Elaboração: Júlia Ayres de Oliveira.



Chlorophyll Red-Edge Index (CI.RedEdge)

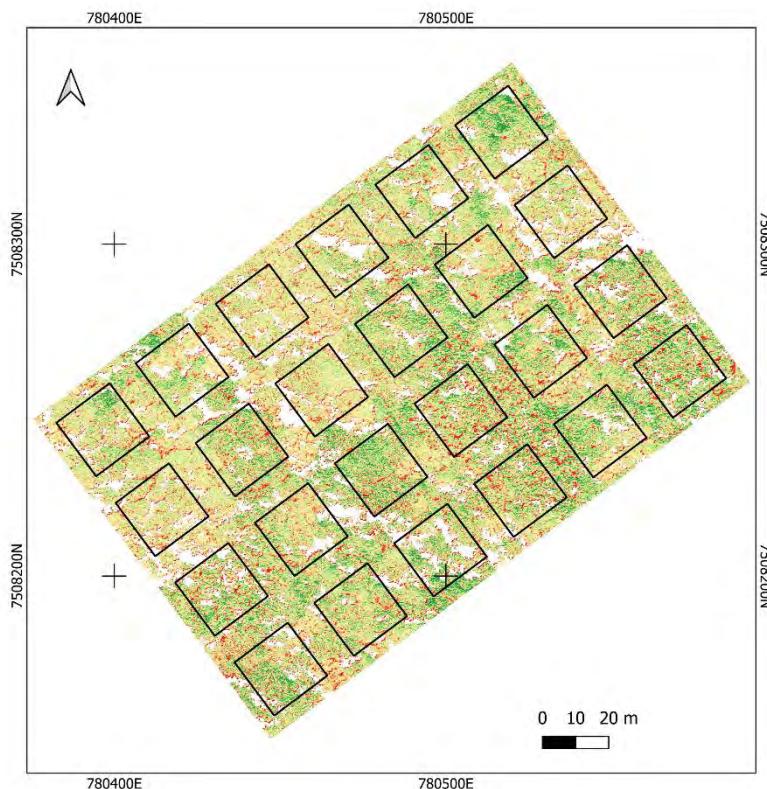
$$\text{CI.RedEdge} = (\text{NIR} / \text{RedEdge}) - 1$$

Área útil de 20x20m
CI.RedEdge
0.11
0.605
1.1
1.6
2.09

Sistema de referência de coordenadas
 Datum SIRGAS 2000
 Projeção UTM, 23 S
 Data de execução: 12/2024
 Elaboração: Júlia Ayres de Oliveira.

APÊNDICE A

(continua)

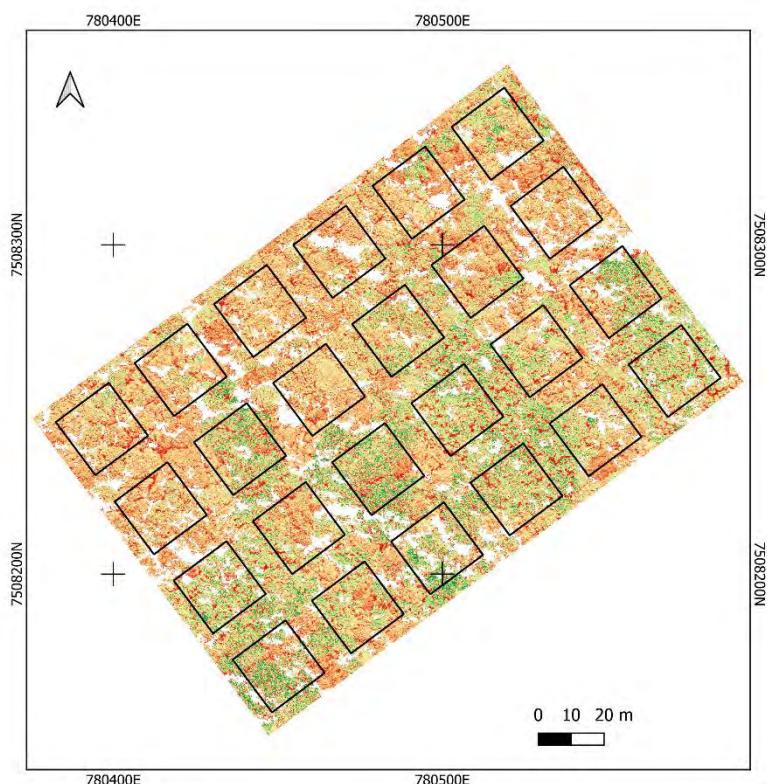


Enhanced Vegetation Index (EVI)

$$EVI = 2.5 * ((NIR - R) / (NIR + 6 * R - 7.5 * B + 1))$$

Área útil de 20x20m
EVI
854.67
4133.7
7412.8
10692
13971

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Excess Green Index (ExG)

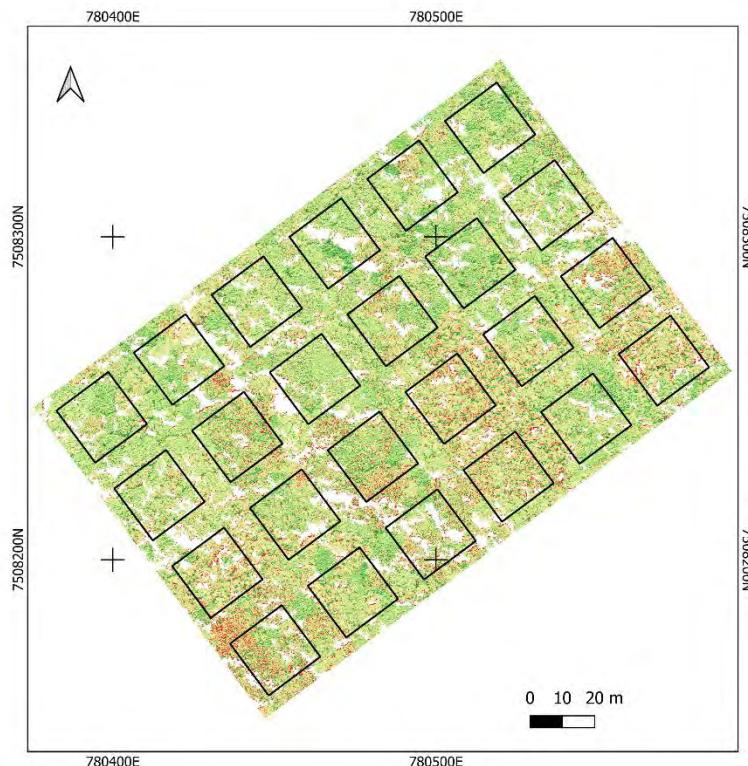
$$ExG = 2 * G - R - B$$

Área útil de 20x20m
ExG
78
453.5
829
1204
1580

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

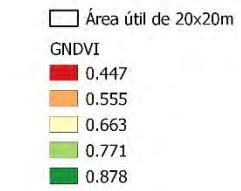
APÊNDICE A

(continua)

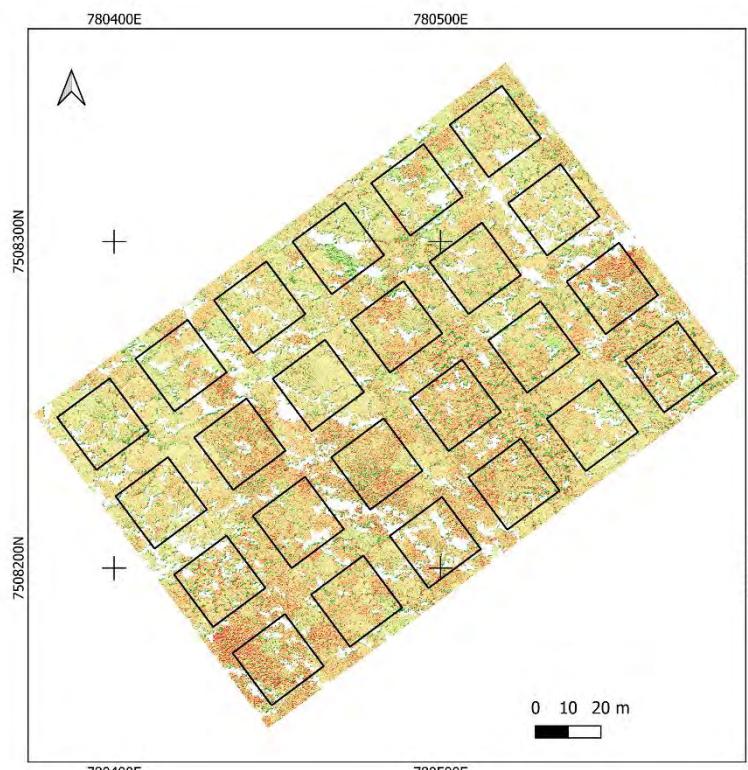


Green Normalized Difference Vegetation (GNDVI)

$$GNDVI = (NIR - G) / (NIR + G)$$

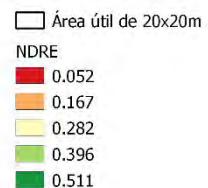


Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Normalized Difference RedEdge (NDRE)

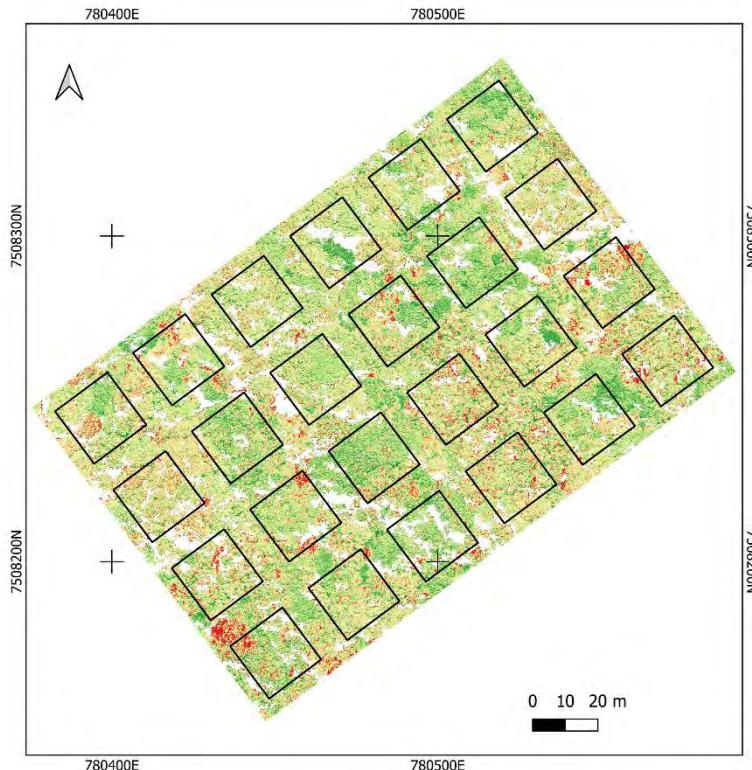
$$NDRE = (NIR - RedEdge) / (NIR + RedEdge)$$



Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE A

(continua)

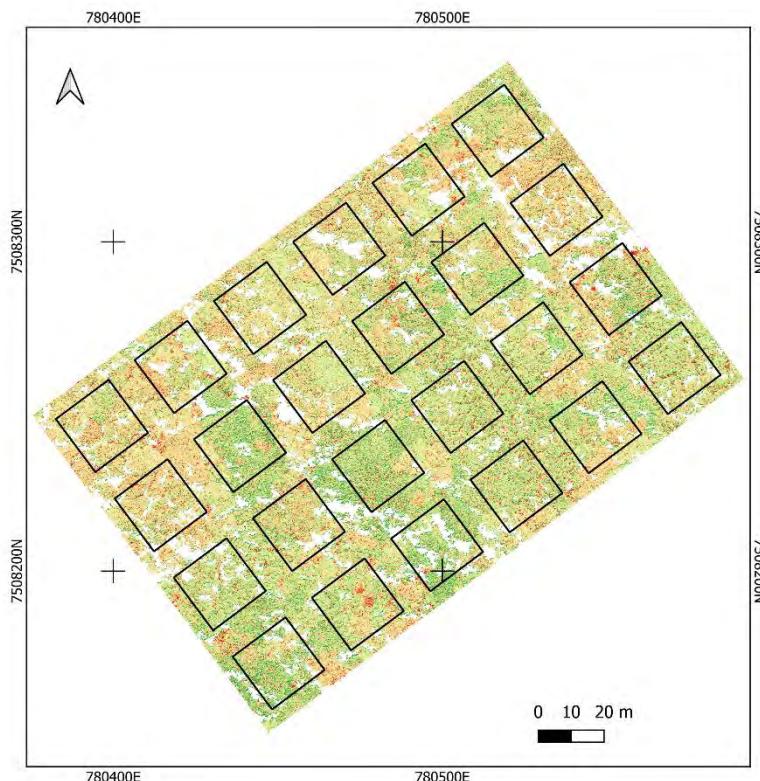


Normalized Difference Vegetation Index (NDVI)

$$NDVI = (NIR - R) / (NIR + R)$$

Área útil de 20x20m
NDVI
0.7554
0.8008
0.8463
0.8917
0.9372

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Normalized Green Red Difference Index (NGRDI)

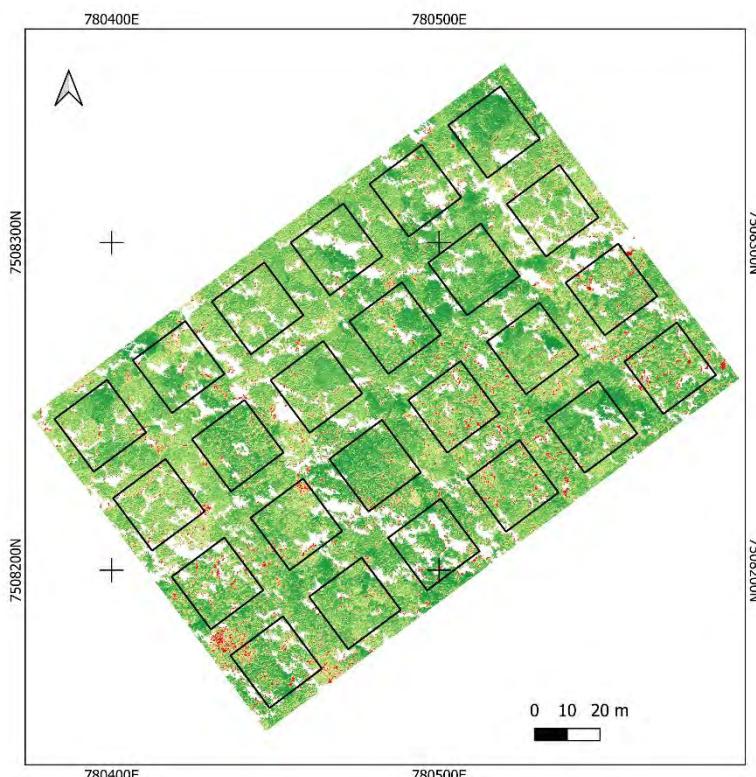
$$NGRDI = (G - R) / (G + R)$$

Área útil de 20x20m
NGRDI
0.0906
0.23
0.369
0.508
0.648

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE A

(continua)

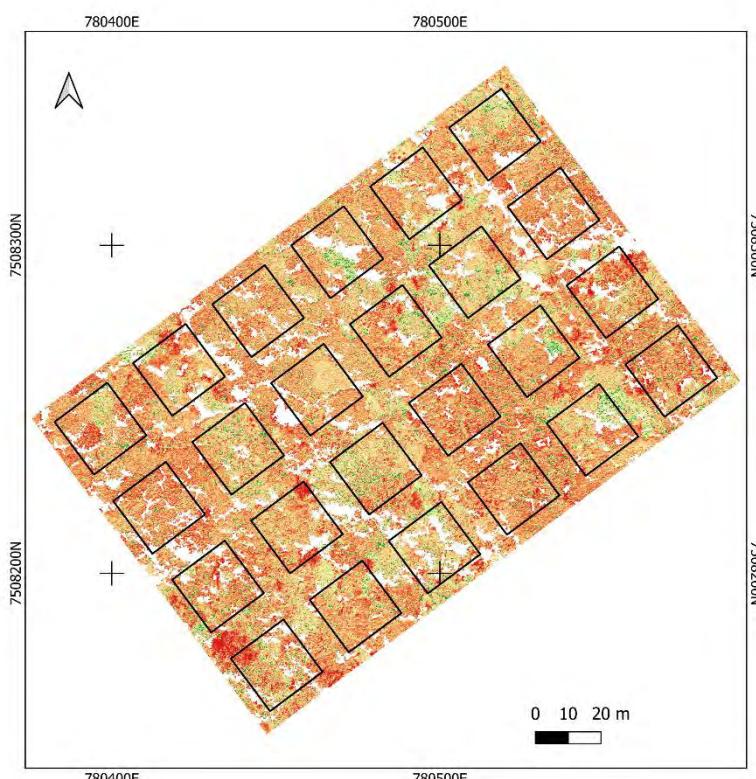


Índice Não Linear (NLI)

$$NLI = (NIR^2 - R) / (NIR^2 + R)$$

Área útil de 20x20m
NLI
0.999856
0.9998876
0.9999191
0.9999506
0.9999822

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Simple Ratio (SR)

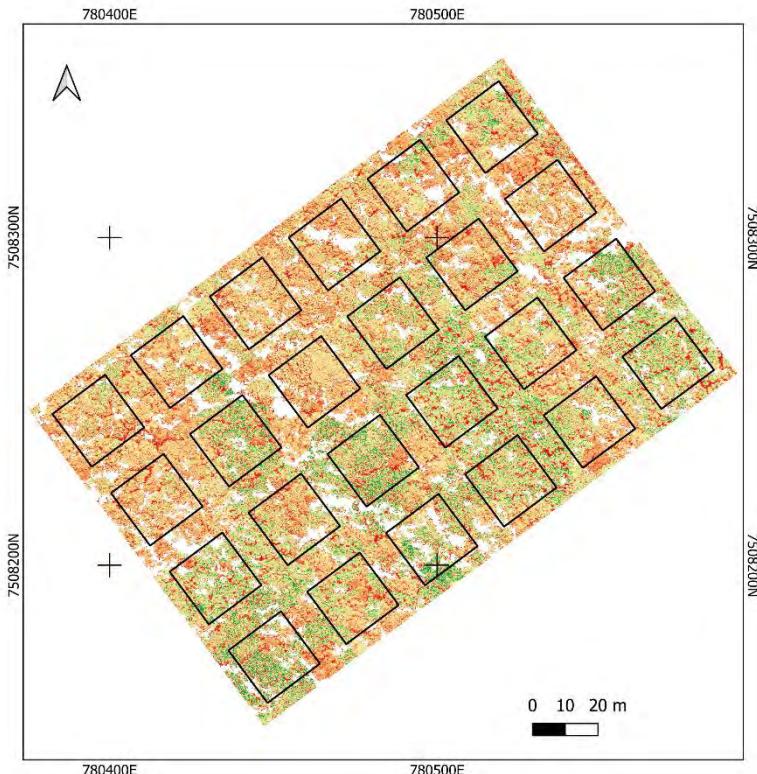
$$SR = NIR / R$$

Área útil de 20x20m
SR
7.18
13.1
19
24.9
30.8

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE A

(continuação)

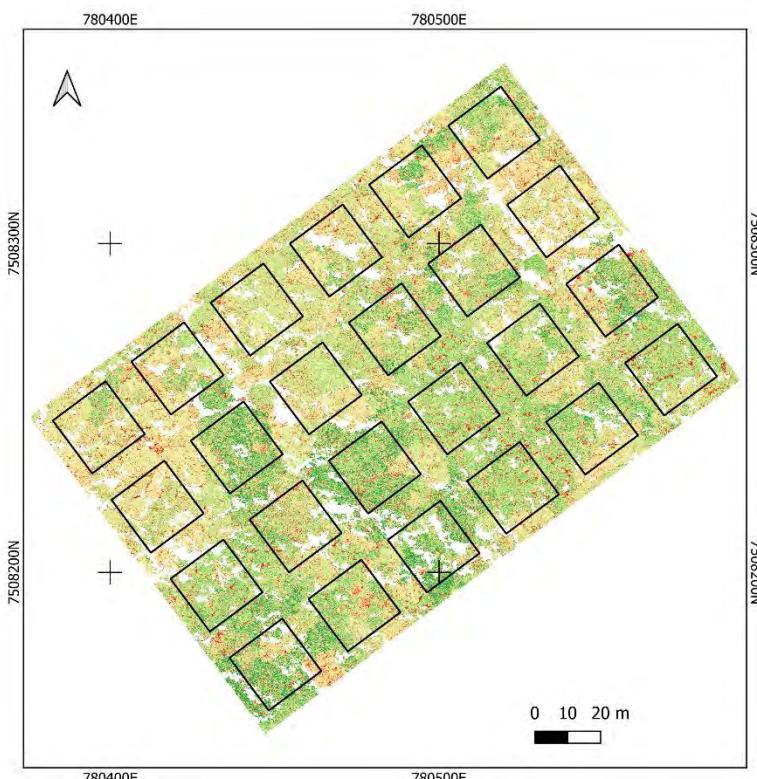


Triangle Greenness Index (TGI)

$$TGI = G - 0,39 * R - 0,61 * B$$

Área útil de 20x20m
TGI
34.7
225
415
605
795

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Visible Difference Vegetation Index (VDVI)

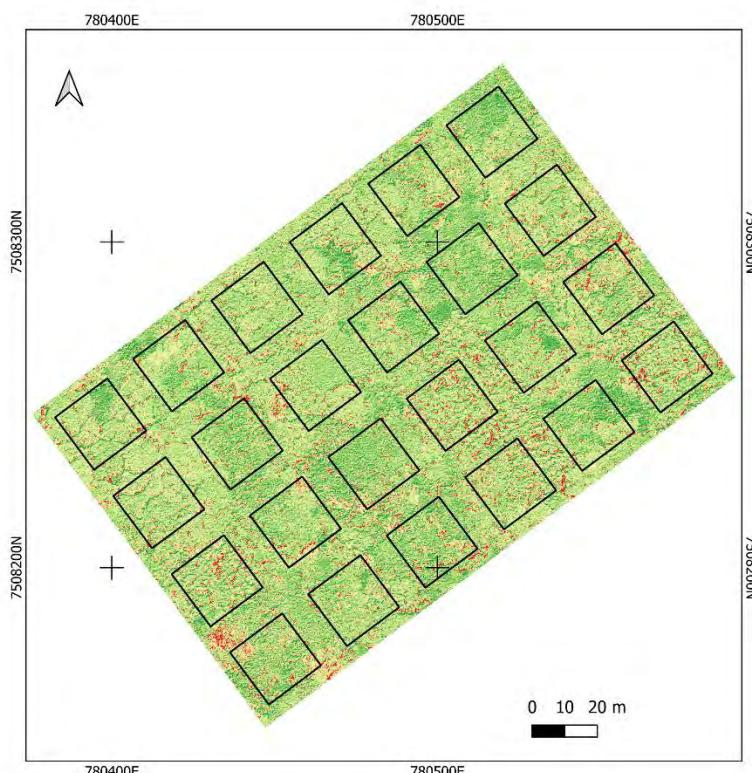
$$VDVI = (2 * G - R - B) / (2 * G + R + B)$$

Área útil de 20x20m
VDVI
0.116
0.23
0.345
0.46
0.574

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE B – MAPAS COM OS ÍNDICES DE VEGETAÇÃO CALCULADOS A PARTIR DO ORTOFOTOMOSAICO COM TODOS OS PIXELS.

(continua)

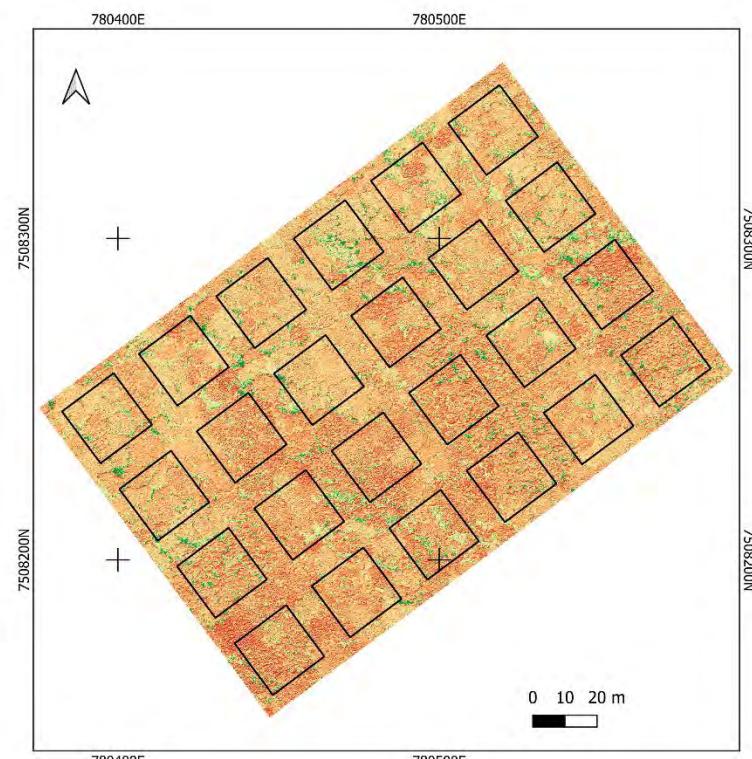


Blue Normalized Difference Vegetation Index (BNDVI)

$$\text{BNDVI} = (\text{NIR} - \text{B}) / (\text{NIR} + \text{B})$$

Área útil de 20x20m
BNDVI
0.7042
0.763
0.8218
0.8806
0.9394

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Chlorophyll Red-Edge Index (CI.RedEdge)

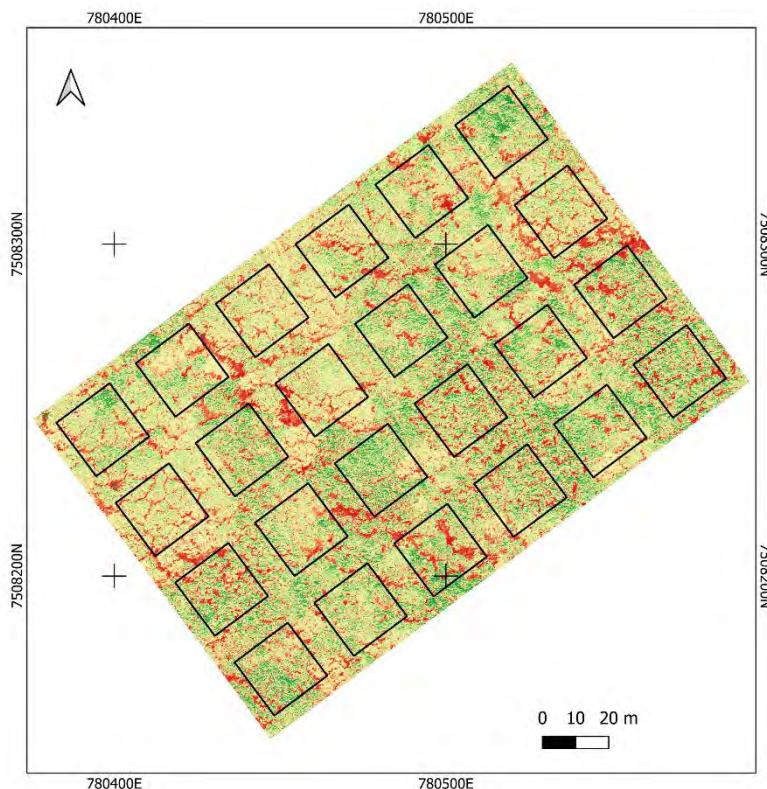
$$\text{CI.RedEdge} = (\text{NIR} / \text{RedEdge}) - 1$$

Área útil de 20x20m
CIRedEdge
0.0903
0.623
1.16
1.69
2.22

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE B

(continua)

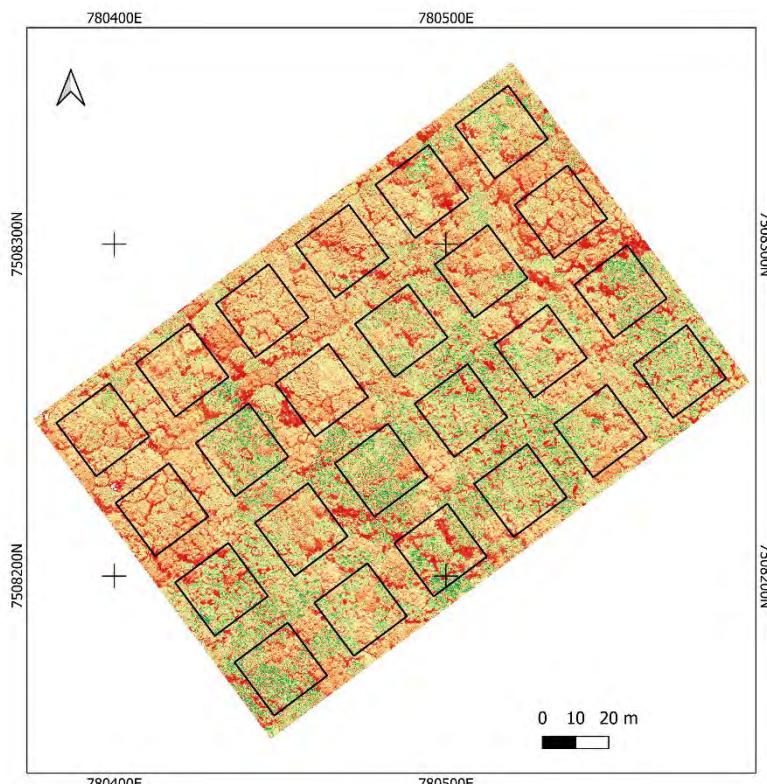


Enhanced Vegetation Index (EVI)

$$EVI = 2.5 * \frac{(NIR - R)}{(NIR + 6 * R - 7.5 * B + 1)}$$

- Área útil de 20x20m
- EVI
- 659.87
- 3958.6
- 7257.3
- 10556
- 13855

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Excess Green Index (ExG)

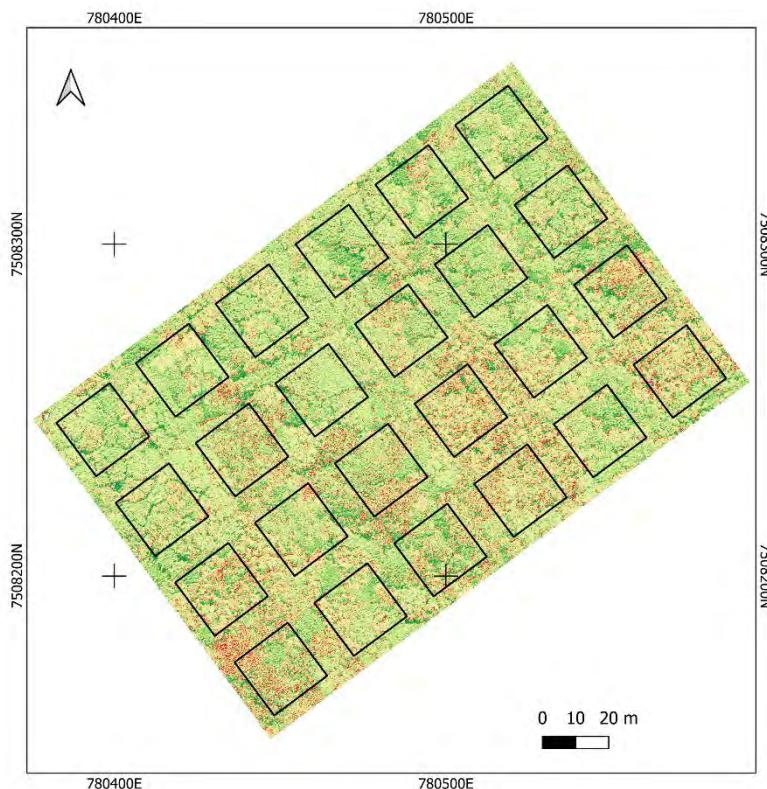
$$ExG = 2 * G - R - B$$

- Área útil de 20x20m
- ExG
- 30
- 410
- 790
- 1170
- 1550

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE B

(continua)

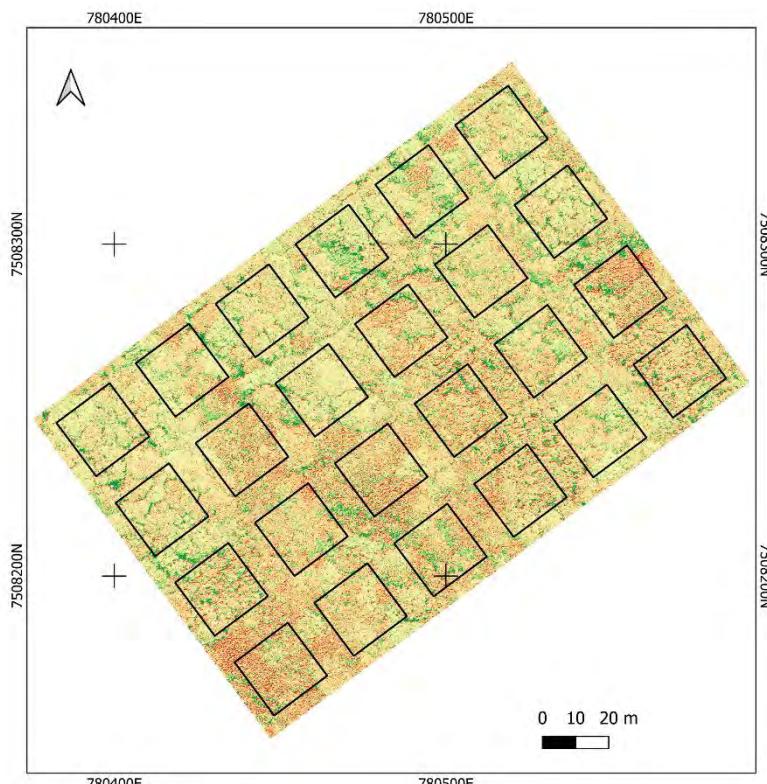


Green Normalized Difference Vegetation (GNDVI)

$$GNDVI = (NIR - G) / (NIR + G)$$

■	Área útil de 20x20m
■	0.453
■	0.565
■	0.676
■	0.788
■	0.9

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Normalized Difference RedEdge (NDRE)

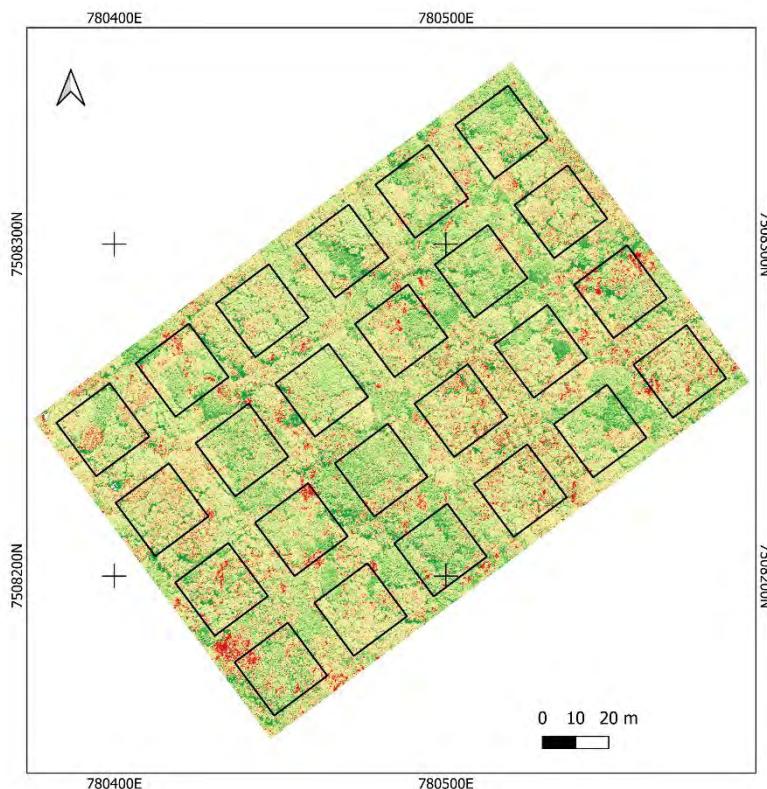
$$NDRE = (NIR - RedEdge) / (NIR + RedEdge)$$

■	Área útil de 20x20m
■	0.0432
■	0.164
■	0.285
■	0.406
■	0.526

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE B

(continua)

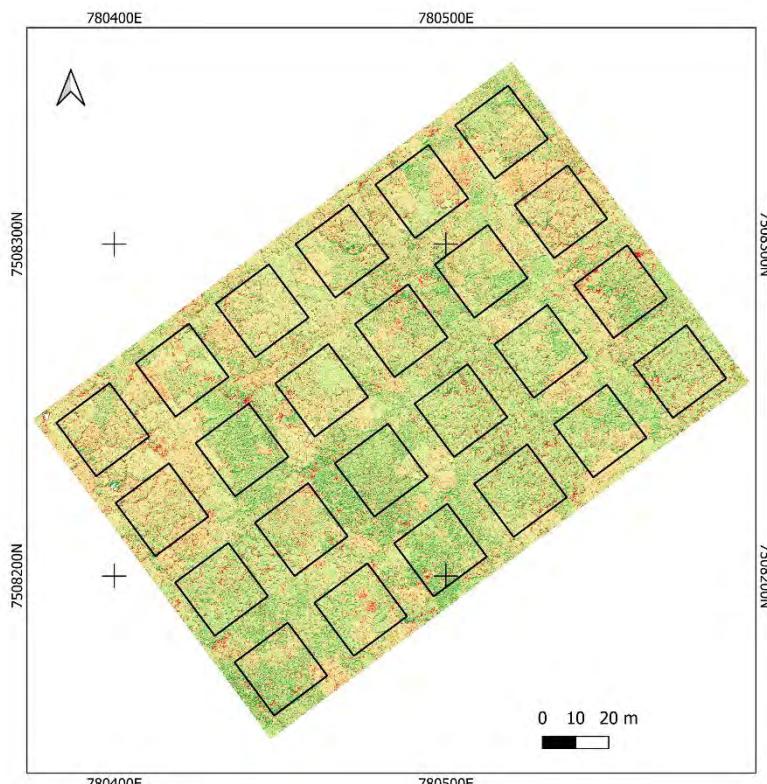


Normalized Difference Vegetation Index (NDVI)

$$NDVI = (NIR - R) / (NIR + R)$$

- Área útil de 20x20m
- NDVI
- 0.7571
- 0.8045
- 0.8518
- 0.8992
- 0.9465

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Normalized Green Red Difference Index (NGRDI)

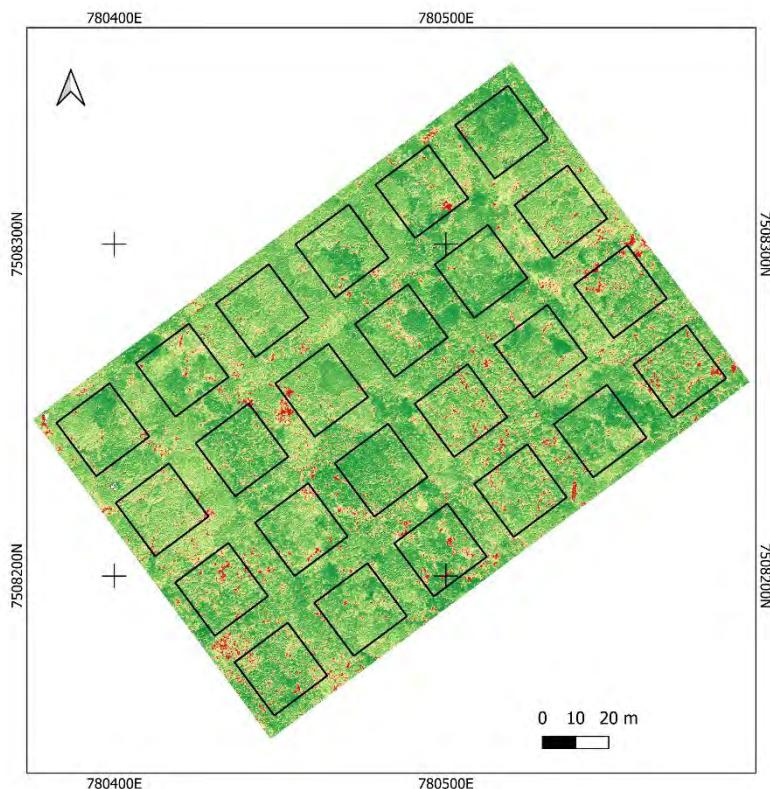
$$NGRDI = (G - R) / (G + R)$$

- Área útil de 20x20m
- NGRDI
- 0.0588
- 0.207
- 0.354
- 0.502
- 0.65

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE B

(continua)



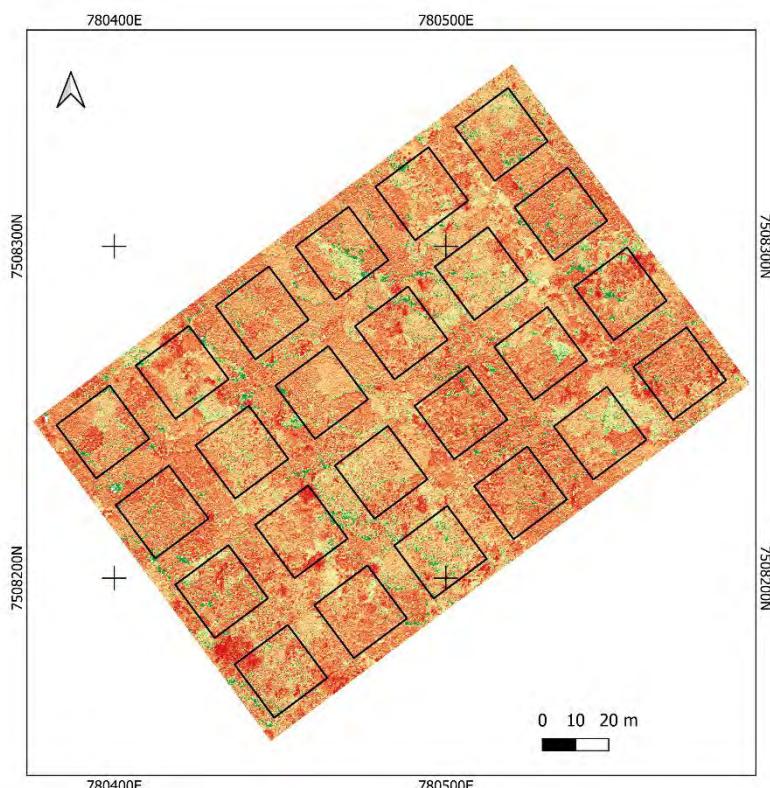
Índice Não Linear (NLI)

$$NLI = (NIR^2 - R) / (NIR^2 + R)$$

Área útil de 20x20m

■	NLI
■	0.999846
■	0.999801
■	0.9999142
■	0.9999483
■	0.9999824

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Simple Ratio (SR)

$$SR = NIR / R$$

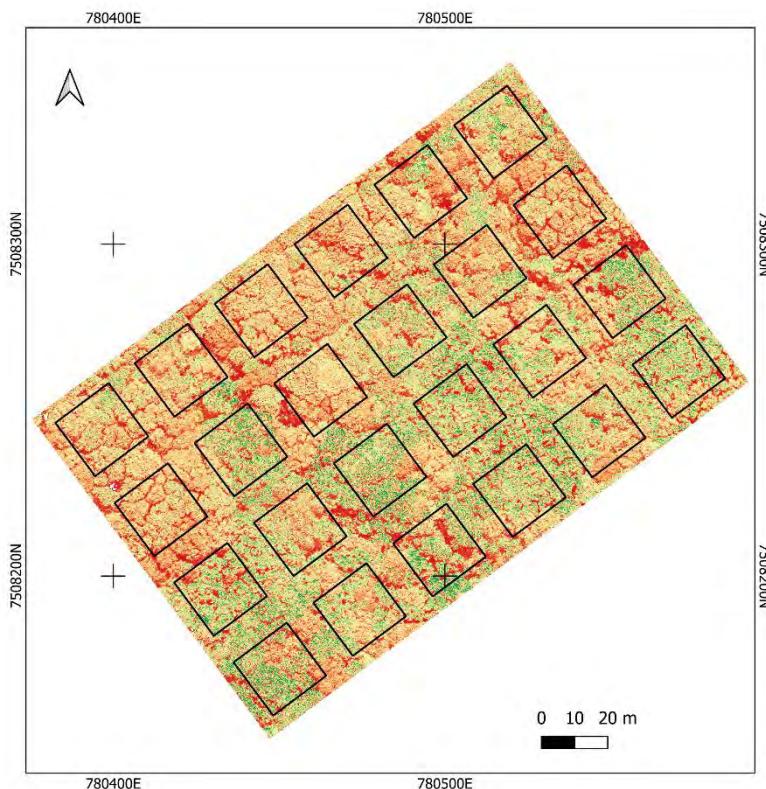
Legend for the 20x20m area:

- SR: 7.24
- 14.5
- 21.8
- 29.1
- 36.4

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE B

(continuação)

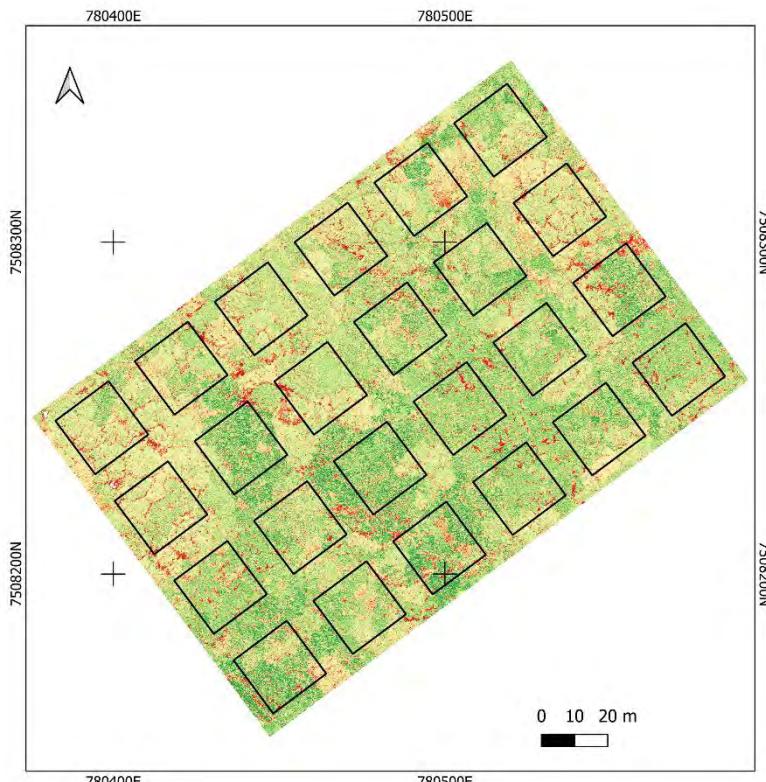


Triangle Greenness Index (TGI)

$$TGI = G - 0,39 * R - 0,61 * B$$

Área útil de 20x20m
TGI
10.9
203
396
588
781

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.



Visible Difference Vegetation Index (VDVI)

$$VDVI = (2 * G - R - B) / (2 * G + R + B)$$

Área útil de 20x20m
VDVI
0.0709
0.196
0.322
0.447
0.573

Sistema de referência de coordenadas
Datum SIRGAS 2000
Projeção UTM, 23 S
Data de execução: 12/2024
Elaboração: Júlia Ayres de Oliveira.

APÊNDICE C –FAMÍLIAS E ESPÉCIES REGISTRADAS EM TODA ÁREA EXPERIMENTAL.

(continua)

Família/Espécies		Forma de vida	Origem
Anacardiaceae			
<i>Tapirira guianensis</i> Aubl.		Árvore	Nativa
Annonaceae			
<i>Xylopia sericea</i> A.St.-Hil.		Arbusto, árvore	Nativa
Asteraceae			
<i>Moquiniastrum polymorphum</i> (Less.) G. Sancho		Arbusto, árvore	Nativa
Bignoniaceae			
<i>Handroanthus albus</i> (Cham.) Mattos		Árvore	Nativa
<i>Sparattosperma leucanthum</i> (Vell.) K.Schum.		Árvore	Nativa
Calophyllaceae			
<i>Calophyllum brasiliense</i> Cambess.		Árvore	Nativa
Cannabaceae			
<i>Trema micranthum</i> (L.) Blume		Arbusto, árvore	Nativa
Caricaceae			
<i>Jacarata spinosa</i> (Aubl.) A.DC. ***		Árvore	Nativa
Euphorbiaceae			
<i>Alchornea glandulosa</i> Poepp. & Endl.		Arbusto, árvore	Nativa
<i>Tetrorchidium rubrivenium</i> Poepp.		Árvore	Nativa
Fabaceae			
<i>Centrolobium tomentosum</i> Guillem. ex Benth.		Árvore	Nativa
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.		Árvore	Nativa
<i>Inga edulis</i> Mart.		Árvore	Nativa
<i>Plathymeria reticulata</i> Benth. ***		Arbusto, árvore	Nativa
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima ***		Árvore	Nativa
<i>Pterocarpus rohrii</i> Vahl		Árvore	Nativa
<i>Swartzia langsdorffii</i> Raddi ***		Árvore	Nativa
Lacistemaceae			
<i>Lacistema pubescens</i> Mart.		Arbusto, árvore	Nativa
Lauraceae			
Lauraceae sp. 1		-	-
Lauraceae sp. 2		-	-
Lauraceae sp. 3		-	-
<i>Nectandra cissiflora</i> Nees ***		Árvore	Nativa
<i>Nectandra membranacea</i> (Sw.) Griseb.		Árvore	Nativa
<i>Ocotea laxa</i> (Nees) Mez		Arbusto, árvore	Nativa
Lecythidaceae			
<i>Cariniana legalis</i> (Mart.) Kuntze *		Árvore	Nativa
Malvaceae			
<i>Pseudobombax majus</i> (A.Robyns) Carv.-Sobr. ***		Árvore	Nativa
Melastomataceae			
<i>Miconia calvescens</i> DC.		Arbusto, árvore	Nativa
<i>Miconia prasina</i> (Sw.) DC.		Arbusto, árvore	Nativa
<i>Pleroma granulosum</i> (Desr.) D. Don ***		Arbusto	Nativa

APÊNDICE C

(continuação)

Família/Espécies	Forma de vida	Origem
Meliaceae		
<i>Cedrela fissilis</i> Vell. **	Árvore	Nativa
<i>Guarea guidonia</i> (L.) Sleumer	Árvore	Nativa
Moraceae		
<i>Artocarpus heterophyllus</i> Lam.	Árvore	Naturalizada
<i>Helicostylis tomentosa</i> (Poepp. & Endl.) Rusby ***	Árvore	Nativa
Myrtaceae		
<i>Eugenia florida</i> DC.	Arbusto, árvore	Nativa
<i>Myrcia neolucida</i> A.R.Lourenço & E.Lucas	Árvore	Nativa
<i>Myrcia splendens</i> (Sw.) DC.	Árvore	Nativa
<i>Myrcia strigipes</i> Mart.	Arbusto, árvore	Nativa
<i>Plinia edulis</i> (Vell.) Sobral *	Árvore	Nativa
<i>Psidium guajava</i> L.	Árvore	Naturalizada
Piperaceae		
<i>Piper arboreum</i> var. <i>hirtellum</i> Yunck.	Arbusto	Nativa
Primulaceae		
<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	Arbusto, árvore	Nativa
Rutaceae		
<i>Citrus aurantiifolia</i> (Christm.) Swingle	Árvore	Cultivada
Salicaceae		
<i>Casearia</i> sp.	-	-
<i>Casearia sylvestris</i> Sw.	Arbusto, árvore, subarbusto	Nativa
Sapindaceae		
<i>Cupania vernalis</i> Cambess.	Árvore	Nativa
Siparunaceae		
<i>Siparuna guianensis</i> Aubl.	Arbusto, árvore	Nativa
Solanaceae		
Solanaceae 1	-	-
Urticaceae		
<i>Cecropia pachystachya</i> Trécul	Árvore	Nativa
Verbenaceae		
<i>Citharexylum myrianthum</i> Cham.	Árvore	Nativa
Indeterminada		
Indeterminada	-	-

Categoria de ameaça: *Em perigo. **Vulnerável. ***Pouco preocupante. Fonte: Flora e Funga do Brasil, Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/>>. Acesso em: 24 jul. 2024.

APÊNDICE D – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES PIONEIRAS (Pi).

Espécie	Abundância	Área basal (m²)	Área de copa (m²)
<i>Alchornea glandulosa</i> Poepp. & Endl.	75	1,785	1184,636
<i>Artocarpus heterophyllus</i> Lam.	2	0,005	10,407
<i>Cecropia pachystachya</i> Trécul	4	0,038	21,284
<i>Citharexylum myrianthum</i> Cham.	26	0,652	291,006
<i>Guarea guidonia</i> (L.) Sleumer	57	0,780	1091,303
<i>Inga edulis</i> Mart.	1	0,003	3,189
<i>Miconia calvescens</i> DC.	8	0,039	105,086
<i>Miconia prasina</i> (Sw.) DC.	22	0,085	188,590
<i>Moquiniastrum polymorphum</i> (Less.) G. Sancho	2	0,030	19,187
<i>Myrcia neolucida</i> A.R.Lourenço & E.Lucas	1	0,005	4,406
<i>Nectandra membranacea</i> (Sw.) Griseb.	1	0,003	10,462
<i>Pleroma granulosum</i> (Desr.) D. Don	1	0,004	5,466
<i>Psidium guajava</i> L.	1	0,003	2,969
<i>Siparuna guianensis</i> Aubl.	1	0,003	8,372
Solanaceae 1	1	0,009	19,321
<i>Sparattosperma leucanthum</i> (Vell.) K.Schum.	2	0,056	23,955
<i>Tapirira guianensis</i> Aubl.	5	0,107	70,654
<i>Trema micranthum</i> (L.) Blume	1	0,009	20,852
Total	211	3,615	3081,144

APÊNDICE E – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES SECUNDÁRIAS (Se).

Espécie	Abundância	Área basal (m²)	Área de copa (m²)
<i>Alchornea glandulosa</i> Poepp. & Endl.	2	0,010	8,011
<i>Artocarpus heterophyllus</i> Lam.	1	0,011	15,135
<i>Cecropia pachystachya</i> Trécul	1	0,015	28,078
<i>Centrolobium tomentosum</i> Guillem. ex Benth.	7	0,109	79,042
<i>Citharexylum myrianthum</i> Cham.	1	0,057	11,938
<i>Cupania vernalis</i> Cambess.	1	0,003	6,597
<i>Guarea guidonia</i> (L.) Sleumer	80	0,530	941,967
<i>Inga edulis</i> Mart.	6	0,325	193,451
<i>Jacaratia spinosa</i> (Aubl.) A.DC.	5	0,296	99,290
<i>Lacistema pubescens</i> Mart.	1	0,004	3,299
Lauraceae 1	1	0,005	12,496
Lauraceae 2	1	0,003	8,011
Lauraceae 3	1	0,004	6,597
<i>Miconia prasina</i> (Sw.) DC.	6	0,016	48,102
<i>Myrcia strigipes</i> Mart.	1	0,004	3,731
<i>Nectandra membranacea</i> (Sw.) Griseb.	5	0,029	23,860
<i>Ocotea laxa</i> (Nees) Mez	2	0,012	8,074
<i>Pleroma granulosum</i> (Desr.) D. Don	9	0,412	125,946
<i>Pseudobombax majus</i> (A.Robyns) Carv.-Sobr.	55	0,916	351,415
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	13	0,167	248,956
<i>Siparuna guianensis</i> Aubl.	6	0,022	70,183
<i>Sparattosperma leucanthum</i> (Vell.) K.Schum.	1	0,002	5,655
<i>Tapirira guianensis</i> Aubl.	12	1,273	1014,279
<i>Tetrorchidium rubrivenium</i> Poepp.	2	0,008	6,142
<i>Xylopia sericea</i> A.St.-Hil.	2	0,004	4,547
Total	222	4,239	3324,802

APÊNDICE F – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES CLÍMAX (CL).

Espécie	Abundância	Área basal (m²)	Área de copa (m²)
<i>Calophyllum brasiliense</i> Cambess.	16	0,224	166,359
<i>Cariniana legalis</i> (Mart.) Kuntze	1	0,005	3,613
<i>Cecropia pachystachya</i> Trécul	3	0,048	22,109
<i>Cedrela fissilis</i> Vell.	3	0,012	10,438
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	5	0,033	20,628
<i>Eugenia florida</i> DC.	20	1,146	898,303
<i>Guarea guidonia</i> (L.) Sleumer	72	1,234	1423,350
<i>Miconia calvescens</i> DC.	1	0,002	11,200
<i>Miconia prasina</i> (Sw.) DC.	2	0,009	22,384
<i>Plathymenia reticulata</i> Benth.	37	2,498	1176,189
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	2	0,023	7,171
<i>Pterocarpus rohrii</i> Vahl	4	0,041	28,573
<i>Swartzia langsdorffii</i> Radde	1	0,002	7,477
Total	167	5,279	3797,793

APÊNDICE G – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES PIONEIRAS, SECUNDÁRIAS E CLÍMAX (PSC).

Espécie	Abundância	Área basal (m ²)	Área de copa (m ²)
<i>Alchornea glandulosa</i> Poepp. & Endl.	26	0,337	225,370
<i>Artocarpus heterophyllus</i> Lam.	2	0,031	27,819
<i>Calophyllum brasiliense</i> Cambess.	2	0,012	9,331
<i>Cariniana legalis</i> (Mart.) Kuntze	1	0,021	27,269
<i>Casearia</i> sp.	1	0,002	7,540
<i>Cedrela fissilis</i> Vell.	5	0,051	51,530
<i>Citharexylum myrianthum</i> Cham.	10	0,264	83,786
<i>Cupania vernalis</i> Cambess.	1	0,003	5,773
<i>Eugenia florida</i> DC.	9	0,382	356,457
<i>Guarea guidonia</i> (L.) Sleumer	35	0,537	902,360
<i>Handroanthus albus</i> (Cham.) Mattos	1	0,004	5,498
<i>Helicostylis tomentosa</i> (Poepp. & Endl.) Rusby	2	0,005	14,019
<i>Inga edulis</i> Mart.	20	0,678	540,048
Lauraceae 1	1	0,003	4,147
<i>Miconia calvescens</i> DC.	1	0,004	15,779
<i>Miconia prasina</i> (Sw.) DC.	4	0,013	41,752
<i>Myrcia splendens</i> (Sw.) DC.	1	0,003	4,335
<i>Nectandra cissiflora</i> Nees	1	0,005	5,301
<i>Nectandra membranacea</i> (Sw.) Griseb.	5	0,048	41,029
<i>Piper arboreum</i> var. <i>hirtellum</i> Yunck.	2	0,006	29,421
<i>Plathymenia reticulata</i> Benth.	7	0,821	589,284
<i>Pleroma granulosum</i> (Desr.) D. Don	3	0,301	161,949
<i>Siparuna guianensis</i> Aubl.	7	0,028	80,825
<i>Tapirira guianensis</i> Aubl.	2	0,008	10,202
<i>Xylopia sericea</i> A.St.-Hil.	1	0,003	0,000
Total	150	3,571	3240,825

APÊNDICE H – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES PIONEIRAS E CLÍMAX (PC).

Espécie	Abundância	Área basal (m²)	Área de copa (m²)
<i>Alchornea glandulosa</i> Poepp. & Endl.	23	0,798	599,926
<i>Calophyllum brasiliense</i> Cambess.	36	0,492	500,833
<i>Casearia sylvestris</i> Sw.	1	0,004	10,171
<i>Citharexylum myrianthum</i> Cham.	20	0,472	231,583
<i>Citrus aurantiifolia</i> (Christm.) Swingle	1	0,003	0,000
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	7	0,148	148,629
<i>Eugenia florida</i> DC.	20	0,987	893,705
<i>Guarea guidonia</i> (L.) Sleumer	31	0,368	529,099
Indeterminada	1	0,003	3,471
<i>Miconia calvescens</i> DC.	2	0,010	30,442
<i>Miconia prasina</i> (Sw.) DC.	8	0,032	58,889
<i>Myrcia splendens</i> (Sw.) DC.	1	0,007	4,838
<i>Piper arboreum</i> var. <i>hirtellum</i> Yunck.	4	0,017	60,484
<i>Plinia edulis</i> (Vell.) Sobral	1	0,004	5,938
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	2	0,021	14,443
<i>Siparuna guianensis</i> Aubl.	1	0,002	7,069
<i>Tapirira guianensis</i> Aubl.	2	0,073	86,834
Total	161	3,441	3186,352

APÊNDICE I – ABUNDÂNCIA, ÁREA BASAL E ÁREA DE COPA DAS ESPÉCIES DO TRATAMENTO COMPOSTO POR ESPÉCIES SECUNDÁRIAS E CLÍMAX (SC).

Espécie	Abundância	Área basal (m²)	Área de copa (m²)
<i>Cariniana legalis</i> (Mart.) Kuntze	1	0,008	6,032
<i>Cecropia pachystachya</i> Trécul	1	0,002	0,785
<i>Cedrela fissilis</i> Vell.	2	0,008	21,457
<i>Centrolobium tomentosum</i> Guillem. ex Benth.	14	0,119	57,224
<i>Guarea guidonia</i> (L.) Sleumer	44	0,655	823,011
<i>Handroanthus albus</i> (Cham.) Mattos	1	0,002	3,456
<i>Jacaratia spinosa</i> (Aubl.) A.DC.	4	0,383	140,327
<i>Miconia calvescens</i> DC.	10	0,036	82,082
<i>Miconia prasina</i> (Sw.) DC.	4	0,011	36,026
<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	1	0,063	27,489
<i>Nectandra membranacea</i> (Sw.) Griseb.	1	0,004	8,985
<i>Plathymenia reticulata</i> Benth.	40	3,625	1424,054
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	9	0,167	172,316
<i>Pterocarpus rohrii</i> Vahl	6	0,076	48,577
<i>Siparuna guianensis</i> Aubl.	1	0,003	13,525
<i>Tapirira guianensis</i> Aubl.	15	1,801	1062,542
Total	154	6,962	3927,888

APÊNDICE J – VALORES DOS ATRIBUTOS FUNCIONAIS POR ESPÉCIE.

(continua)

Espécie	LDMC(mg.g ⁻¹)	LA (mm ²)	SLA (cm ² .g ⁻¹)	N (%)	C (%)	P (g.kg ⁻¹)
<i>Alchornea glandulosa</i> Poepp. & Endl.	348,681	8816,847	160,548	2,615	45,125	1,38
<i>Artocarpus heterophyllus</i> Lam.	327,243	10943,647	131,199	2,008	39,185	0,94
<i>Calophyllum brasiliense</i> Cambess.	316,500	4687,067	129,840	1,263	46,555	0,93
<i>Cariniana legalis</i> (Mart.) Kuntze	358,412	1492,422	202,272	2,504	41,693	1,14
<i>Casearia</i> sp.	278,431	9968,700	133,247	1,795	42,518	0,63
<i>Casearia sylvestris</i> Sw.	317,580	2693,933	200,616	2,344	42,448	0,94
<i>Cecropia pachystachya</i> Trécul	217,607	61440,750	230,173	2,373	38,986	1,58
<i>Cedrela fissilis</i> Vell.	269,212	3227,822	381,486	4,254	43,554	0,82
<i>Centrolobium tomentosum</i> Guillem. ex Benth.	336,178	5802,413	300,373	3,309	44,822	1,31
<i>Citharexylum myrianthum</i> Cham.	288,578	6953,487	150,007	2,091	43,353	1,31
<i>Citrus aurantiifolia</i> (Christm.) Swingle	-	-	-	-	-	-
<i>Cupania vernalis</i> Cambess.	311,071	28834,967	144,840	2,551	45,358	1,11
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	368,491	2912,838	283,336	2,558	44,259	0,91
<i>Eugenia florida</i> DC.	397,333	4661,240	130,799	1,738	46,231	1,1
<i>Guarea guidonia</i> (L.) Sleumer	329,267	5711,913	186,561	3,380	46,134	1,4
<i>Handroanthus albus</i> (Cham.) Mattos	307,414	1666,200	292,363	3,542	42,703	1,62
<i>Helicostylis tomentosa</i> (Poepp. & Endl.) Rusby	350,553	12917,683	175,988	2,44	40,714	0,95
Indeterminada	215,899	3045,300	242,177	2,437	38,321	1,28
<i>Inga edulis</i> Mart.	382,883	3967,607	143,437	2,922	44,710	1,43
<i>Jacaratia spinosa</i> (Aubl.) A.DC.	219,405	3491,900	217,010	3,187	41,233	1,95
<i>Lacistema pubescens</i> Mart.	250,509	3251,367	236,092	2,387	43,569	0,99
Lauraceae 1	338,682	3193,517	150,011	2,637	46,741	1,25
Lauraceae 2	435,749	8611,833	95,901	1,561	44,823	0,73
Lauraceae 3	345,114	3631,233	155,689	3,127	47,684	1,16
<i>Miconia calvescens</i> DC.	259,369	23236,700	166,525	1,713	39,511	1,12
<i>Miconia prasina</i> (Sw.) DC.	266,696	12426,760	193,368	2,183	38,070	0,82

APÊNDICE J

(continuação)

Espécie	LDMC(mg.g ⁻¹)	LA (mm ²)	SLA (cm ² .g ⁻¹)	N (%)	C (%)	P (g.kg ⁻¹)
<i>Moquiniastrum polymorphum</i> (Less.) G. Sancho	338,130	8980,667	167,655	2,432	44,263	1,18
<i>Myrcia neolucida</i> A.R.Lourenço & E.Lucas	309,168	2785,167	144,083	1,832	43,538	1,01
<i>Myrcia splendens</i> (Sw.) DC.	340,169	3790,117	149,828	2,075	44,349	0,83
<i>Myrcia strigipes</i> Mart.	423,588	11017,200	104,489	1,538	40,914	0,74
<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	229,054	3733,000	221,528	3,304	46,864	2,07
<i>Nectandra cissiflora</i> Nees	466,521	10355,900	100,117	1,828	45,959	0,88
<i>Nectandra membranacea</i> (Sw.) Griseb.	405,617	9680,890	136,757	2,234	46,190	0,88
<i>Ocotea laxa</i> (Nees) Mez	421,099	11092,617	109,163	1,716	47,276	0,82
<i>Piper arboreum</i> var. <i>hirtellum</i> Yunck.	187,365	10951,925	239,094	3,213	40,613	1,21
<i>Plathymenia reticulata</i> Benth.	393,592	1080,592	167,983	2,811	48,064	1,98
<i>Pleroma granulosum</i> (Desr.) D. Don	305,238	6263,683	151,864	1,933	42,887	1,22
<i>Plinia edulis</i> (Vell.) Sobral	386,870	4043,300	149,117	1,610	45,352	0,65
<i>Pseudobombax majus</i> (A.Robyns) Carv.-Sobr.	284,171	17142,837	200,258	2,361	43,613	1,41
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	410,784	614,327	130,795	2,689	45,182	0,68
<i>Psidium guajava</i> L.	339,761	3910,300	108,636	1,808	44,398	1,03
<i>Pterocarpus rohrii</i> Vahl	311,707	3284,088	279,356	3,743	44,228	1,06
<i>Siparuna guianensis</i> Aubl.	268,303	6441,743	174,223	2,897	43,092	1,11
Solanaceae 1	264,512	2088,967	184,589	3,755	42,424	1,3
<i>Sparattosperma leucanthum</i> (Vell.) K.Schum.	317,099	3716,211	241,534	2,715	47,515	1,32
<i>Swartzia langsdorffii</i> Raddi	344,873	1861,550	314,138	4,013	45,702	1,08
<i>Tapirira guianensis</i> Aubl.	392,745	2234,260	123,641	1,705	43,252	0,91
<i>Tetrorchidium rubrivenium</i> Poepp.	189,102	8308,150	198,461	3,052	42,256	1,74
<i>Trema micranthum</i> (L.) Blume	285,685	3099,533	240,033	2,885	39,398	1,49
<i>Xylopia sericea</i> A.St.-Hil.	403,143	807,311	164,726	2,159	44,739	0,77

LDMC: Conteúdo de matéria seca da folha (*Leaf dry matter content*); LA: Área foliar (*Leaf Area*). SLA: Área foliar específica (*Specific leaf area*); N: Concentração de nitrogênio foliar; C: Concentração de carbono foliar; P: concentração de fósforo foliar.

ANEXO A – PONTOS DE CONTROLE EM SUPERFÍCIE E COORDENADAS DOS VÉRTICES DAS PARCELAS.

(continua)

Nome	Coordenada X	Desvio 95%	Coordenada Y	Desvio 95%
Base	781052.544	0.000	7508978.267	0.000
Pontos de controle				
1	780359.438	0.001	7508606.719	0.001
2	780461.444	0.001	7508638.973	0.001
3	780269.953	0.001	7508590.800	0.001
Vértices das parcelas				
C1	780434.243	0.027	7508262.309	0.054
C10	780448.783	0.025	7508261.985	0.061
C11	780440.180	0.025	7508253.955	0.023
C12	780425.070	0.083	7508241.869	0.072
C13	780415.687	0.054	7508236.179	0.054
C14	780400.610	0.048	7508226.704	0.067
C15	780472.591	0.04	7508280.614	0.064
C2	780406.135	0.002	7508265.948	0.003
C3	780397.534	0.002	7508260.400	0.003
C4	780535.456	0.076	7508327.666	0.073
C5	780522.333	0.085	7508319.077	0.057
C6	780512.165	0.034	7508311.552	0.065
C7	780497.239	0.037	7508298.476	0.04
C8	780487.302	0.058	7508292.991	0.061
C9	780463.372	0.034	7508272.083	0.064
D1	780443.013	0.002	7508216.765	0.003
D10	780508.958	0.057	7508233.400	0.062
D11	780522.306	0.027	7508245.577	0.065
D12	780529.707	0.047	7508251.183	0.063
D13	780546.876	0.029	7508262.113	0.035
D14	780555.603	0.02	7508269.442	0.028
D15	780573.263	0.039	7508280.613	0.054
D16	780531.348	0.041	7508335.416	0.044
D17	780513.409	0.023	7508325.387	0.042
D18	780504.447	0.048	7508317.526	0.058
D19	780489.719	0.054	7508306.261	0.045
D2	780434.001	0.017	7508212.548	0.066
D20	780487.979	0.04	7508298.094	0.051
D21	780480.870	0.002	7508291.822	0.002
D22	780453.477	0.036	7508310.448	0.059
D23	780457.810	0.002	7508280.121	0.003
D24	780443.883	0.002	7508267.713	0.004
D25	780556.065	0.028	7508302.799	0.056
D26	780537.298	0.037	7508292.110	0.042
D27	780527.738	0.065	7508284.650	0.062
D28	780511.776	0.014	7508274.562	0.034
D29	780506.024	0.007	7508268.836	0.066

ANEXO A

(continuação)

Nome	Coordenada X	Desvio 95%	Coordenada Y	Desvio 95%
Vértices das parcelas				
D3	780416.697	0.017	7508202.119	0.065
D30	780481.306	0.031	7508250.223	0.023
D31	780481.306	0.054	7508250.223	0.039
D32	780467.507	0.033	7508237.537	0.049
D33	780458.313	0.066	7508230.288	0.063
D4	780410.768	0.023	7508209.075	0.057
D5	780449.419	0.034	7508191.149	0.065
D6	780458.919	0.051	7508195.288	0.065
D7	780475.958	0.054	7508206.998	0.065
D8	780483.314	0.048	7508214.239	0.044
D9	780499.756	0.049	7508225.879	0.06
A1	780421.884	0.003	7508277.008	0.003
A10	780499.993	0.046	7508277.076	0.05
A11	780481.346	0.036	7508264.767	0.064
A12	780473.437	0.029	7508255.040	0.064
A13	780459.654	0.046	7508247.494	0.065
A14	780453.439	0.037	7508238.970	0.064
A15	780436.823	0.056	7508226.330	0.064
A16	780429.106	0.01	7508220.160	0.067
A17	780408.810	0.046	7508211.400	0.063
A18	780518.632	0.027	7508350.776	0.029
A19	780501.612	0.003	7508340.604	0.004
A2	780416.566	0.002	7508250.320	0.003
A20	780493.434	0.035	7508334.783	0.066
A21	780478.391	0.003	7508322.709	0.003
A22	780471.078	0.04	7508321.963	0.055
A23	780476.748	0.039	7508313.673	0.046
A24	780461.128	0.039	7508302.350	0.049
A25	780445.392	0.033	7508296.336	0.049
A26	780431.294	0.001	7508283.386	0.002
A27	780567.641	0.044	7508286.185	0.053
A28	780549.193	0.025	7508276.178	0.035
A29	780543.769	0.07	7508269.745	0.057
A3	780408.075	0.003	7508245.667	0.004
A30	780526.319	0.009	7508255.898	0.03
A31	780516.156	0.036	7508253.000	0.057
A32	780501.225	0.061	7508240.312	0.048
A33	780493.663	0.001	7508234.044	0.002
A34	780476.244	0.012	7508223.004	0.025
A35	780471.124	0.041	7508214.674	0.063
A4	780392.220	0.001	7508235.057	0.002
A5	780380.992	0.043	7508250.126	0.042
A6	780548.135	0.041	7508312.264	0.052

ANEXO A

(continuação)

Nome	Coordenada X	Desvio 95%	Coordenada Y	Desvio 95%
Vértices das parcelas				
A7	780532.381	0.015	7508302.258	0.065
A8	780525.009	0.009	7508294.854	0.025
A9	780508.719	0.017	7508283.531	0.031
B1	780456.640	0.067	7508204.464	0.06
B10	780511.049	0.033	7508210.651	0.042
B11	780510.712	0.002	7508210.394	0.002
B12	780518.778	0.012	7508217.318	0.031
B13	780534.538	0.06	7508228.484	0.069
B14	780542.292	0.046	7508234.952	0.044
B15	780556.413	0.05	7508246.194	0.059
B16	780568.420	0.039	7508252.752	0.036
B17	780583.558	0.034	7508264.706	0.038
B2	780445.671	0.042	7508196.406	0.061
B3	780429.339	0.03	7508185.382	0.065
B4	780433.430	0.023	7508179.708	0.065
B5	780445.169	0.068	7508164.124	0.062
B6	780462.696	0.041	7508175.540	0.064
B7	780472.726	0.014	7508180.642	0.035
B8	780489.009	0.053	7508191.382	0.063
B9	780495.751	0.039	7508197.920	0.04

Fonte: Levantamento Topográfico Georreferenciado, 2024. Responsável técnico: Gustavo Barros Ventorim. Registro Nacional: 06418476611.