



UNIVERSIDADE FEDERAL DO PARANÁ

LUCAS HENDERSON DE OLIVEIRA SANTOS

CLASSIFICAÇÃO DE ESTÁGIOS SUCESSIONAIS DA VEGETAÇÃO
SECUNDÁRIA NA FLORESTA OMBRÓFILA MISTA: UM ENFOQUE DE MÉTRICAS
UAV-LIDAR E LIDAR MLS

CURITIBA

2025

LUCAS HENDERSON DE OLIVEIRA SANTOS

CLASSIFICAÇÃO DE ESTÁGIOS SUCESSIONAIS DA VEGETAÇÃO
SECUNDÁRIA NA FLORESTA OMBRÓFILA MISTA: UM ENFOQUE DE MÉTRICAS
UAV-LIDAR E LIDAR MLS

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal, Área de Concentração em Manejo Florestal.

Orientadora: Profa. Dra. Ana Paula Dalla Corte
Coorientador: Prof. Dr. Christopher Thomas Blum
Coorientador: Prof. Dr. Vagner Alex Pesck

CURITIBA

2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ / SISTEMA DE BIBLIOTECAS
BIBLIOTECA DE CIÊNCIAS FLORESTAIS E DA MADEIRA

Santos, Lucas Henderson de Oliveira

Classificação de estágios sucessionais da vegetação secundária na floresta ombrófila mista: um enfoque de métricas UAV-LIDAR e LIDAR MLS. - Curitiba, 2025.

1 recurso on-line : PDF

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias. Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 11/06/2025.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Christopher Thomas Blum

Prof. Dr. Vagner Alex Pesck

1. Sucessão florestal. 2. Radar óptico. 3. Florestas - Sensoriamento remoto. 4. Florestas - Medição. 5. Análise multivariada. 6. Mata Atlântica. I. Dalla Corte, Ana Paula. II. Blum, Christopher Thomas. III. Pesck, Vagner Alex. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD - 634.9285

CDU - 528.8

GFDC - 634.0.58

Bibliotecária: Marilene do Rocio Veiga CRB9/424

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **LUCAS HENDERSON DE OLIVEIRA SANTOS**, intitulada: **CLASSIFICAÇÃO DE ESTÁGIO SUCESSIONAL NA FLORESTA OMBROFILA MISTA: UM ENFOQUE EM MÉTRICAS DERIVADAS DE UAV-LIDAR E MLS**, sob orientação da Profa. Dra. ANA PAULA DALLA CORTE, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa. A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 11 de Junho de 2025.

Assinatura Eletrônica

11/06/2025 13:48:40.0

ANA PAULA DALLA CORTE

Presidente da Banca Examinadora

Assinatura Eletrônica

11/06/2025 22:07:33.0

JONATHAN WILLIAM TRAUTENMÜLLER

Avaliador Externo (ESCOLA SUPERIOR DE AGRICULTURA - LUIZ DE QUEIROZ -USP)

Assinatura Eletrônica

12/06/2025 20:11:28.0

ANGELO AUGUSTO EBLING

Avaliador Externo (UNIVERSIDADE FEDERAL DO MATO GROSSO)

Assinatura Eletrônica

11/06/2025 15:19:55.0

CRISTIANO RODRIGUES REIS

Avaliador Externo (UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO - UNESP)

Assinatura Eletrônica

12/06/2025 11:48:17.0

MAURICIO BERGAMINI SCHEER

Avaliador Externo (COMPANHIA DE SANEAMENTO DO PARANA.)

A Deus, aos meus pais Devair e Márcia, meus irmãos Paulo e Vinícius, meus avós Josefa, Júlia, José e Vanildo, minha família e aos meus amigos que estiveram ao meu lado durante esta jornada...

DEDICO!

“A Sabedoria é resplandecente e sempre viçosa. Ela é facilmente contemplada por aqueles que a amam, e é encontrada por aqueles que a procuram. Ela até se antecipa, dando-se a conhecer aos que a desejam. Quem por ela madruga não se cansará, pois a encontrará sentada à sua porta.

Meditar sobre ela é a perfeição da prudência; e quem ficar acordado por causa dela, em breve há de viver despreocupado. Pois ela mesma sai à procura dos que a merecem, cheia de bondade, aparece-lhes nas estradas e vai ao seu encontro em todos os seus projetos...”

Livro da Sabedoria 6,12-16

AGRADECIMENTOS

À Universidade Federal do Paraná (UFPR), em especial ao Programa de Pós-Graduação em Engenharia Florestal (PPGEF), agradeço profundamente pela oportunidade de realizar meu doutorado. A estrutura acadêmica, os recursos disponíveis e o ambiente de excelência científica proporcionaram as condições ideais para o desenvolvimento deste trabalho. Agradeço imensamente por esse apoio, que foi essencial para minha dedicação integral à pesquisa.

À minha orientadora, Prof.^a Dr.^a Ana Paula Dalla Corte, expresso minha mais profunda e especial gratidão. Sua confiança em meu potencial, mesmo nos momentos mais difíceis, foi essencial para que eu pudesse seguir com firmeza nesta jornada. Mais do que uma orientadora, foi uma presença acolhedora e constante, oferecendo não apenas orientação acadêmica de excelência, mas também suporte emocional quando ele foi mais necessário. Sua generosidade, sensibilidade e dedicação ultrapassaram os limites do papel acadêmico e deixaram marcas profundas em minha formação e em minha vida. Se eu pudesse escolher novamente uma orientadora, a escolheria sem hesitar. Sou imensamente grato por tudo que vivemos e construímos juntos ao longo desses anos.

Aos meus coorientadores, Prof. Dr. Christopher Blum e Prof. Dr. Vagner Alex Pesck, agradeço sinceramente pelas contribuições valiosas, pela orientação técnica precisa e pelo comprometimento demonstrado em cada etapa desta pesquisa. Suas colaborações enriqueceram significativamente este trabalho.

Ao Laboratório BIOFIX, registro meu agradecimento pelo suporte técnico, espaço de aprendizado e trocas enriquecedoras ao longo da pesquisa. Agradeço às pessoas que colaboraram com o trabalho de campo, coleta de dados e suporte técnico nas etapas práticas desta pesquisa. Cada contribuição foi fundamental para a conclusão deste projeto.

Durante a minha trajetória, tive também a valiosa oportunidade de atuar como residente técnico no Instituto Água e Terra (IAT), no Paraná. Essa experiência foi marcante para minha formação prática e ampliou significativamente minha visão sobre a gestão ambiental e os desafios da aplicação do conhecimento técnico no setor público. Agradeço a todos os profissionais e colegas do IAT que contribuíram para esse período tão enriquecedor, em especial pelo acolhimento, trocas de saberes e

pela confiança em meu trabalho.

Atualmente, tenho a honra de integrar o quadro de servidores públicos da Secretaria de Meio Ambiente de Itapoá (SEMAI), município onde fui aprovado em concurso público para o cargo de engenheiro florestal. Agradeço à SEMAI e à Prefeitura Municipal de Itapoá pela confiança depositada em meu trabalho e pela oportunidade de contribuir com a gestão ambiental local. Esse novo capítulo na minha trajetória profissional tem sido extremamente significativo, permitindo aplicar na prática o conhecimento adquirido ao longo dos anos e reafirmar meu compromisso com a conservação e o desenvolvimento sustentável.

Aos meus pais, Devair e Márcia, e aos meus irmãos, Paulo e Vinicius, minha eterna gratidão por todo amor, apoio e incentivo em cada passo dessa caminhada. Vocês são minha base, minha força e minha inspiração. Agradeço por estarem sempre presentes, torcendo por mim e compartilhando essa trajetória com companheirismo e orgulho. Aos meus avós, Josefa, Júlia, José e Vanildo, agradeço por todo carinho, exemplo de vida e valores que levo comigo. Suas histórias, ensinamentos e presença são parte fundamental de quem eu sou.

Agradeço de coração aos amigos que estiveram ao meu lado durante essa caminhada. Em especial, à Adriane, Carla, Isabele, Steffano, Lila, Gabriel, Thiago, Verena, Manoela, Leonardo, Rafael, Gabriel, Jessica, Mariana, João, Alexandre, Ademir, Jhonatan, Ageu, Mariese, Júnia, Paula, Eriton e Estevam, Jeff, Rafa, Andrey, Hudson, Igor, Talita, Stéfanie, Dona Maria e sua filha Ana Paula, Fernanda, Lauriane, Dell, Gláucia, Jessica, Fernando, Davi, Kinko, João Cláudio, Lidiane e todos que sempre estiveram presentes nos momentos mais desafiadores, oferecendo apoio, escuta e companheirismo. Estendo esse agradecimento a todos os meus amigos que, ao longo da graduação, mestrado e doutorado, me apoiaram de diversas formas, seja nas trocas de saberes, nos estudos em grupo, nas conversas sinceras ou nos momentos de descontração que tanto aliviaram a jornada.

Sou grato por ter tido a oportunidade de conviver com pessoas tão especiais, com quem aprendi não apenas conteúdos acadêmicos, mas também lições de vida. A convivência com vocês tornou esse caminho mais leve, mais rico e mais humano. E, caso algum nome tenha escapado desta lista, deixo aqui meu pedido de desculpas e meu sincero agradecimento. Cada gesto de amizade, por menor que pareça, teve grande importância para mim e será sempre lembrado com carinho.

A todas as pessoas que, direta ou indiretamente, contribuíram para a realização desta tese, seja com palavras de incentivo, auxílio técnico ou simplesmente com sua presença, deixo meu mais sincero agradecimento. Cada gesto, por menor que tenha parecido, fez diferença e me ajudou a trilhar esse caminho até aqui.

Esta tese é fruto de um percurso coletivo, construído com o apoio e a generosidade de muitas mãos e corações. A cada pessoa que cruzou meu trajeto acadêmico, deixo meu reconhecimento e gratidão. Que este trabalho também represente uma forma de retribuição à ciência, à educação pública e a todos que acreditam no poder transformador do conhecimento.

OBRIGADO!

RESUMO

A presente tese investigou o potencial de diferentes tecnologias LiDAR para classificação e caracterização de estágios sucessionais em remanescentes da Floresta Ombrófila Mista (FOM) no sul do Brasil. O estudo integrou abordagens de sensoriamento remoto de alta resolução e análises ecológicas para testar metodologias robustas de classificação sucessional, essenciais para o monitoramento e gestão de ecossistemas florestais em regeneração. A pesquisa foi estruturada em cinco capítulos complementares. Inicialmente, uma revisão bibliográfica estabeleceu os fundamentos teóricos sobre sucessão florestal, estrutura da vegetação e sensoriamento remoto aplicado a florestas nativas, contextualizando a problemática e justificativa do estudo. O segundo capítulo explorou a aplicação de dados UAV- LiDAR em 30 parcelas permanentes distribuídas em diferentes estágios sucessionais (inicial, médio e avançado), onde foram derivadas métricas estruturais, incluindo variáveis discretas e simuladas *full waveform* (FWF). A análise exploratória multivariada revelou padrões estruturais distintos entre os estágios, com perfis verticais evoluindo de estruturas simples no estágio inicial para configurações multimodais e estratificadas no estágio avançado. O terceiro capítulo apresentou uma revisão sistemática sobre o uso da tecnologia *Mobile Laser Scanning* (MLS) em inventários florestais, analisando 56 artigos científicos publicados entre 2013 e 2023. Esta revisão documentou a evolução do MLS como ferramenta de alta precisão para coleta de dados florestais, sua crescente integração com algoritmo *Random Forest* e as limitações técnicas em ambientes naturais complexos. No quarto capítulo, foi utilizada uma abordagem de classificação sucessional utilizando sistema portátil de varredura a *laser* móvel (LiBackpack) em 12 parcelas. Por meio dos resultados foram inferidos padrões, identificando vantagens e limitações específicas da plataforma para caracterização estrutural dos estágios sucessionais da FOM. Para classificação dos estágios sucessionais, foi utilizado o algoritmo *Random Forest* e abordagens descritivas das variáveis. As variáveis mais importantes para discriminação sucessional incluíram métricas de altura, complexidade estrutural e penetração do dossel, evidenciando a complementaridade entre diferentes tipos de dados LiDAR. A análise ecológica dos resultados confirmou que as métricas LiDAR capturam efetivamente os processos de desenvolvimento estrutural ao longo da sucessão florestal. As considerações finais integraram os resultados dos estudos com UAV-LiDAR e MLS, discutindo suas implicações práticas para monitoramento florestal e planejamento ambiental. A tese

demonstrou que dados LiDAR, quando analisados por meio de metodologias que integram conhecimento ecológico e técnicas avançadas de aprendizado de máquina, permitem classificação acurada e objetiva de estágios sucessionais em FOM, oferecendo potencial para aplicação em programas de monitoramento, restauração e conservação.

Palavras-chave: UAV-LiDAR, MLA-LiDAR, Sucessão Florestal, *Random Forest*, Análise Multivariada.

ABSTRACT

This thesis investigated the potential of different LiDAR technologies for the classification and characterization of successional stages in remnants of the Mixed Ombrophilous Forest (MOF) in southern Brazil. The study integrated high-resolution remote sensing approaches and ecological analyses to test robust successional classification methodologies, which are essential for the monitoring and management of regenerating forest ecosystems. The research was structured into five complementary chapters: Chapter 1: A literature review established the theoretical foundations of forest succession, vegetation structure, and remote sensing applied to native forests, providing context for the study's problem and justification. Chapter 2: Explored the application of UAV-LiDAR data across 30 permanent plots distributed among different successional stages (initial, intermediate, and advanced). Structural metrics were derived, including discrete variables and simulated Full Waveform (FWF) data. Multivariate exploratory analysis revealed distinct structural patterns, with vertical profiles evolving from simple structures in the initial stage to multimodal and stratified configurations in the advanced stage. Chapter 3: Presented a systematic review of Mobile Laser Scanning (MLS) technology in forest inventories, analyzing 56 scientific articles published between 2013 and 2023. This review documented the evolution of MLS as a high-precision tool for forest data collection, its increasing integration with the Random Forest algorithm, and the technical limitations encountered in complex natural environments. Chapter 4: Utilized a successional classification approach using a handheld mobile laser scanning system (LiBackpack) across 12 plots. The results allowed for the inference of patterns, identifying specific advantages and limitations of the platform for the structural characterization of MOF successional stages. The Random Forest algorithm and descriptive variable approaches were used for classification. The most significant variables for successional discrimination included height metrics, structural complexity, and canopy penetration, highlighting the complementarity between different types of LiDAR data. The ecological analysis confirmed that LiDAR metrics effectively capture structural development processes throughout forest succession. The final considerations integrated the results from the UAV-LiDAR and MLS studies, discussing their practical implications for forest monitoring and environmental planning. This thesis demonstrated that LiDAR data—when analyzed through methodologies integrating ecological knowledge and advanced machine learning techniques—allows for the accurate and objective

classification of successional stages in the Mixed Ombrophilous Forest, offering significant potential for application in monitoring, restoration, and conservation programs.

Keywords: UAV-LiDAR, MLA-LiDAR, Forest Succession, Random Forest, Multivariate Analysis.

LISTA DE FIGURAS

- Figura 1. Mapa de localização da área de estudo e das parcelas.
- Figura 2. DJI Matrice 300 utilizado para a presente pesquisa.
- Figura 3. Sensor LiAir V utilizado no voo.
- Figura 4. Dados discretos x Dados FWF Simulados.
- Figura 5. Scree plot da PCA.
- Figura 6. Gráfico do tipo *biplot* da PCA.
- Figura 7. Dendrograma da Classificação Hierárquica Ascendente (CHA)
- Figura 8. *Boxplots* das variáveis estruturais por cluster.
- Figura 9. Distribuições (violin/box) de z_{max} e z_{mean} por estágio sucessional (discreto).
- Figura 10. Distribuições (violin/box) de LAD_{mean} e zsd por estágio (discreto).
- Figura 11. Distribuições (violin/box) de percentis z_q por estágio (discreto).
- Figura 12. Distribuições (violin/box) de z_{skew} e z_{kurt} por estágio (discreto).
- Figura 13. Distribuições (violin/box) de métricas FWF simuladas por estágio.
- Figura 14. Distribuições (violin/box) de métricas FWF simuladas por estágio.
- Figura 15. Violin plots dos percentis rh_{Gauss} com letras de pós-teste.
- Figura 16. Violin plots dos percentis rh_{Gauss} com letras de pós-teste.
- Figura 17. Gráfico de violino das variáveis LiDAR FWF Simulados.
- Figura 18. Gráfico *Biplot* da análise de componentes principais dos Dados Discretos.
- Figura 19. Gráfico *Biplot* da análise de componentes principais dos FWF Simulados.
- Figura 20. Gráfico *Biplot* da análise de componentes principais dos Dados Integrados.
- Figura 21. Gráfico *Biplot* da análise NMDS dos Dados Discretos.
- Figura 22. Gráfico *Biplot* da análise NMDS dos Dados FWF Simulados.
- Figura 23. Gráfico *Biplot* da análise NMDS dos Dados Integrados.
- Figura 24. Perfil vertical das parcelas – Estágio Inicial.
- Figura 25. Perfil vertical das parcelas – Estágio Médio.
- Figura 26. Perfil vertical das parcelas – Estágio Avançado.
- Figura 27. Importância relativa das variáveis LiDAR para classificação.
- Figura 28. Métricas de desempenho do *Random Forest* por estágio.
- Figura 29. Matriz de confusão do Random Forest.
- Figura 30. Limiares estruturais entre estágios sucessionais.
- Figura 31. Frequência de artigos publicados anualmente sobre o uso da tecnologia MLS em aplicações florestais.
- Figura 32. Número de publicações sobre o uso da tecnologia MLS em aplicações florestais, de 2013 a 2023.

Figura 33. *Wordcloud* com base nas palavras-chave utilizadas pelos autores das publicações científicas selecionadas na pesquisa bibliográfica sobre o uso do MLS em aplicações florestais.

Figura 34. Países onde as pesquisas foram desenvolvidas com o uso do MLS no contexto florestal, de 2013 a 2023 e incluídos no presente trabalho.

Figura 35. Mapa de localização da área de estudo e das parcelas utilizadas nesta fase.

Figura 36. Método de caminhamento para obtenção de dados LiDAR utilizando a *BackPack*.

Figura 37. Representação da LiBackPack utilizada no estudo.

Figura 38. Dados discretos x Dados FWF Simulados.

Figura 39. Gráfico de violino de z_{max} , z_{mean} e z_{sd} .

Figura 40. Gráfico de violino de z_{skew} , z_{kurt} e $z_{entropy}$.

Figura 41. Gráfico de violino de $p_{zabovezmean}$, $p_{zabove2}$ e z_{q20} .

Figura 42. Gráfico de violino de z_{q50} , z_{q75} e z_{q95} .

Figura 43. Gráfico de violino de p_{ground} .

Figura 44. Gráfico de violino de g_{Height} .

Figura 45. Gráfico de violino de $signal.top$ e $signal.bottom$.

Figura 46. Gráfico de violino de $trailing.edge.extent$.

Figura 47. Gráfico de violino de $rhGauss 50$.

Figura 48. Gráfico de violino de $rhGauss 95$.

Figura 49. Gráfico de violino de FHD.

Figura 50. Gráfico de violino de FHDcanGauss.

Figura 51. Biplot PCA dados Discretos.

Figura 52. Biplot PCA dados FWF simulados.

Figura 53. Biplot PCA dados Integrados.

Figura 54. Biplots NMDS dados MLS.

Figura 55. Gráfico de estrutura vertical dos estágios iniciais.

Figura 56. Gráfico de estrutura vertical dos estágios médios.

Figura 57. Gráfico de estrutura vertical dos estágios avançados.

Figura 58. Desempenho de métricas por método.

Figura 59. Importância das variáveis (FWF simulado).

Figura 60. Importância das variáveis (dados discretos).

Figura 61. Importância das variáveis (dados combinados).

LISTA DE TABELAS

Tabela 1. Variáveis dendrométricas do inventário florestal tradicional e calculadas para cada uma das 30 parcelas amostradas.

Tabela 2. Valores Mínimos, médios e máximos de variáveis chave.

Tabela 3. Número de artigos sobre MLS em contexto florestal em função dos locais de estudo.

SUMÁRIO

ESTRUTURA DA TESE.....	23
1. ASPECTOS GERAIS DA PESQUISA.....	25
1.1. INTRODUÇÃO GERAL.....	25
1.2. HIPÓTESE.....	27
1.3. OBJETIVOS.....	27
1.3.1. Objetivo Geral.....	27
1.3.2. Objetivos Específicos.....	27
2. CAPÍTULO I – REVISÃO DE LITERATURA.....	28
2.1. A FLORESTA OMBRÓFILA MISTA: ECOLOGIA E IMPORTÂNCIA.....	28
2.2. DINÂMICA SUCESSIONAL EM FLORESTAS.....	28
2.3. SENSORIAMENTO REMOTO NO MONITORAMENTO FLORESTAL.....	30
2.4. TECNOLOGIAS LIDAR: FUNDAMENTOS, DADOS DISCRETO E <i>DADOS FULL-WAVEFORM</i>	32
2.4.1. Dados Discretos.....	32
2.4.2. Dados <i>Full-Waveform</i>	33
2.4.2.1. Dados <i>Full-Waveform</i> Simulados e Não-Simulados.....	34
2.5. <i>MOBILE LASER SCANNING</i> (MLS) E UAV-LIDAR: FUNDAMENTOS E APLICAÇÕES EM FLORESTAS NATIVAS.....	35
2.5.1. <i>Mobile Laser Scanning</i> (MLS).....	35
2.5.2. UAV-LIDAR.....	36
2.6. APLICAÇÕES DE <i>MACHINE LEARNING</i> EM SUCESSÃO FLORESTAL.....	37
2.7. DESAFIOS E PERSPECTIVAS FUTURAS NO USO DE LIDAR PARA AVALIAÇÃO SUCESSIONAL.....	38
3. CAPÍTULO II - CLASSIFICAÇÃO SUCESSIONAL EM FLORESTA FRAGMENTOS DA OMBRÓFILA MISTA (FOM) USANDO UAV-LIDAR.....	40
3.1. INTRODUÇÃO.....	40
3.2. MATERIAIS E MÉTODOS.....	42
3.2.1. Caracterização da Área de Estudo.....	42
3.2.2. Levantamento dos Dados de Campo.....	43
3.2.2.1. Cálculo de Variáveis Oriundas do Inventário Florestal.....	44
3.2.2.1.1. Área Basal (m ² /ha) (G).....	44
3.2.2.1.2. Altura Média (ht).....	45
3.2.2.1.3. Diâmetro Médio (dap).....	45

3.2.2.1.4.	Diâmetro Quadrático Médio (<i>dqm</i>).....	45
3.2.2.1.5.	Variância das Alturas (<i>htvar</i>)	46
3.2.2.1.6.	Desvio Padrão das Alturas (<i>htsd</i>).....	46
3.2.2.1.7.	Altura Dominante (<i>htdom</i>).....	47
3.2.2.1.8.	Percentil 90 (P90)	47
3.2.2.1.9.	Altura Mediana (<i>htmed</i>)	48
3.2.2.1.10.	Altura Máxima (<i>htmax</i>)	48
3.2.2.1.11.	Percentil 95 (P95)	48
3.2.2.1.12.	Percentil 25 (P25)	49
3.2.2.1.13.	Altura Média Ponderada com Área Basal (<i>htmab</i>).....	49
3.2.2.1.14.	Quantificação de Árvores.....	49
3.2.2.1.15.	Coeficiente de Variação de Diâmetro (<i>dapcv</i>).....	50
3.2.2.1.16.	Coeficiente de Variação da Altura (<i>htcv</i>).....	50
3.2.2.1.17.	Estratificação Diagrama <i>h-M</i> (SANQUETTA, 1995).....	51
3.2.2.1.18.	Índice de Uniformidade (IU).....	51
3.2.2.1.19.	Índice de Diversidade de Shannon (H').....	52
3.2.2.1.20.	Índice de Equitabilidade de Pielou (J').....	52
3.2.2.1.21.	Índice de Sucessão Florística (ISF).....	53
3.2.3.	Classificação em Estágios Sucessionais e Análise Descritiva das Variáveis com Base nos Dados de Inventário Florestal Tradicional.....	53
3.2.4.	Obtenção de Dados LiDAR.....	54
3.2.4.1.	Parâmetros de Voo e Especificações Técnicas.....	54
3.2.4.2.	Processamento da Nuvem LiDAR.....	55
3.2.4.3.	Métricas Extraídas da Nuvem com o Pacote <i>lidR</i>	56
3.2.4.3.1.	Índice de Diversidade Vertical (VDI).....	57
3.2.4.3.2.	Índice de Estratificação (SI).....	58
3.2.4.3.3.	Densidade de Área Foliar (<i>LEAF AREA DENSITY - LAD</i>), Índice de Área Foliar (<i>LEAF AREA INDEX - LAI</i>).....	59
3.2.4.3.4.	Métricas de Diversidade (SHANNON, PIELOU).....	60
3.2.4.3.5.	Métricas de Dossel.....	61
3.2.4.4.	Simulação de Dados <i>Full-Waveform</i> a Partir de UAV-LiDAR.....	62
3.2.4.5.	Análise Gráfica e Espacial da Estrutura Vertical (Voxelização e Curvas de Perfil)	64

3.2.5.	Estruturação das Matrizes Preditoras e Consolidação do Banco de Dados.....	64
3.2.6.	Análise Exploratória e Estatística Multivariada.....	65
3.2.6.1.	Caracterização Estrutural e Pressupostos Estatísticos.....	65
3.2.6.2.	Análise de Redundância e Seleção de Métricas.....	66
3.2.6.3.	Ordenação e Separabilidade dos Estágios Sucessionais.....	66
3.2.6.4.	Modelagem Preditiva e Classificação Automatizada.....	66
3.2.6.4.1.	Treinamento e Otimização do Algoritmo.....	67
3.2.6.4.2.	Avaliação de Desempenho e Importância de Variáveis.....	67
3.3.	RESULTADOS.....	68
3.3.1.	Características da Vegetação com base no Inventário Florestal.....	68
3.3.2.	Variáveis Dendrométricas Calculadas.....	69
3.3.3.	Aplicação da PCA e Identificação dos Componentes Principais Para as Variáveis Dendrométricas.....	72
3.3.3.1.	Validação Estatística dos Agrupamentos.....	76
3.3.4.	Comparação com Parâmetros da Resolução CONAMA 02/1994.....	80
3.3.5.	Caracterização Estrutural dos Estágios Sucessionais com Variáveis LiDAR...82	
3.3.5.1.	Estatísticas Descritivas e Distribuição das Variáveis.....	82
3.3.5.1.1.	Variáveis discretas.....	82
3.3.5.1.2.	Variáveis <i>Full-Waveform</i> simuladas.....	86
3.3.6.	Análise de Relações Entre Variáveis LiDAR.....	89
3.3.6.1.	Análise de Relações Entre Variáveis de Dados Discretos.....	89
3.3.6.2.	Correlações Entre Variáveis FWF Simulados.....	90
3.3.7.	Padrões Multivariados e Gradientes Ecológicos.....	90
3.3.7.1.	Análise de Componentes Principais.....	90
3.3.7.1.1.	Análise de Componentes Principais – Dados Discretos.....	90
3.3.7.1.2.	Análise de Componentes Principais – Dados <i>Full-WaveForm</i> simulados.....	91
3.3.7.1.3.	Análise de Componentes Principais – Dados Integrados.....	92
3.3.7.2.	Escalonamento Multidimensional Não-Métrico (NMDS).....	93
3.3.7.3.	Análise Multivariada de Variância (PERMANOVA).....	95
3.3.7.4.	Perfis Verticais e Distribuição dos Retornos.....	95
3.3.8.	Modelagem e Classificação de Estágios Sucessionais.....	101
3.3.8.1.	Seleção de Variáveis e Pré-Processamento.....	101
3.3.8.2.	Otimização de Hiperparâmetros do <i>Random Forest</i>	103

3.3.8.3.	Avaliação de Desempenho.....	103
3.3.8.4.	Importância das Variáveis Para Classificação.....	105
3.3.8.5.	Análise de Sensibilidade e Parcimônia do Modelo.....	105
3.4.	DISCUSSÕES.....	107
3.5.	CONCLUSÃO.....	111
4.	CAPÍTULO III - ESTADO DA ARTE DO LIDAR MLS EM APLICAÇÕES FLORESTAIS.....	112
4.1.	INTRODUÇÃO.....	112
4.2.	MATERIAL E MÉTODOS.....	114
4.2.1.	Pesquisa Bibliográfica.....	114
4.2.2.	Análise do Levantamento Bibliográfico.....	114
4.3.	RESULTADOS.....	115
4.3.1.	Resultado da Pesquisa Bibliográfica.....	115
4.3.2.	Análise de Publicações Científicas.....	115
4.4.	DISCUSSÃO.....	119
4.4.1.	Aplicações Florestais do MLS: Eficiência, Precisão e Comparações Com Outras Tecnologias.....	119
4.4.2.	MLS Integrado a Tecnologias Complementares: UAV, GNSS, SLAM e Inteligência Artificial.....	123
4.4.3.	Detecção E Segmentação Automática De Árvores Com MLS.....	124
4.4.4.	Estimativas De Atributos Dendrométricos Com MLS: DAP, Altura, Volume e Estrutura.....	126
4.4.5.	Aplicações do MLS em Ambientes Urbanos, Ecossistemas Naturais e Análises Ambientais.....	127
4.5.	CONCLUSÕES.....	130
5.	CAPÍTULO IV - CLASSIFICAÇÃO SUCESSIONAL EM FLORESTA OMBRÓFILA MISTA (FOM): UM ENFOQUE NO USO DO <i>MOBILE BACKPACK LIDAR (MLS)</i>.....	131
5.1.	INTRODUÇÃO.....	131
5.2.	MATERIAIS E MÉTODOS.....	133
5.2.1.	Caracterização da Área de Estudo.....	133
5.2.2.	Levantamento dos Dados de Campo.....	134
5.2.3.	Obtenção de Dados <i>Mobile Backpack</i> LiDAR (MLS).....	136
5.2.3.1.	Especificações Do Sensor LiDAR MLS.....	136

5.2.3.2.	Coleta da Nuvem de Pontos com <i>LiBackPack</i>	137
5.2.4.	Processamento da Nuvem LiDAR.....	138
5.2.4.1.	Processamento da Nuvem LiDAR.....	138
5.2.4.2.	Métricas Extraídas da Nuvem com o Pacote <i>lidR</i>	139
5.2.4.3.	Simulação de Dados <i>Full-Waveform</i> a Partir de UAV-LiDAR.....	140
5.2.4.4.	Análise Gráfica e Espacial da Estrutura Vertical (Voxelização e Curvas de Perfil).....	142
5.2.5.	Estruturação das Matrizes Predictoras e Consolidação do Banco de Dados	142
5.2.6.	Análise Exploratória e Estatística Multivariada.....	143
5.2.6.1.	Caracterização Estrutural e Pressupostos Estatísticos.....	143
5.2.6.2.	Análise de Redundância e Seleção de Métricas.....	144
5.2.6.3.	Ordenação e Separabilidade dos Estágios Sucessionais.....	144
5.2.6.4.	Análise Preditiva e Classificação Automatizada.....	144
5.3.	RESULTADOS.....	146
5.3.1.	Caracterização Estrutural dos Estágios Sucessionais com Variáveis LiDAR.	146
5.3.1.1.	Estatísticas Descritivas e Distribuição das Variáveis.....	146
5.3.1.2.	Análise de Relações Entre Variáveis LiDAR.....	156
5.3.1.3.	Dados Discretos.....	156
5.3.1.4.	Dados <i>FWF Simulados</i>	156
5.3.2.	Padrões Multivariados e Gradientes Ecológicos.....	157
5.3.2.1.	Análise de Componentes Principais.....	157
5.3.2.1.1.	Dados Discretos.....	157
5.3.2.1.2.	Dados <i>Full-Waveform Simulados</i>	158
5.3.2.1.3.	Dados Integrados.....	159
5.3.2.2.	Escalonamento Multidimensional Não-Métrico (NMDS).....	160
5.3.2.3.	Análise Multivariada de Variância (PERMANOVA).....	162
5.3.3.	Significância Estatística das Variáveis LiDAR.....	163
5.3.4.	Análise Tridimensional da Estrutura Vertical e Perfis de Retorno LiDAR.....	164
5.3.4.1.	Estágios Iniciais (Parcelas 2, 3, 7, 9).....	164
5.3.4.2.	Estágios Médios (Parcelas 8, 24, 25, 26).....	166
5.3.4.3.	Estágios Avançados (Parcelas 23, 27, 28).....	169
5.3.5.	Modelagem Preditiva Com <i>Random Forest</i>	171
5.3.6.	Desempenho Comparativo Entre Abordagens.....	171
5.3.7.	Análise Da Importância Das Variáveis.....	172

5.4.	DISCUSSÕES.....	175
5.5.	CONCLUSÃO.....	179
6.	CAPÍTULO V - CONSIDERAÇÕES FINAIS E PERSPECTIVAS.....	180
6.1.	COMPLEMENTARIDADE ENTRE MLS E UAV-LIDAR NA CLASSIFICAÇÃO SUCESSIONAL.....	180
6.2.	IMPLICAÇÕES PARA O APRIMORAMENTO DA RESOLUÇÃO CONAMA	181
6.3.	LIMITAÇÕES ENFRENTADAS E DESAFIOS METODOLÓGICOS.....	182
6.4.	PERSPECTIVAS FUTURAS E APLICAÇÕES PRÁTICAS.....	183
7.	REFERÊNCIAS BIBLIOGRÁFICAS.....	185

ESTRUTURA DA TESE

Esta tese está organizada em cinco capítulos, cada um delineando uma etapa essencial do desenvolvimento científico da pesquisa, conforme segue:

- **Capítulo I - Revisão de Literatura:** Apresenta os fundamentos teóricos e contextuais que norteiam a investigação, abordando os principais conceitos relacionados à sucessão florestal, estrutura da vegetação e avanços em sensoriamento remoto aplicado a florestas nativas. Também introduz a problemática, os objetivos e a justificativa do estudo, consolidando o embasamento científico para os capítulos subsequentes.
- **Capítulo II - Classificação sucessional em Floresta Ombrófila Mista (FOM) usando UAV-LiDAR: análise estrutural e dinâmica de vegetação:** Explora e detalha a aplicação de dados LiDAR obtidos por UAV para estimar os estágios sucessionais da FOM. A partir da nuvem de pontos LiDAR, foram extraídas métricas estruturais discretas e simuladas de retorno completo (*Full-Waveform*), por meio dos pacotes *lidR* e *GEDIsimulator* do *software* R. As análises incluíram estatística descritiva, correlações, métodos multivariados e modelos *Random Forest* com validação *k-fold*.
- **Capítulo III - Estado da arte do LiDAR MLS em aplicações florestais:** Consiste em uma revisão sistemática da literatura sobre o uso da tecnologia MLS em inventários florestais entre 2013 e 2023. Foram analisados 56 artigos científicos, abrangendo sensores, regiões de estudo, metodologias e aplicações. O capítulo discute a evolução do MLS como ferramenta de alta precisão para coleta de dados florestais, suas integrações com algoritmos de *machine learning*, e as limitações técnicas em ambientes naturais complexos. A revisão fornece uma visão abrangente e atualizada do papel do MLS na transformação da coleta de dados em ecossistemas florestais.
- **Capítulo IV - Classificação sucessional em floresta ombrófila mista (FOM): um enfoque no uso do *Mobile BackPack* LiDAR (MLS):** Apresenta uma abordagem inovadora de classificação dos estágios sucessionais da FOM utilizando dados obtidos por sistema portátil de varredura a *laser* móvel (LiBackpack). Foram analisadas 12

parcelas com classificação de campo prévia, nas quais foram extraídas métricas estruturais detalhadas, tanto discretas quanto simuladas como *Full- Waveform* simulados.

- **Capítulo V - Considerações finais e perspectivas:** Este capítulo apresenta as conclusões gerais do trabalho, destacando os principais achados científicos obtidos ao longo dos estudos com UAV-LiDAR e MLS. São discutidas comparações diretas entre as metodologias empregadas, suas vantagens e limitações, bem como as implicações práticas para o monitoramento florestal e planejamento ambiental. Também foram exploradas as perspectivas de uso e escalabilidade dessas tecnologias em iniciativas de restauração, licenciamento e conservação da Mata Atlântica.

1. ASPECTOS GERAIS DA PESQUISA

1.1. INTRODUÇÃO GERAL

Os ecossistemas florestais ocupam cerca de 4,06 bilhões de hectares, cobrindo aproximadamente 31% da superfície terrestre global (FAO, 2020). Deste total, 93% correspondem a formações nativas em regeneração natural, enquanto apenas 7% são áreas plantadas, destacando a predominância dos ecossistemas naturais na cobertura florestal do planeta. Dentre esses ecossistemas, a Floresta Ombrófila Mista (FOM), inserida no bioma Mata Atlântica, configura-se como uma das mais ameaçadas, tendo sofrido intensos processos de fragmentação e degradação ao longo dos últimos séculos (OLIVEIRA-FILHO et al., 2007; HIGUCHI et al., 2012).

A fragmentação florestal, impulsionada majoritariamente pela conversão de uso do solo para fins agropecuários e urbanos, resultou em um mosaico heterogêneo de remanescentes com distintos tamanhos, formatos e estágios sucessionais (NEGRINI et al., 2014). Tal processo comprometeu não apenas a continuidade espacial da vegetação, mas também sua composição florística, estrutura vertical e dinâmica ecológica. Diante desse cenário, a gestão e o monitoramento de ecossistemas nativos tornaram-se desafiadores, especialmente frente às mudanças climáticas globais e ao avanço do desmatamento (JONES et al., 2021). Entre os impactos observados, destacam-se a perda de biodiversidade, a alteração dos ciclos hidrológicos e climáticos, e a redução de serviços ecossistêmicos essenciais (FERREIRA et al., 2018).

A classificação precisa dos estágios sucessionais dos fragmentos florestais é essencial para o planejamento de ações eficazes de conservação e restauração, promovendo o uso sustentável dessas áreas. Conforme estabelece a Lei da Mata Atlântica (Lei Federal nº 11.428/2006), em processos de licenciamento ambiental, o procedimento de compensação ambiental e manutenção florestal deve ser feito em áreas com o mesmo estágio sucessional ou em estágios mais avançados do que aquele afetado. Além disso, essa legislação define que a preservação deve cobrir, no mínimo, 30% da área para florestas em estágio médio e 50% para as em estágio avançado, variando conforme a área esteja situada em zona urbana ou rural, sendo o corte de florestas primárias completamente proibido (BRASIL, 2006).

No estado do Paraná, aplicam-se os critérios da Resolução CONAMA nº

002/1994 (CONAMA, 1994), para classificar os estágios sucessionais para florestas secundárias em diferentes fitofisionomias, como número de estratos, número de espécies lenhosas, altura média, distribuição diamétrica, epífitas, sub-bosque, entre outros. No entanto, sua abordagem generalista pode não refletir adequadamente a complexidade ecológica dos ecossistemas locais.

Pastório, Gasper e Vibrans (2020) demonstram que os parâmetros definidos pela Resolução CONAMA 04/1994, feita para Santa Catarina, mas semelhante à do Paraná, não garantem uma classificação consistente, pois combinam critérios qualitativos subjetivos e valores-limite arbitrários, resultando em ambiguidades entre os estágios. Os autores evidenciam que a caracterização sucessional exige variáveis estruturais e ecológicas mais informativas, como: densidade, diversidade e proporção de pioneiras, além de métodos analíticos objetivos, como a análise discriminante linear, capazes de reduzir conflitos e melhorar a precisão da classificação.

É clara a necessidade de inclusão de outras variáveis, como diversidade genética, interações ecológicas, resiliência a distúrbios, heterogeneidade espacial e temporal, além de fatores climáticos e topográficos. Tais variáveis são fundamentais para oferecer uma avaliação mais completa e precisa, contribuindo significativamente para a conservação e o manejo eficaz dos ecossistemas florestais. Esse panorama evidencia a urgência por ferramentas tecnológicas que viabilizem diagnósticos precisos sobre a estrutura e a dinâmica das florestas. Nesse contexto, o sensoriamento por *Light Detection and Ranging* (LiDAR) emergiu como uma solução inovadora, fornecendo dados tridimensionais de alta resolução da vegetação (ILANGAKOON et al., 2021).

O LiDAR tem sido amplamente utilizado para estimar biomassa acima do solo (Asner et al., 2010), caracterizar a estrutura vertical do dossel, monitorar mudanças no uso e cobertura da terra Vatandaşlar et al., (2023), e avaliar os impactos de distúrbios ambientais (SCHEERES et al., 2023). Sua capacidade de capturar com precisão a complexidade estrutural das florestas permitiu avanços expressivos na compreensão dos processos sucessionais e na quantificação de serviços ecossistêmicos.

A integração entre ecossistemas nativos e tecnologias avançadas de sensoriamento remoto, como o LiDAR, representa uma abordagem promissora para ampliar o entendimento sobre a funcionalidade e integridade estrutural das florestas.

Nesta perspectiva, o presente estudo teve como objetivo avaliar a aplicabilidade métricas obtidas a partir de dados LiDAR, adquiridos por plataformas aérea e móvel, na classificação dos estágios sucessionais da Floresta Ombrófila Mista (FOM), por meio de análises tridimensionais da vegetação e algoritmos de aprendizado de máquina. Objetivou-se, com isso, contribuir para o desenvolvimento de metodologias inovadoras que subsidiem estratégias mais eficazes de conservação, manejo e recuperação de florestas subtropicais fragmentadas.

1.2. HIPÓTESE

A hipótese principal desta tese é de que métricas estruturais obtidas por sensores LiDAR embarcados em plataformas aéreas (UAV-LiDAR) e móveis (*Mobile LiDAR* – MLS) permitem distinguir com precisão os estágios sucessionais em fragmentos florestais na região da Floresta Ombrófila Mista por meio de indicadores extraídos das nuvens de pontos.

1.3. OBJETIVOS

1.3.1. Objetivo Geral

Explorar e avaliar a aplicabilidade de dados estruturais obtidos por sensores LiDAR embarcados em plataformas aéreas (UAV-LiDAR) e móveis (*Mobile LiDAR* – MLS) na classificação dos estágios sucessionais da Floresta Ombrófila Mista, tomando-se como base as métricas extraídas das nuvens de pontos e aplicando-se algoritmos de aprendizado de máquina.

1.3.2. Objetivos Específicos

- a) Explorar e testar o desempenho das métricas UAV-LiDAR para classificar os estágios sucessionais em fragmentos florestais de Floresta Ombrófila Mista.
- b) Realizar uma revisão sistemática da literatura científica sobre o uso de *Mobile Laser Scanning* (MLS) em inventários florestais, destacando avanços, limitações e tendências metodológicas.
- c) Explorar e testar o desempenho das métricas MLS para classificar os estágios sucessionais em fragmentos florestais de Floresta Ombrófila Mista.
- d) Avaliar a capacidade discriminativa dessas métricas estruturais, tanto do UAV-LiDAR quanto do MLS na classificação dos estágios sucessionais da FOM.

2. CAPÍTULO I – REVISÃO DE LITERATURA

2.1. A FLORESTA OMBRÓFILA MISTA: ECOLOGIA E IMPORTÂNCIA

A Floresta Ombrófila Mista (FOM) é uma formação florestal de grande importância ecológica e socioeconômica dentro do bioma Mata Atlântica, apresentando uma composição florística diversificada, composta por espécies latifoliadas e coníferas como a *Araucaria angustifolia* (SCHAAF et al., 2006; SILVA, GANADE e BACKES, 2010). Sua principal ocorrência está em regiões de clima subtropical úmido, com precipitações anuais superiores a 1200 mm e temperaturas médias variando entre 13 °C e 18 °C, sendo condicionado por solos férteis e relevo ondulado a montanhoso (SANQUETTA, 2017).

Com o passar do tempo, a FOM sofreu intensa exploração madeireira, associada ao alto valor econômico da madeira de Araucária e de outras espécies como *Ocotea porosa* (Nees) Mez e *Cedrela fissilis* Vell. Esse histórico de uso, somado à expansão agropecuária e urbana, resultou na fragmentação severa dos remanescentes florestais, restando atualmente menos de 3% da cobertura original em condições de conservação (FERREIRA et al., 2017). Esta realidade impulsionou a implementação de políticas públicas específicas, como a Lei da Mata Atlântica (Lei nº 11.428/2006) e a Resolução CONAMA nº 002/1994, que regulamentam a proteção e o uso sustentável dos remanescentes, mediante a categorização dos estágios sucessionais da vegetação.

A avaliação dos estágios sucessionais tornou-se, assim, requisito fundamental para a gestão ambiental e para a definição de práticas de restauração ecológica. Na Mata Atlântica, a identificação precisa dos estágios de regeneração é particularmente desafiadora, em função da elevada diversidade estrutural e da sobreposição de características entre os diferentes estágios, exigindo o emprego de metodologias que integrem alta acurácia e representatividade espacial (MAGURRAN, 2004; ARAÚJO, 2019).

2.2. DINÂMICA SUCESSIONAL EM FLORESTAS

A sucessão ecológica refere-se às alterações temporais na composição e estrutura das comunidades vegetais, em resposta a distúrbios naturais ou antrópicos,

culminando na formação de estágios florestais de crescente complexidade (CONNELL & SLATYER, 1977; PICKETT, COLLINS & ARMESTO, 1987). Em geral, esse processo é governado por interações entre fatores bióticos e abióticos, incluindo disponibilidade de luz, competição por recursos, características edáficas e regimes de distúrbio (CHAZDON, 2008).

Os estágios sucessionais são tradicionalmente classificados em três categorias: inicial, médio e avançado. No estágio inicial, predominam espécies pioneiras de rápido crescimento e alta demanda luminosa, enquanto os estágios médios e avançados apresentam, progressivamente, maior diversidade de espécies, estratificação vertical definida e aumento da biomassa acima do solo (MAGURRAN, 2004; SILVA, GANADE & BACKES, 2010). Características estruturais como altura média do dossel, densidade do sub-bosque e complexidade da copa tornam-se indicadores-chave para diferenciar os estágios de sucessão (CHAZDON, 2003).

No contexto brasileiro, a compreensão e a correta identificação desses estágios não se restringem ao âmbito da ecologia teórica, mas assumem um papel fundamental na formulação e aplicação de políticas públicas de conservação e restauração. A legislação ambiental nacional, exemplificada pela Lei nº 12.651/2012 (Código Florestal) e pela Lei nº 6.938/1981 (Política Nacional de Meio Ambiente), estabelece as bases para a proteção da vegetação nativa, delineando a importância de sua regeneração e sucessão.

Adicionalmente, a Lei 11.428 (Mata Atlântica) e o Decreto nº 6.660/2008, que regulamenta a Lei da Mata Atlântica, reforça a necessidade da categorização dos estágios sucessionais para orientar o uso e manejo sustentável, bem como a autorização de intervenções em áreas de floresta nativa. A relevância dessa classificação é ainda mais acentuada no Estado do Paraná, área objeto deste estudo, onde a Resolução CONAMA nº 002/1994 desempenha um papel crucial. Esta resolução estabelece critérios específicos para a definição das formações vegetais primárias e, principalmente, para a caracterização dos estágios sucessionais da vegetação secundária.

Ela detalha as características estruturais e florísticas que devem ser consideradas para enquadrar uma área em estágio inicial, médio ou avançado de regeneração, influenciando diretamente as práticas de licenciamento ambiental,

compensação ambiental e recuperação de áreas degradadas no estado (CONAMA, 1994). A precisão nessa categorização é, portanto, vital para o cumprimento da legislação e para a eficácia das ações de manejo e conservação, impactando decisões sobre desmatamento, uso alternativo do solo e atividades de baixo impacto (CONAMA, 1994).

Para além da conformidade legal, a identificação acurada dos estágios sucessionais serve como um indicador-chave da saúde ecológica dos ecossistemas. Ela permite a avaliação da capacidade de resiliência de uma floresta após distúrbios, auxiliando na compreensão dos processos de colonização e competição que moldam a estrutura e composição vegetal (VATANDAŞLAR et al., 2023). Ademais, a classificação detalhada contribui para o monitoramento de metas de restauração e para o embasamento de estratégias de manejo que visam a recuperação da biodiversidade e dos serviços ecossistêmicos, tornando-se uma ferramenta indispensável tanto para a pesquisa científica quanto para a gestão ambiental prática.

Entretanto, a variabilidade natural das florestas tropicais e subtropicais e a influência de fatores locais, como a fertilidade do solo e o histórico de uso da terra, podem gerar padrões sucessionais não lineares, dificultando a aplicação de critérios uniformes para a classificação dos estágios (VATANDAŞLAR et al., 2023). Essa complexidade ecológica, aliada à imperativa necessidade de embasamento técnico robusto para o cumprimento da legislação ambiental e para um manejo florestal eficaz, impulsiona a busca por tecnologias avançadas, como o LiDAR. Tais tecnologias são capazes de fornecer descritores tridimensionais detalhados da estrutura florestal, representando uma alternativa promissora para a avaliação objetiva e precisa dos processos sucessionais.

2.3. SENSORIAMENTO REMOTO NO MONITORAMENTO FLORESTAL

O avanço das tecnologias de sensoriamento remoto transformou profundamente a maneira como os ecossistemas florestais são monitorados, permitindo a obtenção de dados em grande escala, com alta precisão e resolução espacial (ASNER et al., 2012). Tradicionalmente, sensores ópticos têm sido amplamente utilizados, fornecendo informações valiosas sobre a reflectância da vegetação.

Contudo, suas limitações são evidentes em ambientes florestais densos, onde a saturação dos índices de vegetação e a incapacidade de penetrar o dossel superior impedem a captura da estrutura vertical interna, um atributo crucial para o entendimento da dinâmica sucessional (GAIDA et al., 2016).

Em busca de superar essas barreiras, os sensores de radar de abertura sintética (SAR) emergiram, oferecendo a capacidade de penetração do dossel e resistência a condições atmosféricas adversas. Embora representem um avanço, a resolução e a capacidade do SAR de caracterizar os detalhes finos da estrutura tridimensional da floresta para fins de classificação sucessional ainda permanecem restritas em comparação com outras tecnologias (VATANDAŞLAR et al., 2023).

Para uma análise detalhada dos complexos atributos estruturais que definem os diferentes estágios de regeneração, como a estratificação vertical e a densidade do sub-bosque, tanto os sensores ópticos quanto o SAR demonstram insuficiência, destacando a necessidade de abordagens mais robustas (MONTEIRO, 2018; MATUNAGA, 2022).

Nesse cenário, os sensores LiDAR (*Light Detection and Ranging*) surgiram como uma tecnologia de sensoriamento remoto eficaz para capturar a complexidade estrutural das florestas tropicais e subtropicais. Diferentemente dos métodos passivos, o LiDAR é um sistema ativo que emite pulsos de *laser* e mede o tempo de retorno, permitindo a medição direta e tridimensional de atributos como a altura da vegetação, a densidade do dossel, a rugosidade da superfície e até mesmo a estrutura do sub-bosque com alta acurácia (NÆSSET, 2007; ILANGAKOON et al., 2022).

Essa capacidade de mapear o perfil vertical da vegetação e o terreno subjacente confere ao LiDAR uma vantagem singular para a caracterização estrutural de florestas, superando as limitações impostas pela saturação em biomassa e pela falta de informação sobre a arquitetura interna (LEFSKY et al., 2002).

As aplicações recentes do LiDAR, embarcado em diversas plataformas: aéreas (LiDAR aerotransportado), orbitais (como o GEDI) e móveis (como o MLS), têm demonstrado um elevado potencial. Permitem o mapeamento preciso da biomassa acima do solo, a caracterização detalhada da diversidade estrutural e a classificação eficaz de estágios sucessionais, oferecendo uma abordagem não destrutiva e altamente eficiente em comparação com métodos tradicionais de campo (COSTA,

2020; BILL NETO, 2022; SCHEERES et al., 2023). Sua utilidade se estende desde o monitoramento do crescimento arbóreo em fragmentos florestais até o controle de vegetação invasora em plantios de restauração, consolidando sua posição como ferramenta indispensável no manejo e conservação florestal (MATUNAGA, 2022).

2.4. TECNOLOGIAS LIDAR: FUNDAMENTOS, DADOS DISCRETO E *DADOS FULL-WAVEFORM*

A tecnologia LiDAR (*Light Detection and Ranging*) representa um avanço significativo no sensoriamento remoto ativo, operando através da emissão de pulsos de luz *laser* e da detecção precisa do tempo que esses pulsos levam para retornar ao sensor após interagir com objetos na superfície terrestre. Esse princípio de "tempo de voo" permite a geração de uma nuvem de pontos tridimensional de alta resolução que representa a estrutura detalhada do ambiente (SILVA et al., 2018; ROUSSEL & AUTY, 2022).

Os sistemas LiDAR para aplicações florestais são distinguidos por diversos fatores, incluindo a plataforma (terrestre, aerotransportada ou espacial), o tamanho da pegada do *laser* (*small-footprint*, tipicamente <1m, ou *large-footprint*, 10-25m de diâmetro) e, crucialmente, a forma de registro do sinal retornado, que se divide principalmente em dados discretos e de forma de onda completa (*Full-Waveform*) (SILVA et al., 2018).

2.4.1. Dados Discretos

Nos sistemas LiDAR de dados discretos (*discrete-return*), o sensor registra um número limitado de retornos individuais (tipicamente 1 a 5, mas podendo chegar a 20) por pulso *laser*. Cada retorno corresponde a um pico de intensidade na energia refletida, representando superfícies distintas como o topo do dossel, estratos intermediários da vegetação ou o solo (MORS DORF et al., 2004; DISNEY et al., 2010).

Este tipo de dado é amplamente utilizado em estudos florestais devido à sua relativa simplicidade de processamento e à capacidade de gerar produtos derivados essenciais, como Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT), a partir dos quais as alturas da vegetação podem ser normalizadas (MALLMANN, 2023).

A partir de nuvens de pontos discretos, uma vasta gama de métricas estruturais

pode ser extraída, fornecendo informações valiosas sobre a arquitetura da floresta. As métricas de altura são fundamentais, incluindo a altura máxima (H_{max}), altura média (H_{mean}) e percentis de altura (e.g., H_{25} , H_{50} , H_{75} , H_{95} , H_{98} , H_{100}), que descrevem a distribuição vertical do dossel e a altura da vegetação (LEFSKY et al., 2002; SILVA et al., 2018).

As métricas de densidade quantificam a distribuição vertical da biomassa, como a cobertura do dossel (*canopy cover*), a fração de lacunas (*gap fraction*) e a densidade de pontos em diferentes estratos de altura, servindo como *proxies* para a densidade foliar e a estratificação vertical. Além disso, métricas de complexidade estrutural, como o desvio padrão das alturas, assimetria (*skewness*) e curtose (*kurtosis*) da distribuição de altura dos pontos, caracterizam a variabilidade e a forma do perfil vertical da floresta (ZIMBLE et al., 2003).

Contudo, apesar de sua eficácia, a abordagem discreta pode subestimar a complexidade vertical completa em florestas densas e multiestratificadas, uma vez que apenas os retornos mais energéticos são registrados, limitando a detecção de detalhes da estrutura interna do dossel (HANCOCK et al., 2019).

2.4.2. Dados *Full-Waveform*

Em contraste com os sistemas discretos, os sistemas LiDAR de forma de onda completa (*Full-Waveform - FW*) registram o perfil contínuo da energia refletida ao longo de todo o percurso do pulso *laser*. Em vez de registrar apenas picos, o FW captura a forma integral do pulso de retorno, que é uma função da distribuição vertical das superfícies dispersoras de energia dentro da pegada do *laser* (HANCOCK et al., 2019; ILANGAKOON et al., 2022). Essa abordagem proporciona uma "assinatura" detalhada da interação do *laser* com a estrutura da vegetação, revelando informações sobre a distribuição vertical da biomassa e dos espaços vazios (NEUENSCHWANDER et al., 2019).

Os dados FW oferecem vantagens significativas sobre os dados discretos para a caracterização detalhada da estrutura florestal. Permitem a identificação precisa da estrutura interna do dossel, das camadas do sub-bosque e até mesmo do terreno sob vegetação densa, atributos essenciais para a compreensão da dinâmica sucessional (FERREIRA et al., 2017). A capacidade de extrair métricas de forma de onda e

métricas de altura relativa contínuas torna o FW particularmente valioso para diferenciar estágios sucessionais.

As métricas de forma de onda incluem o comprimento ou extensão da forma de onda (*waveform extent/height*), que indica a altura da coluna de vegetação; a amplitude e intensidade dos picos, que se relacionam com a densidade e refletividade das superfícies de dispersão; e a largura do pulso de retorno, que pode fornecer *insights* sobre a complexidade vertical do dossel. Outras métricas importantes incluem a assimetria e a curtose da forma de onda, que descrevem a distribuição vertical da biomassa e a presença de lacunas (SILVA et al., 2018).

As métricas de altura relativa (RH), calculadas a partir da energia acumulada da forma de onda (e.g., RH25, RH50, RH75, RH98, RH100), são amplamente utilizadas para caracterizar a distribuição vertical dos elementos do dossel, indicando a altura em que uma certa porcentagem da energia do pulso foi refletida (SILVA et al., 2018). Além disso, métricas derivadas como cobertura do dossel (*gaussHalfCov*, *maxHalfCov*), Índice de Área Foliar (IAF) em diferentes bandas de altura (tLAI0t10, gLAI0t10) e Diversidade de Altura Foliar (FHD) podem ser extraídas, oferecendo uma caracterização ainda mais robusta.

2.4.2.1. Dados *Full-Waveform* Simulados e Não-Simulados

Os dados *Full-Waveform* podem ser classificados em não-simulados e simulados, uma distinção crucial para o contexto deste estudo.

Os dados *Full-Waveform* não-simulados são aqueles diretamente adquiridos por sensores LiDAR que registram a forma de onda completa, como o sensor aerotransportado LVIS (*Land, Vegetation, and Ice Sensor*) e, notavelmente, o sensor GEDI (*Global Ecosystem Dynamics Investigation*), embarcado na Estação Espacial Internacional (SILVA et al., 2018).

O GEDI, lançado em 2018, é um LiDAR espacial de grande pegada (tipicamente 25 m de diâmetro) projetado para fornecer medições globais da estrutura vertical das florestas e da biomassa acima do solo (SILVA et al., 2018; HANCOCK et al., 2019). Seus dados são de grande importância para estudos em larga escala, mas sua resolução espacial e cobertura nem sempre são ideais para análises detalhadas em pequenas áreas.

Em contrapartida, os dados *Full-Waveform* simulados são gerados sinteticamente a partir de nuvens de pontos de alta densidade obtidas por sistemas LiDAR de retorno discreto, como os aerotransportados (ALS) ou embarcados em UAVs (*Unmanned Aerial Vehicles*) (BLAIR & HOFTON, 1999; HANCOCK et al., 2019). A simulação envolve a agregação e processamento desses pontos discretos dentro de uma "pegada" virtual de maior diâmetro, convolvendo-os com uma função que imita o comportamento de um pulso FW real.

Ferramentas como o GEDIsimulator, parte do pacote rGEDI, permitem converter arquivos LAS de ALS em formas de onda simuladas no formato HDF5, possibilitando a extração de métricas semelhantes às do GEDI real.

2.5. MOBILE LASER SCANNING (MLS) E UAV-LiDAR: FUNDAMENTOS E APLICAÇÕES EM FLORESTAS NATIVAS

A aquisição de dados LiDAR de alta resolução em ambientes florestais tem sido revolucionada por plataformas móveis e aerotransportadas não tripuladas. O *Mobile Laser Scanning* (MLS), conhecido como LiDAR móvel, e o UAV-LiDAR (*Unmanned Aerial Vehicle-LiDAR*), ou LiDAR embarcado em *drones*, representam abordagens complementares que permitem a coleta de nuvens de pontos densas e precisas, essenciais para a caracterização estrutural detalhada de ecossistemas complexos.

Ambas as tecnologias integram sensores de varredura a *laser* com sistemas de posicionamento (GNSS) e orientação (IMU), bem como, opcionalmente, câmeras, para gerar representações tridimensionais fidedignas do ambiente (ROUSSEL & AUTY, 2022).

2.5.1. Mobile Laser Scanning (MLS)

O MLS abrange sistemas LiDAR montados em plataformas que se movem sobre ou através do terreno, incluindo mochilas (*Backpack LiDAR*), veículos terrestres ou outros dispositivos móveis. A principal vantagem do MLS reside na sua capacidade de penetração sob o dossel e na sua operação em ambientes com cobertura vegetal densa e topografia irregular, onde sistemas aéreos tradicionais enfrentam limitações significativas (KUKKO et al., 2017; HARTLEY et al., 2022). A proximidade do sensor com o solo e com os elementos do sub-bosque permite a captura de detalhes finos e alta densidade de pontos nas camadas inferiores da floresta.

Em florestas nativas no hemisfério norte, o MLS tem sido uma ferramenta inestimável para a mensuração de atributos estruturais de árvores individuais com alta precisão, tais como o diâmetro à altura do peito (DAP), alturas de fustes, área de copa e volume de madeira (COMESANA-CABRAL et al., 2021; SHAO et al., 2024).

Além disso, o MLS possibilita a segmentação individual de árvores, o mapeamento tridimensional detalhado do sub-bosque e a identificação de troncos e galhos em diferentes estratos, informações cruciais para a análise de sucessão ecológica. A precisão geométrica obtida com o auxílio de algoritmos de posicionamento avançados, como SLAM (*Simultaneous Localization and Mapping*), permite resultados comparáveis aos obtidos por TLS (*Terrestrial Laser Scanning*), mas com maior praticidade operacional e menor custo em áreas extensas ou de difícil acesso (QI et al., 2022).

Esta capacidade de detalhamento da estrutura vertical e horizontal das camadas inferiores da floresta o torna particularmente adequado para caracterizar a densidade de sub-bosque e a estratificação, parâmetros-chave para a diferenciação de estágios sucessionais.

2.5.2. UAV-LiDAR

O UAV-LiDAR consiste na montagem de um sensor LiDAR leve em uma plataforma aérea não tripulada (*drone*). Essa combinação oferece uma flexibilidade sem precedentes para a aquisição de dados em escala local e regional, preenchendo a lacuna entre o detalhe do TLS/MLS e a cobertura de grandes áreas do LiDAR aerotransportado tradicional (ALS) (WALLACE et al., 2016). O UAV-LiDAR se destaca pela sua capacidade de adquirir dados de alta densidade e precisão a altitudes relativamente baixas, o que minimiza a oclusão do dossel e permite a geração de modelos digitais da superfície e do terreno com grande acurácia.

As aplicações do UAV-LiDAR em florestas nativas são vastas e têm se mostrado extremamente eficazes no monitoramento e caracterização de processos sucessionais. Permite a geração de Modelos de Altura do Dossel (MDE) altamente detalhados, Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT), a partir dos quais métricas de altura e densidade podem ser derivadas com grande fidelidade (ZHANG et al., 2023).

Essa tecnologia é particularmente útil para a delimitação de copas de árvores

individuais, a estimativa de biomassa e volume, a detecção de clareiras e a avaliação da complexidade da estrutura do dossel superior (TORRESAN et al., 2017; WU et al., 2023). A agilidade e o custo-benefício do UAV-LiDAR o tornam uma ferramenta de destaque para levantamentos em parcelas experimentais, fragmentos florestais e áreas de restauração, permitindo o monitoramento temporal da evolução da estrutura florestal e a identificação de mudanças associadas à sucessão.

Em resumo, enquanto o MLS se sobressai na captura de detalhes do sub-bosque e da estrutura de fustes, o UAV-LiDAR oferece uma visão detalhada do dossel superior e da estrutura geral da floresta em escalas intermediárias. Ambas as tecnologias, em suas particularidades e em potencial integração, são pilares para a caracterização estrutural necessária à classificação acurada dos estágios sucessionais em florestas nativas complexas, como a Floresta Ombrófila Mista.

2.6. APLICAÇÕES DE *MACHINE LEARNING* EM SUCESSÃO FLORESTAL

A emergência dos algoritmos de aprendizado de máquina (*Machine Learning*) representou uma transformação paradigmática na análise de dados florestais, capacitando pesquisadores a modelar, classificar e prever estágios sucessionais com precisão e eficiência sem precedentes (BELGIU & DRĂGUȚ, 2016; FRICK, 2020). Estes métodos, ao identificar padrões complexos e relações não lineares em vastos conjuntos de dados, superam as limitações das abordagens estatísticas tradicionais, que muitas vezes exigem pressupostos rígidos sobre a distribuição dos dados e a linearidade das relações. A capacidade de processar e extrair conhecimento de um grande volume de métricas LiDAR, tanto discretas quanto *Full-Waveform*, é central para essa revolução.

Entre a miríade de algoritmos de ML, as técnicas baseadas em árvores de decisão, e em particular o *Random Forest* (RF), destacam-se como uma escolha preferencial em estudos florestais. O RF é um classificador de *ensemble* que opera construindo múltiplas árvores de decisão durante o treinamento e produzindo a classe que é a moda das classes (classificação) ou a média de previsão (regressão) das árvores individuais (BREIMAN, 2001).

Sua robustez deriva da capacidade de lidar eficientemente com grandes volumes de dados, alta dimensionalidade, presença de ruído, e multicolinearidade

entre as variáveis de entrada. Estudos recentes demonstram a eficácia do *Random Forest* na classificação de estágios sucessionais a partir de métricas derivadas de dados LiDAR, apresentando superioridade em relação a algumas análises baseadas apenas em inventários de campo, ao capturar a complexidade estrutural e a heterogeneidade inerente às florestas (BILL NETO, 2022; SCHEERES et al., 2023).

A importância de cada métrica na predição pode ser avaliada, fornecendo *insights* sobre quais atributos LiDAR (e.g., percentis de altura, densidades de pontos em diferentes estratos, índices de complexidade do dossel) são mais discriminatórios para a distinção entre os estágios sucessionais.

A integração de dados provenientes de diferentes plataformas LiDAR, como o UAV-LiDAR e o MLS, aliada ao uso de algoritmos robustos de ML, potencializa significativamente a identificação e caracterização de padrões estruturais complexos, que são essenciais para a discriminação precisa dos estágios sucessionais. Essa abordagem permite combinar a visão superior do dossel fornecida pelo UAV-LiDAR com o detalhamento do sub-bosque e fustes oferecido pelo MLS, criando um conjunto de métricas mais completo e representativo da estrutura florestal tridimensional.

Contudo, desafios como a generalização de modelos, a necessidade de conjuntos de dados de treinamento bem curados e a padronização das métricas LiDAR entre diferentes sensores e plataformas ainda constituem áreas ativas de pesquisa. O avanço contínuo dessas técnicas e a exploração de novas arquiteturas de ML reforçam a viabilidade do uso do aprendizado de máquina como uma ferramenta estratégica e indispensável para a avaliação acurada e dinâmica da sucessão florestal em ecossistemas complexos.

2.7. DESAFIOS E PERSPECTIVAS FUTURAS NO USO DE LIDAR PARA AVALIAÇÃO SUCESSIONAL

Embora os avanços recentes consolidem o LiDAR como tecnologia-chave para o monitoramento de florestas, diversos desafios permanecem para sua aplicação plena na avaliação de estágios sucessionais. Entre eles, destaca-se a necessidade de métodos padronizados para a extração e interpretação de métricas estruturais, a fim de garantir comparabilidade entre estudos e regiões distintas.

A variabilidade nos parâmetros de aquisição de dados LiDAR, como densidade

de pontos, ângulo de escaneamento e frequência dos pulsos, influencia diretamente a qualidade dos produtos derivados e, conseqüentemente, a acurácia dos modelos preditivos (ILANGAKOON et al., 2022). Além disso, a integração de diferentes plataformas de aquisição, como UAV-LiDAR e *Mobile Laser Scanning* (MLS), impõe desafios adicionais de calibração e harmonização de dados (MALLMANN, 2023).

No contexto da Floresta Ombrófila Mista, a elevada heterogeneidade estrutural e a presença de múltiplos estratos verticais agravam as dificuldades de classificação dos estágios sucessionais. A utilização de abordagens híbridas, combinando dados discretos e simulados (*Full-Waveform*), aliadas a algoritmos avançados de *machine learning*, desponta como caminho promissor para superar essas limitações.

Perspectivas futuras indicam o desenvolvimento de sensores LiDAR multiespectrais, capazes de integrar informações estruturais e espectrais em um único conjunto de dados, além da aplicação de técnicas de aprendizado profundo (*Deep learning*) para modelagem automática de atributos florestais (SCHEERES et al., 2023). Tais inovações têm o potencial de aprimorar significativamente a capacidade de monitoramento e gestão de florestas tropicais, consolidando o LiDAR como ferramenta indispensável para uma avaliação mais robusta e precisa da sucessão florestal.

3. CAPÍTULO II - CLASSIFICAÇÃO SUCESSIONAL EM FLORESTA FRAGMENTOS DA OMBRÓFILA MISTA (FOM) USANDO UAV-LIDAR

3.1. INTRODUÇÃO

A Mata Atlântica é um bioma de grande importância ecológica, abrigando cerca de 2.420 espécies de vertebrados e 20 mil espécies de plantas, muitas das quais possuem alto grau de endemismo (MITTERMEIER et al., 2011; MACHADO et al., 2025). Dentro desse bioma, a Floresta Ombrófila Mista (FOM), destaca-se por sua biodiversidade e complexidade ecológica. Contudo, este ecossistema tem passado por severos processos de degradação e fragmentação, resultando em paisagens compostas por mosaicos de floresta primária e em regeneração, áreas degradadas e regiões convertidas para uso agropecuário e urbano (SCARANO, 2015; BISPO et al., 2020).

De acordo com a Lei da Mata Atlântica (Lei Federal nº 11.428/2006), a compensação ambiental durante o licenciamento deve ser feita em áreas de mesmo estágio sucessional ou superior ao licenciado. A área de manutenção florestal, de modo geral, é determinada pelo estágio sucessional, exigindo a preservação de 30% para florestas em estágios médios e 50% para estágios avançados, a depender da área estar com zonas urbanas ou rurais, além da proibição de corte em florestas primárias (BRASIL, 2006).

Tradicionalmente, inventários florestais são realizados para coletar dados dendrométricos, como diâmetro e altura das árvores (FINEGAN, 1984; CABRAL et al., 2023). Essas informações são essenciais para compreender a estrutura e a dinâmica das florestas, sendo fundamentais na classificação dos estágios sucessionais (CAMPOS & LEITE, 2013; AVERY & BURKHART, 2015). Porém, realizar o inventário costuma ser oneroso e moroso, especialmente em áreas de difícil acesso (PÉLLICO NETTO & BRENA, 1997). Dessa forma, a busca por métodos eficientes, que auxiliem na caracterização mais precisa da floresta e que sejam acessíveis, se torna cada vez mais necessária para garantir a sustentabilidade e o manejo adequado das florestas.

Neste contexto, o sensoriamento remoto tem se revelado uma ferramenta fundamental na classificação dos estágios sucessionais florestais, onde, por meio de imagens de satélite de alta resolução já é possível mapear mudanças na cobertura do solo e identificar diferentes estruturas florestais com precisão (SOTHE et al., 2024).

Dados de radar também são eficazes para monitorar a estrutura do dossel florestal e variações na biomassa (HU et al., 2020).

Tecnologias como o LiDAR (*Light Detection and Ranging*), têm revolucionado os estudos florestais possibilitando a coleta de dados tridimensionais de alta resolução, oferecendo uma visão detalhada da estrutura vertical e da densidade do dossel florestal (MC ELHINNY et al., 2005). O LiDAR utiliza pulsos de *laser* para medir distâncias e criar modelos digitais da vegetação, capturando variáveis como altura máxima, altura média e desvio padrão das alturas, entre outros (DALLA CORTE et al., 2022).

Ferramentas avançadas para a extração de variáveis florestais a partir de dados LiDAR estão disponíveis, como o pacote *lidR* (Roussel & Auty, 2021) e *GediSimulator* (Hamamura et al., 2024) do *software R*, que oferece opções de extração de métricas detalhadas de altura, densidade de folhagem e estrutura do dossel, permitindo uma análise abrangente e multidimensional dessas variáveis (SILVA et al., 2019; ROUSSEL et al., 2020).

Estudos recentes confirmam a eficácia do uso de dados LiDAR na análise estrutural de florestas, destacando sua importância na quantificação precisa de características florestais (SILVA et al., 2022; ZHOU et al., 2023). Além disso, técnicas de análise multivariada e aprendizado de máquina, como análise de componentes principais e redes neurais (RN), têm mostrado grande potencial na classificação automatizada dos estágios sucessionais a partir de dados LiDAR, como nos estudos de (REIS et al., 2020; CABRAL et al., 2023).

Assim, o uso dessa tecnologia tem evoluído significativamente, integrando métodos de aprendizado de máquina e modelagem avançada para aprimorar a precisão das medições florestais. Tais ferramentas permitem a detecção, caracterização e modelagem florestal com maior precisão (DALLA CORTE et al., 2022).

Além disso, é possível verificar a eficácia dessas tecnologias na identificação de padrões de crescimento e regeneração florestal, oferecendo uma abordagem mais abrangente e precisa em comparação aos métodos tradicionais (DALPOSSO et al., 2021). Com tais ferramentas, é possível aprimorar os processos de diagnósticos sobre a condição dos fragmentos florestais e seus estágios sucessionais, além da análise de desenvolvimento e estrutura da floresta (MEIRA et al., 2020).

Diante deste cenário, este trabalho buscou investigar o potencial de uso da

tecnologia UAV-LiDAR (*Unmanned Aerial Vehicles*) para caracterização da estrutura vertical de remanescentes florestais em diferentes estágios sucessionais da floresta ombrófila mista (FOM). Adicionalmente, buscou-se investigar a possibilidade de aplicação de diferentes indicadores e métricas obtidas com a nuvem de pontos para caracterizar e enquadrar os diferentes estágios sucessionais da FOM.

3.2. MATERIAIS E MÉTODOS

3.2.1. Caracterização da Área de Estudo

O estudo foi conduzido na Fazenda Experimental Canguiri de propriedade da Universidade Federal do Paraná, localizada no município de Pinhais-PR, cujas coordenadas centrais são 25°23'30" S e 49°07'30" W (Figura 1). De acordo com a classificação climática de Köppen-Geiger, o clima da região é subtropical úmido (Cfb), caracterizado por verões amenos e invernos moderados, sem estação seca definida.

A precipitação média acumulada anual é de aproximadamente 1550 mm, enquanto a temperatura média anual é de 17°C. A fazenda está situada a uma altitude de 935 metros acima do nível do mar (ÁLVARES et al., 2013).

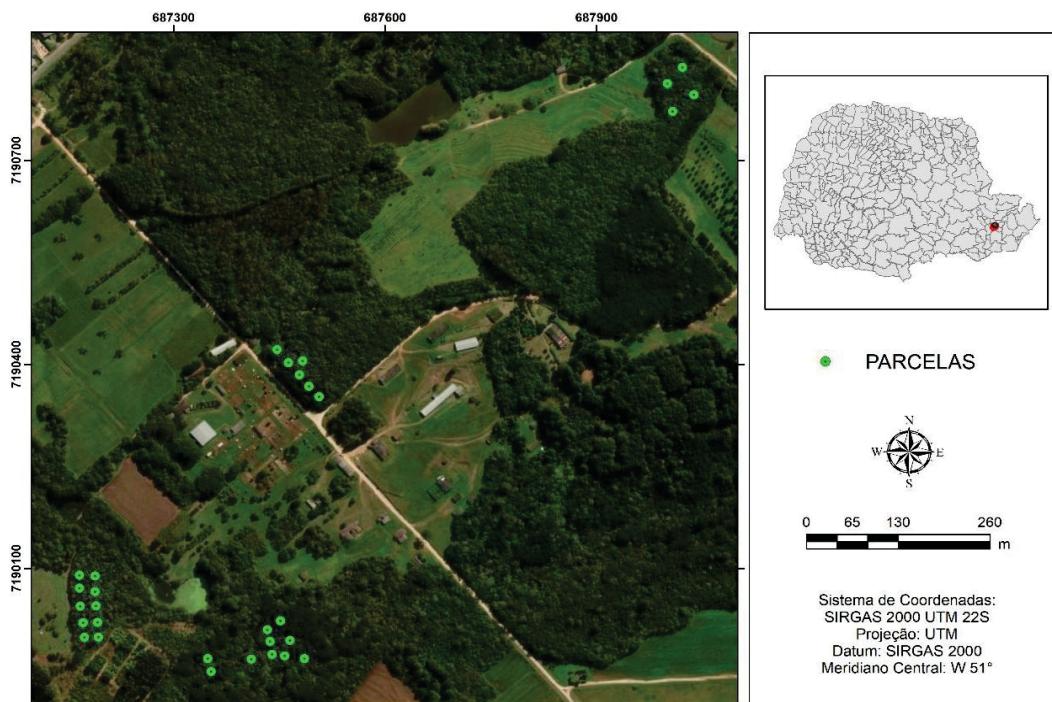


Figura 1. Mapa de localização da área de estudo e das parcelas.

Os solos predominantes na área de estudo incluem Cambissolos, Latossolos, Organossolos e Gleissolos, cada um com características particulares que influenciam a produtividade agrícola e a gestão do uso da terra. Cambissolos são solos jovens e bem drenados; Latossolos são profundos e bem desenvolvidos; Organossolos são ricos em matéria orgânica; e Gleissolos são frequentemente encontrados em áreas de drenagem deficiente e sujeitas a alagamentos.

A vegetação predominante na região é classificada como Floresta Ombrófila Mista (FOM), esse tipo de vegetação desempenha um papel crucial na conservação da biodiversidade e no equilíbrio ecológico da região (IBGE, 1992). Segundo Sanquetta (1995), a estrutura vertical da FOM apresenta diferentes estratos, variando desde indivíduos emergentes de *Araucaria angustifolia* até espécies latifoliadas de sub-bosque, destacando sua complexidade ecológica e relevância para a sustentabilidade ambiental.

A Fazenda Experimental Canguiri possui uma relevância significativa para a pesquisa agropecuária e florestal, fornecendo uma base para estudos que visam aprimorar as práticas de cultivo, a conservação do solo e o manejo ambiental. A presença de diversas classes de solo e de vegetação nativa, com remanescentes próximos a 10 anos e alguns superiores a 30, e de floresta plantada faz da fazenda um local ideal para a condução de pesquisas que buscam entender as interações entre clima, solo e vegetação, bem como desenvolver tecnologias sustentáveis de produção agrícola.

3.2.2. Levantamento dos Dados de Campo

Os dados de inventário florestal (IF) foram coletados em três campanhas realizadas em agosto de 2022. A amostragem do componente arbóreo ocorreu em 30 parcelas permanentes de 10 x 10 m, totalizando uma área de 3.000 m². A escolha pelo delineamento amostral em parcelas de 10 × 10 metros fundamentaram-se em critérios técnicos voltados à eficiência de coleta e à representatividade estrutural em ambientes de elevada heterogeneidade, como as florestas subtropicais. Estudos indicaram que unidades amostrais reduzidas são adequadas para capturar a variação estrutural local quando associadas a tecnologias de alta resolução, como o LiDAR (VATANDAŞLAR et al., 2023).

A localização e instalação das parcelas foram realizadas com auxílio de GPS e

trena. As alturas totais foram mensuradas com auxílio do hipsômetro *Vertex IV* e os diâmetros à altura do peito (dap) a 1,3 metro de todos os indivíduos arbóreos utilizando a fita diamétrica, sendo o diâmetro mínimo de 4 cm. Cada árvore medida foi identificada por meio de numeração sequencial dentro da parcela.

Árvores com múltiplos fustes abaixo de 1,30 m foram consideradas multicaule, com todos os fustes que atendiam ao diâmetro mínimo de inclusão medidos e identificados com o mesmo número. A coleta de dados começava sempre pelo vértice A, localizado no sudoeste (SW), sendo os demais vértices (B, C e D) determinados em sentido horário.

Todos os indivíduos arbóreos vivos, cujas bases dos troncos estavam completamente dentro dos limites da parcela, foram mensurados. A identificação das espécies foi realizada *in loco*, para aquelas não reconhecidas no campo, o material botânico foi coletado para posterior identificação no Herbário Escola de Florestas de Curitiba – EFC. A confirmação e atualização dos nomes científicos e das respectivas famílias foram feitas por meio de consulta à Lista de Espécies da Flora do Brasil, seguindo o sistema *Angiosperm Phylogeny Group III* (APG III, 2009).

3.2.2.1. Cálculo de Variáveis Oriundas do Inventário Florestal

3.2.2.1.1. Área Basal (m²/ha) (G)

Para o cálculo da área basal, primeiro foi obtido o valor da área transversal de cada indivíduo arbóreo por parcela, conforme a Equação (1):

$$g_i = \frac{\pi \times (dap_i)^2}{40.000} \quad \text{Equação (1)}$$

Onde:

g_i = Área transversal individual (m²);

π = Constante Pi;

dap = Diâmetro à 1,30 m de altura (cm);

Para o cálculo da Área Basal (G), somou-se a área transversal de todas as árvores da parcela, que multiplicado pelo fator de expansão converteu em (G), conforme a Equação (2):

$$G \text{ (m}^2\text{/ha)} = \sum g \times F \text{ Equação (2)}$$

$$F = 10000/\text{Área da Parcela m}^2$$

Onde:

G = Área Basal (m²/ha);

$\sum g$ = Somatório das áreas transversais (m²);

F = Fator de Expansão;

3.2.2.1.2. Altura Média (\overline{ht})

A altura média foi calculada somando-se as alturas das árvores medidas em cada parcela e dividindo-se pelo número total de árvores, conforme a Equação (3):

$$\overline{ht} = \frac{\sum ht}{n} \text{ Equação (3)}$$

Onde:

\overline{ht} = Altura médias das árvores (m);

$\sum ht$ = Somatório das alturas das árvores medidas na parcela (m);

n = Número total de árvores contadas na parcela;

3.2.2.1.3. Diâmetro Médio (\overline{dap})

O diâmetro médio é obtido pela média aritmética dos diâmetros à altura do peito (dap) das árvores, conforme a Equação (4):

$$\overline{dap} = \frac{\sum dap}{n} \text{ Equação (4)}$$

Onde:

\overline{dap} = Diâmetro média à altura do peito dos indivíduos arbóreos (m);

$\sum dap$ = Somatório dos diâmetros à 1,3 m de altura das árvores da parcela;

n = Número total de árvores contadas na parcela;

3.2.2.1.4. Diâmetro Quadrático Médio (dqm)

O DQM é uma medida que representa um valor médio ponderado do diâmetro das árvores em uma determinada área, considerando o efeito da área basal de cada árvore, sendo mais representativo da estrutura da floresta do que a média aritmética dos diâmetros (SANQUETTA et al., 1995; HUSCH et al., 2003). Ele é calculado

extraindo-se a raiz quadrada da média dos quadrados dos diâmetros, conforme a Equação (5):

$$dqm = \sqrt{\frac{\sum dap^2}{n}} \quad \text{Equação (5)}$$

Onde:

dqm = Diâmetro quadrático médio das árvores (m);

$\sum dap^2$ = Soma dos quadrados dos diâmetros à 1,30 de altura;

n = Número total de árvores;

3.2.2.1.5. Variância das Alturas ($htvar$)

A variância das alturas fornece uma medida da dispersão das alturas em relação à média. É calculada conforme a Equação (6):

$$htvar = \frac{\sum (ht - \overline{ht})^2}{n-1} \quad \text{Equação (6)}$$

Onde:

$htvar$ = Variância das alturas das árvores (m^2);

$\sum (ht - \overline{ht})^2$ = Soma dos quadrados das diferenças entre as alturas individuais e a altura média da parcela;

n = Número total de árvores;

3.2.2.1.6. Desvio Padrão das Alturas ($htsd$)

O desvio padrão das alturas foi calculado como a raiz quadrada da variância das alturas, representando a dispersão das alturas individuais em relação à média de maneira mais intuitiva. Ele é calculado conforme a Equação (7):

$$htsd = \sqrt{htvar} \quad \text{Equação (7)}$$

Onde:

$htsd$ = Desvio Padrão das alturas das árvores (m);

$htvar$ = variância das alturas das árvores medidas na parcela;

3.2.2.1.7. Altura Dominante (*htdom*)

A altura dominante é a média das alturas das árvores mais altas que dominam o dossel florestal. Esta medida é essencial para avaliar o potencial de crescimento do sítio e a qualidade do habitat (CURTIS et al., 2002). A altura dominante foi calculada selecionando as árvores cujo diâmetro está acima do percentil 75 da distribuição dos diâmetros na parcela e calculando a média das alturas dessas árvores. A fórmula é dada pela Equação (8):

$$htdom = \frac{\sum ht \text{ dominantes}}{n \text{ dominantes}} \text{ Equação (8)}$$

Onde:

$\sum ht$ dominantes = Soma das alturas das árvores dominantes na parcela (m);

n dominantes = Número de árvores dominantes consideradas na parcela;

3.2.2.1.8. Percentil 90 (P90)

O percentil 90 é uma métrica utilizada para representar o estrato superior da floresta e fornecer uma estimativa robusta da estrutura do dossel e do potencial de crescimento das árvores dominantes. É calculada como a média das alturas das árvores cujo valor está acima do percentil 90 da distribuição das alturas dentro de cada parcela.

Essa abordagem é respaldada por estudos que demonstram forte correlação entre o percentil 90 das alturas e a média das árvores mais altas obtidas por inventário tradicional, sendo especialmente válida em análises com dados LiDAR e fotogrametria digital (PRIOR et al., 2022). A utilização do percentil 90 como critério para estimativa da altura dominante tem se mostrado eficaz em florestas decíduas e de dossel fechado, contribuindo para a caracterização estrutural precisa em ambientes complexos. É calculada conforme a Equação (9):

$$P90 = \text{Percentil 90 (ht) Equação (9)}$$

Onde:

P90 = Percentil a 90% das alturas;

3.2.2.1.9. Altura Mediana (*htmed*)

A altura mediana é o valor que divide a distribuição das alturas das árvores em duas metades, onde 50% das árvores têm alturas menores e 50% têm alturas maiores que esse valor. Essa métrica é útil para entender a distribuição das alturas sem a influência de valores extremos. A fórmula para calcular a altura mediana é dada pela Equação (10):

$$htmed = \text{Mediana}(ht) \text{ Equação (10)}$$

Onde:

ht = Alturas das árvores medidas na parcela (m);

3.2.2.1.10. Altura Máxima (*htmax*)

A altura máxima é a maior altura registrada entre as árvores da parcela e indica o potencial máximo de crescimento em resposta às condições ecológicas locais. Essa métrica reflete a dominância estrutural e a vantagem competitiva por luz, estando associada a maiores taxas de crescimento e produtividade florestal (FALSTER & WESTOBY, 2003; GARNIER & NAVAS, 2012). A fórmula é apresentada na Equação (11).

$$htmax = \text{Máximo}(ht) \text{ Equação (11)}$$

Onde:

ht = Conjunto de alturas das árvores medidas na parcela (m).

3.2.2.1.11. Percentil 95 (P95)

O Percentil 95% representam o valor abaixo do qual se encontram 95% das alturas das árvores, sendo amplamente utilizada em análises para estimar a altura do dossel dominante com menor influência de *outliers*. Tem se mostrado uma variável relevante em classificações estruturais florestais (TIJERÍN-TRIVIÑO et al., 2022). A fórmula é dada pela Equação (12).

$$P95 = \text{Percentil 95}(ht) \text{ Equação (12)}$$

Onde:

P95 = Percentil a 95% das alturas;

3.2.2.1.12. Percentil 25 (P25)

O Percentil 25%, correspondem a distribuição das alturas, representando a altura mínima das árvores que compõem o dossel. Essa métrica é útil para descrever a transição entre o sub-bosque e o estrato superior da floresta (MacDICKEN, 2015). A fórmula é dada pela Equação (13).

$$P25 = \text{Percentil 25 (ht) Equação (13)}$$

Onde:

P25 = Percentil a 25% das alturas;

3.2.2.1.13. Altura Média Ponderada com Área Basal (*htmab*)

A altura média ponderada pela área basal confere maior peso às árvores de maior diâmetro. Reflete com mais precisão a estrutura dominante do povoamento, sendo amplamente empregada em análises de crescimento, produtividade e modelagem florestal (BURKHART & TOMÉ, 2012). A *htmab* é calculada segundo a Equação (14), em que cada altura é ponderada pela respectiva área basal da árvore na parcela.

$$htmab = \frac{\sum(hti \times gi)}{\sum gi} \quad \text{Equação (14)}$$

Onde:

hti = altura do indivíduo i na parcela;

gi = área transversal do indivíduo i na parcela (m²);

3.2.2.1.14. Quantificação de Árvores

A contagem da vegetação arbórea foi realizada individualmente em cada parcela, com o objetivo de compreender melhor a composição florística e a dinâmica estrutural da floresta. Para isso, foram registrados o número total de árvores vivas, mortas, o número de famílias botânicas e o total de espécies identificadas.

Além disso, as espécies presentes foram classificadas conforme seu grupo ecológico, considerando três categorias funcionais: pioneiras (PI), não pioneiras (NP) e facultativas (FA). Essa categorização teve como base publicações de referência

como os trabalhos de Carvalho (2008), os manuais da EMBRAPA e a dissertação de Secco (2017). Agrupar as espécies dessa forma permitiu identificar estratégias ecológicas distintas, como a capacidade de colonizar áreas abertas ou a preferência por ambientes mais sombreados. Essa abordagem torna-se uma ferramenta valiosa para interpretar o estágio sucessional dos fragmentos florestais estudados, ajudando a revelar padrões de resiliência e adaptação da vegetação.

3.2.2.1.15. Coeficiente de Variação de Diâmetro (*dapcv*)

O coeficiente de variação de diâmetro é a medida relativa de dispersão dos diâmetros em relação à média da parcela, expresso em porcentagem. É amplamente empregada para avaliar a heterogeneidade estrutural da floresta, indicando a variabilidade de crescimento entre os indivíduos arbóreos (BURKHART & TOMÉ, 2012), como descrito na Equação (15):

$$dapcv = \frac{dapdp}{\overline{dap}} \times 100 \text{ Equação (15)}$$

Onde:

dapdp = desvio padrão dos diâmetros à altura do peito;

\overline{dap} = diâmetro médio à altura do peito por parcela.

3.2.2.1.16. Coeficiente de Variação da Altura (*htcv*)

O coeficiente de variação da altura (*htcv*) expressa a variabilidade relativa das alturas das árvores em uma parcela, sendo calculado como a razão entre o desvio padrão e a média das alturas, em porcentagem. Essa métrica é amplamente usada para avaliar a heterogeneidade vertical da floresta e sua estrutura sucessional (BURKHART & TOMÉ, 2012) (Equação 16).

$$htcv = \frac{htdp}{\overline{ht}} \times 100 \text{ Equação (16)}$$

Onde:

htdp = desvio padrão das alturas na parcela;

\overline{ht} = Altura mediadas árvores por parcela.

3.2.2.1.17. Estratificação Diagrama h - M (SANQUETTA, 1995)

O diagrama h - M representa os estratos da floresta por meio de um gráfico relacionando a altura total das árvores (denotada como h) no eixo y e o valor médio cumulativo parcial da altura (representado por M) no eixo x , para seu cálculo foram seguidas as etapas metodológicas descritas por (SALZMANN et al., 2011).

Utilizando os dados por parcela do inventário florestal tradicional, as alturas das árvores foram então ordenadas em ordem decrescente para a análise cumulativa. Em seguida, calculou-se o número cumulativo de árvores $N(x)$ somando-se o número de árvores a partir da maior altura até a menor. A produção cumulativa de altura $Y(x)$ foi obtida somando-se cumulativamente as alturas das árvores. O valor médio de produção $M(x)$ foi então calculado dividindo-se a produção cumulativa de altura $Y(x)$ pelo número cumulativo de árvores $N(x)$.

Conforme Salzmann et al., (2011), os dados coletados foram divididos em três grupos contendo o mesmo número de indivíduos: árvores mais baixas, árvores de altura média e árvores mais altas. Essa divisão facilita a identificação de picos abruptos entre um estrato e outro. Para cada grupo, foram retirados certos percentuais de árvores dos extremos das distribuições de altura: no grupo de árvores mais baixas, retiraram-se 10% das árvores mais baixas; no grupo de árvores de altura média, retiraram-se 5% das árvores mais altas e 5% das mais baixas dentro deste grupo; no grupo de árvores mais altas, retiraram-se 10% das árvores mais altas.

Após esse procedimento, novos diagramas h - M foram gerados. A altura total das árvores h foi plotada no eixo y e o valor médio cumulativo parcial da altura M no eixo x . A análise dos resultados permitiu identificar a existência de estratos bem definidos na floresta. A metodologia, conforme descrita por Salzmann et al. (2011), adaptada da metodologia de Sanquetta (1995), proporciona eficácia ao permitir uma visualização mais clara e definida da estratificação florestal, evidenciando as diferenças entre estratos de forma mais abrupta e facilitando a análise estrutural para o manejo florestal sustentável.

3.2.2.1.18. Índice de Uniformidade (IU)

Para obtenção do Índice de Uniformidade (IU), foi utilizada a metodologia de SANTOS et al. (2019). O IU expressa a distribuição relativa das alturas das árvores,

sendo calculado a partir dos dados obtidos no inventário florestal tradicional.

O índice foi determinado utilizando o percentil 50, conforme adaptado da metodologia de (HAKAMADA, 2012). Esse índice representa a porcentagem acumulada da altura das 50% menores árvores da parcela, ordenadas de forma crescente, conforme Equação 17.

$$IU = \left(\frac{\sum_{i=1}^{n/2} ht_{ijk}}{\sum_{i=1}^n ht_{ijk}} \right) \text{ Equação (17)}$$

Onde:

IU = é a porcentagem acumulada da altura individual das 50% menores árvores na parcela j na idade k ;

ht_{ijk} = é a altura individual da árvore i na parcela j idade k ;

n = Número total de árvores na parcela.

3.2.2.1.19. Índice de Diversidade de Shannon (H')

O Índice de Shannon (H'), fundamentado na teoria da informação proposta por Shannon (1948), foi adaptado para aplicações ecológicas por (MARGALEF, 1958). Atualmente, é amplamente utilizado para quantificar a diversidade ecológica, considerando simultaneamente a riqueza de espécies e sua Equitabilidade dentro de uma comunidade (MAGURRAN, 2003). Valores mais altos de H' indicam maior diversidade, com espécies mais uniformemente distribuídas, enquanto valores mais baixos refletem o predomínio de poucas espécies. A fórmula para seu cálculo é apresentada na Equação (18).

$$H' = -(\sum p_i \ln(p_i)) \text{ Equação (18)}$$

Onde:

P_i = Proporção de indivíduos da espécie i em relação ao total de indivíduos amostrados;

3.2.2.1.20. Índice de Equitabilidade de Pielou (J')

O Índice de Equitabilidade de Pielou (J') foi proposto por Pielou (1966) como uma métrica complementar ao Índice de Shannon (H'), avaliando o grau de uniformidade na distribuição dos indivíduos entre as espécies de uma comunidade. Esse índice varia de 0 a 1, onde valores mais próximos de 1 indicam uma comunidade

mais equitativa e valores próximos de 0 indicam domínio de poucas espécies sobre as demais. Conforme equação 19.

$$J' = \frac{H'}{\ln(S)} \text{ Equação (19)}$$

J' = Índice de Shannon;

S = Número total de espécies na comunidade.

3.2.2.1.21. Índice de Sucessão Florística (ISF)

O Índice de Sucessão Florística (ISF) é uma métrica utilizada para avaliar o grau de maturidade sucessional de uma floresta, baseado na proporção de espécies pioneiras, não pioneiras e facultativas. O conceito do índice deriva de estudos clássicos sobre sucessão ecológica, como os de Connell & Slatyer (1977; Whitmore, 1989). O índice é calculado conforme equação 20.

$$ISF = \frac{NNP+NFA}{NPI+NNP+NFA} \text{ Equação (20)}$$

Onde:

N_{NP} = Número de indivíduos não pioneiros;

N_{FA} = Número de indivíduos facultativos;

N_{PI} = Número de indivíduos pioneiros.

3.2.3. Classificação em Estágios Sucessionais e Análise Descritiva das Variáveis com Base nos Dados de Inventário Florestal Tradicional

A classificação das parcelas nos diferentes estágios sucessionais fundamentou-se em uma abordagem de estatística multivariada, estruturada em duas etapas: redução da dimensionalidade via Análise de Componentes Principais (PCA) e agrupamento estrutural por meio da Classificação Hierárquica Ascendente (CHA).

Previamente às análises, as variáveis estruturais foram submetidas à padronização (*Z-score*), procedimento essencial para equalizar o peso de variáveis mensuradas em diferentes unidades e escalas (JOLLIFFE & CADIMA, 2016). A PCA foi aplicada para sintetizar a variabilidade dos dados em um número reduzido de componentes principais (CPs) ortogonais, mantendo a máxima informação original (ABDI & WILLIAMS, 2010). A seleção do número de CPs seguiu o critério da variância

explicada acumulada, adotando-se o limiar mínimo de 70% (HAIR et al., 2014).

Os escores fatoriais das parcelas nos componentes selecionados serviram de entrada para a CHA, conduzida pelo método de *Ward* com métrica de distância Euclidiana. O número de agrupamentos foi definido por meio da inspeção visual do dendrograma, priorizando a coerência ecológica e a separabilidade entre os grupos (HASTIE et al., 2009). Para validar a classificação, realizou-se uma análise comparativa entre os grupos identificados e os parâmetros da Resolução CONAMA nº 002/1994, verificando a aderência dos métodos empíricos aos critérios legais vigentes para o Estado do Paraná (CONAMA, 1994).

A caracterização estrutural de cada estágio foi realizada por meio de análise descritiva, incluindo o cálculo de média, desvio padrão e amplitude, além da construção de histogramas de frequência e matrizes de correlação de Pearson. O foco recaiu sobre indicadores fundamentais para a regulamentação ambiental: área basal (G), diâmetro médio e altura média.

A comparação estatística das variáveis estruturais entre os estágios identificados foi realizada por meio de testes de hipóteses, precedidos pela verificação de normalidade (Shapiro-Wilk). Aplicou-se a Análise de Variância (ANOVA) para dados normais e o teste de Kruskal-Wallis para distribuições não paramétricas ($p < 0,05$), visando confirmar a distinção estrutural entre os agrupamentos formados. Todas as análises foram processadas no *software R*, buscando uma caracterização sistemática e robusta das estruturas florestais observadas.

3.2.4. Obtenção de Dados LiDAR

3.2.4.1. Parâmetros de Voo e Especificações Técnicas

Os dados aéreos foram coletados em agosto de 2022 por meio de um voo a 120 metros de altura, utilizando a plataforma UAV DJI Matrice 300 RTK (Figura 2). Este drone possui autonomia de voo de até 55 minutos e capacidade de carga útil de 2,7 kg (DJI, 2020), o que confere estabilidade e segurança para operações de mapeamento florestal. A densidade da nuvem de pontos, o plano de voo foi executado com 50% de sobreposição frontal e lateral, minimizando oclusões no dossel.



Figura 2. DJI Matrice 300 utilizado para a presente pesquisa.

O LiAir V (Figura 3) opera com uma taxa de varredura de 100.000 pontos por segundo e possui um campo de visão (FOV) circular de $38,4^\circ$. O sensor apresenta uma precisão de alcance de ± 2 cm e uma precisão sistêmica de ± 5 cm, com alcance operacional de até 260 metros em alvos de alta refletividade (80%) e aproximadamente 90 metros para alvos com 10% de refletividade, características que permitem a captura detalhada da estrutura vertical da Floresta Ombrófila Mista (GREENVALLEY, 2020).



Figura 3. Sensor LiAir V utilizado no voo.

3.2.4.2. Processamento da Nuvem LiDAR

O processamento dos dados LiDAR foi conduzido no ambiente estatístico *R* (R CORE TEAM, 2023), utilizando o ecossistema do pacote *lidR* (ROUSSEL et al., 2020), seguindo o fluxo metodológico para inventário florestal com enfoque em unidade de área (DALLA CORTE et al., 2022). Inicialmente, aplicou-se o filtro de redundância espacial por meio da função *filter_duplicates*, eliminando pontos com coordenadas

idênticas para assegurar a integridade estatística da nuvem e evitar vieses no cálculo de densidade (ROUSSEL, 2023).

A classificação dos pontos do terreno foi feita com o comando *classify_ground*, que aplica algoritmos de filtragem para identificar pontos pertencentes ao relevo. A partir dessa classificação, é possível gerar os modelos DTM (Digital Terrain Model) e DSM (Digital Surface Model), utilizando-se respectivamente os comandos *grid_terrain* e *grid_canopy*.

A etapa crítica de normalização da nuvem foi executada pela função *normalize_height*. A partir da nuvem normalizada, gerou-se o Modelo de Altura do Dossel (CHM), essencial para a extração de métricas de estrutura vertical. Para a análise local, as parcelas foram recortadas utilizando vetores *shapefile* com um *buffer* periférico de 5 metros, totalizando amostras de 20 x 20 metros. Esse procedimento é fundamental para evitar a oclusão de copas situadas nas bordas e garantir a representatividade da diversidade estrutural (FSD) na unidade amostral (ATKINS et al., 2023).

3.2.4.3. Métricas Extraídas da Nuvem com o Pacote *lidR*

A extração de métricas estruturais foi realizada para cada unidade amostral por meio da função *cloud_metrics* do pacote *lidR* (ROUSSEL et al., 2020). As métricas foram selecionadas por sua capacidade de descrever a complexidade tridimensional e a heterogeneidade biológica, atributos fundamentais para a distinção de estágios sucessionais. As variáveis foram agrupadas conforme as seguintes propriedades:

- **Métricas de Centralidade e Extensão Vertical:** A altura máxima (*zmax*) e a altura média (*zmean*) foram utilizadas como indicadores diretos do desenvolvimento ontogênico da floresta e da biomassa acima do solo (AGB) (SANAEL et al., 2018a). O desvio padrão das alturas (*zsd*) quantificou a variação absoluta na organização vertical, sendo um descritor primário da Diversidade Estrutural Florestal (FSD) (ATKINS et al., 2023).
- **Indicadores de Distribuição e Forma:** O coeficiente de variação (*zcv*) expressa a heterogeneidade relativa, permitindo comparar a complexidade entre parcelas com diferentes alturas médias (SANAEL et al., 2020). A assimetria (*zskew*) e a curtose (*zkurt*) da distribuição de alturas foram extraídas para caracterizar a distribuição da biomassa; valores de *zskew* positivos indicam dosséis mais

abertos com dominância de estratos inferiores, enquanto valores negativos sugerem dosséis fechados e maduros (FAGUA et al., 2021).

- **Índices de Complexidade e Densidade:** A entropia de Shannon (zentropy) aplicada ao perfil vertical foi utilizada para medir a uniformidade da ocupação do espaço pelas copas, sendo um indicador de resiliência e maturidade sucessional (SENF et al., 2020). As métricas de densidade, como a proporção de pontos acima da média (pzabovezmean) e acima de 2 metros (pzabove2), permitiram quantificar o fechamento do dossel e a densidade do estrato arbóreo, diferenciando áreas em regeneração inicial de florestas estabelecidas (GOUGH et al., 2019; LARUE et al., 2019).
- **Perfil de Percentis e Penetração:** Extraíram-se os percentis de altura de zq5 a zq99. Os percentis inferiores (zq5 a zq25) foram correlacionados ao estrato de sub-bosque e regeneração, enquanto os superiores (zq75 a zq99) representam o estrato dominante e emergente (PRETZSCH et al., 2019). A proporção de pontos no solo (pground) foi utilizada como um *proxy* para a abertura do dossel (fração de lacunas), refletindo a capacidade de penetração do feixe LiDAR em diferentes densidades de cobertura (FAGUA et al., 2021).

3.2.4.3.1. Índice de Diversidade Vertical (VDI)

Calculou-se o Índice de Diversidade Vertical (VDI) como uma métrica de síntese da complexidade estrutural tridimensional. O VDI fundamenta-se na premissa de que a distribuição vertical da vegetação reflete a estratificação biológica e a heterogeneidade de *habitats*, onde uma ocupação mais equitativa de diferentes estratos correlaciona-se a uma maior oferta de nichos ecológicos e resiliência do ecossistema (GUO et al., 2017; TORRESANI et al., 2020).

O processamento foi executado no ambiente estatístico *R*, integrando as funcionalidades dos pacotes *lidR* (ROUSSEL et al., 2020) para manipulação de nuvens de pontos, *dplyr* (Wickham et al., 2023) para estruturação de dados e *vegan* (Oksanen et al., 2001) para o cálculo de índices de diversidade. O fluxo analítico para a determinação do índice iniciou-se com o pré-processamento e filtragem das nuvens de pontos normalizadas de cada parcela, as quais foram submetidas a uma limpeza rigorosa para eliminação de ruídos, incluindo a remoção de valores de altura negativos e de *outliers* localizados além de três desvios-padrão da média, garantindo que o perfil

vertical representasse fielmente a estrutura da vegetação (TORRESANI et al., 2020).

Na sequência, as alturas dos pontos remanescentes foram organizadas em classes verticais (*bins*) de 1 metro de amplitude, seguindo a metodologia de Torresani et al. (2020), de modo a transformar a distribuição contínua de alturas em uma distribuição de frequências relativas onde cada classe atua como uma unidade funcional da estrutura vertical. Por fim, o VDI foi obtido pela aplicação do Índice de Diversidade de Shannon, utilizando a proporção de pontos em cada classe de altura.

O índice resultante quantifica o grau de incerteza ou "entropia" da distribuição vertical: valores elevados de VDI indicam uma distribuição multiestratificada e uniforme de biomassa ao longo do perfil, característica de estágios sucessionais avançados ou florestas maduras, enquanto valores baixos sugerem dominância de poucos estratos ou dosséis simplificados (LARUE et al., 2023; TORRESANI et al., 2020).

3.2.4.3.2. Índice de Estratificação (SI)

O Índice de Estratificação (SI) foi empregado para quantificar a distribuição vertical da vegetação em camadas discretas, permitindo uma análise detalhada da arquitetura do ecossistema florestal. Conceitualmente fundamentado na teoria de estratificação de Richards (1952), que descreve a organização da floresta em estratos (A, B e C) com base na altura e forma das copas, este índice foi adaptado para dados LiDAR visando identificar a densidade relativa de biomassa em diferentes faixas verticais (VIERLING et al., 2008; SIMONSON et al., 2018).

Diferentemente do VDI, que avalia a diversidade estrutural de forma contínua através da entropia, o SI foca na partição da nuvem de pontos em estratos vegetacionais funcionalmente definidos. No presente estudo, o cálculo baseou-se na frequência relativa de retornos em classes de altura (*bins*) de 1 metro, integradas para compor três estratos principais: sub-bosque (0–10 m), dossel intermediário (10–20 m) e dossel superior (>20 m). O processamento foi automatizado no *software R*, utilizando funções customizadas dos pacotes *lidR* (ROUSSEL et al., 2020) e *dplyr* (WICKHAM et al., 2023).

A distinção entre o VDI e o SI reside na natureza da interpretação estrutural: enquanto o VDI expressa a heterogeneidade vertical (incerteza da distribuição), o SI

quantifica a ocupação volumétrica de camadas específicas. Assim, o SI permitiu inferir a presença de sub-bosques densos ou a dominância de estratos emergentes, sendo um indicador sensível para a caracterização de estágios sucessionais, onde a migração da densidade de pontos dos estratos inferiores para os superiores marca o avanço da maturidade da floresta (SIMONSON et al., 2018; WANG et al., 2018).

3.2.4.3.3. Densidade de Área Foliar (*LEAF AREA DENSITY* - LAD), Índice de Área Foliar (*LEAF AREA INDEX* - LAI).

As estimativas da Densidade de Área Foliar (LAD) e do Índice de Área Foliar (LAI) foram realizadas com o objetivo de caracterizar a distribuição volumétrica da biomassa fotossinteticamente ativa e a complexidade da organização vertical da vegetação. Todo o processamento analítico foi conduzido no ambiente estatístico *R*, integrando as funcionalidades de voxelização do pacote *lidR*, Roussel et al., (2020) e as rotinas de estruturação de dados do pacote *dplyr* (WICKHAM et al., 2023). O fluxo metodológico adotado seguiu os protocolos estabelecidos por Almeida (2019), garantindo a reprodutibilidade dos cálculos para a análise da estrutura florestal.

Na etapa inicial de tratamento da nuvem de pontos, aplicou-se uma filtragem rigorosa para considerar apenas os retornos situados acima de 1,0 metro de altura em relação ao solo, conforme preconizado por (ALMEIDA, 2019). Este procedimento técnico foi fundamental para eliminar as interferências causadas pelos retornos provenientes da serrapilheira e da vegetação herbácea rasteira, assegurando que o perfil vertical resultante reflita exclusivamente a biomassa foliar do sub-bosque lenhoso e do dossel superior. A nuvem de pontos utilizada estava já normalizada para que as coordenadas *Z* correspondessem à altura real da vegetação, permitindo a segmentação subsequente em estratos horizontais.

A estimativa da Densidade de Área Foliar (LAD), foi realizada por meio da discretização da nuvem de pontos em *voxels* com resolução vertical de 1 metro. Para converter a contagem de retornos em área foliar, aplicou-se o método de MacArthur-Horn, que se fundamenta nos princípios de atenuação da energia luminosa descritos pela Lei de Beer-Lambert. Para tanto, utilizou-se um coeficiente de extinção fixado em 0,5, valor que pressupõe uma distribuição angular esférica das folhas e é amplamente validado para dosséis florestais heterogêneos onde a inclinação foliar específica não é conhecida (ALMEIDA, 2019).

O Índice de Área Foliar (LAI), medida adimensional, foi derivado a partir da integração vertical dos valores de LAD obtidos para cada *voxel* ao longo de todo o perfil da parcela. Operacionalmente, esta etapa consistiu no somatório dos valores de LAD calculados para cada estrato de 1 metro, resultando na estimativa da área foliar total por unidade de superfície de solo (ALMEIDA, 2019). Esta transição de uma métrica volumétrica para uma métrica planar permitiu quantificar a capacidade de interceptação luminosa da vegetação e serve como um indicador robusto da densidade arbórea nas unidades amostrais.

Por fim, a consolidação desses parâmetros permitiu uma descrição detalhada da estratificação foliar das áreas em estudo, fornecendo subsídios essenciais para a classificação dos estágios sucessionais. A análise conjunta do LAD e do LAI possibilita identificar mudanças na altura de máxima densidade foliar e no adensamento do dossel, características que marcam a transição entre fases de regeneração inicial e o estabelecimento de estruturas florestais maduras.

3.2.4.3.4. Métricas de Diversidade (SHANNON, PIELOU)

A caracterização da heterogeneidade estrutural foi aprofundada por meio da aplicação dos índices de Shannon (H') e de Equabilidade de Pielou (J'), métricas originárias da ecologia de comunidades e da teoria da informação adaptadas para a análise da distribuição vertical de retornos LiDAR.

Essa abordagem fundamentou-se na premissa de que a organização da vegetação em diferentes estratos de altura assemelha-se à distribuição de indivíduos em diferentes categorias taxonômicas, onde a entropia da distribuição de pontos reflete a complexidade e a maturidade do ecossistema (SHANNON, 1948; PIELOU, 1966). Segundo Atkins et al. (2023), a transposição desses índices para o domínio estrutural permite quantificar a Diversidade Estrutural Florestal (FSD) de forma objetiva, servindo como um indicador sensível para a distinção de estágios sucessionais em florestas tropicais e subtropicais.

O processamento estatístico foi realizado no *software R*, integrando as funções de manipulação de nuvens do pacote *lidR* (ROUSSEL et al., 2020) com as rotinas de análise de diversidade do pacote *vegan* (OKSANEN et al., 2001). O fluxo analítico iniciou-se com a limpeza das nuvens de pontos normalizadas para a exclusão de valores negativos e *outliers* situados além de três desvios-padrão da média de altura.

As alturas remanescentes foram discretizadas em classes verticais (*bins*) de 1 metro de amplitude, transformando a nuvem em uma distribuição de frequências relativas que serviu de base para os cálculos de diversidade.

O Índice de Shannon (H') foi calculado para cada unidade amostral com o objetivo de mensurar a incerteza associada à ocupação vertical, onde valores elevados indicam dosséis multiestratificados com uma distribuição uniforme de biomassa ao longo de todo o perfil (ATKINS et al., 2023). Complementarmente, aplicou-se o Índice de Equabilidade de Pielou (J'), definido como a razão entre o índice de Shannon observado e o logaritmo natural do número total de classes de altura presentes. O índice de Pielou, variando de 0 a 1, permitiu quantificar o grau de homogeneidade na ocupação dos estratos; valores próximos à unidade revelam um dossel verticalmente equilibrado e com preenchimento contínuo, enquanto valores baixos indicam a concentração de pontos em poucos níveis, padrão característico de formações pioneiras ou simplificadas (PIELOU, 1966).

3.2.4.3.5. Métricas de Dossel

A caracterização da camada superior da floresta foi realizada por meio da estimativa da Cobertura do Dossel (CC) e do Índice de Rugosidade do Dossel (CRI), parâmetros essenciais para descrever a continuidade horizontal e a heterogeneidade vertical da copa. A Cobertura do Dossel foi calculada como a razão entre o número de retornos interceptados acima de um limiar de altura e o total de pulsos emitidos na unidade amostral.

Em conformidade com a metodologia de Fagua et al. (2021), adotou-se o limiar de 5 metros para distinguir o dossel propriamente dito dos estratos inferiores e da vegetação arbustiva em regeneração. Valores elevados de CC indicam um dossel fechado e contínuo, característico de florestas em estágios avançados de sucessão, enquanto valores reduzidos sinalizam a presença de clareiras ou descontinuidades estruturais resultantes de distúrbios ou estágios iniciais de colonização (SENF et al., 2020; FAGUA et al., 2021).

Complementarmente, avaliou-se a complexidade da superfície superior da floresta por meio do Índice de Rugosidade do Dossel (CRI). Este índice mensura a variabilidade vertical das alturas da copa, sendo um descritor da arquitetura tridimensional do dossel. A fundamentação teórica para esta métrica baseia-se em

Hardiman et al. (2013), que definem a rugosidade como a variação na organização da área foliar e das alturas, correlacionando-a diretamente com a heterogeneidade de nichos e a eficiência na retenção de biomassa. Operacionalmente, o CRI foi derivado a partir do desvio padrão das alturas dos pontos LiDAR situados acima do limiar de 5 metros, utilizando essa dispersão como um *proxy* para a rugosidade estrutural da vegetação (HARDIMAN et al., 2013; SENF et al., 2020).

A análise conjunta da cobertura e da rugosidade permite uma interpretação robusta da dinâmica sucessional das parcelas. Enquanto a cobertura (CC) fornece uma medida de densidade horizontal, a rugosidade (CRI) captura a "rugosidade" da superfície superior, refletindo a coexistência de árvores de diferentes estratos e tamanhos de copa. Áreas com alta rugosidade e cobertura consolidada sugerem ecossistemas mais resilientes e estruturalmente diversos, ao passo que dosséis com baixa rugosidade e alta cobertura indicam povoamentos mais homogêneos e simplificados, como reflorestamentos ou estágios médios de sucessão com dominância de poucas espécies (HARDIMAN et al., 2013; FAGUA et al., 2021).

3.2.4.4. Simulação de Dados *Full-Waveform* a Partir de UAV-LiDAR

A simulação de sinais *Full-Waveform* (FWF) foi adotada para transpor as limitações dos sistemas de retorno discreto, permitindo a análise da distribuição contínua da energia refletida ao longo do perfil vertical da vegetação. Embora o sensor LiAir V capture retornos discretos, a densidade de pontos obtida via UAV-LiDAR possibilita a reconstrução da forma de onda, assemelhando-se aos dados gerados por sensores de grande pegada (*large footprint*), como o sistema GEDI (*Global Ecosystem Dynamics Investigation*) (DUBAYAH et al., 2020; JACON et al., 2024) (Figura 4).




Figura 4. Dados discretos x Dados FWF Simulados.

O processamento foi realizado no ambiente R, utilizando a integração dos pacotes *rGEDI* (Silva et al., 2019) e *rGEDIsimulator* (HANCOCK et al., 2019). O procedimento consistiu na simulação de *footprints* circulares de 20 metros de diâmetro, posicionados de forma a coincidir com o centro geográfico de cada unidade amostral. Para garantir a fidelidade da resposta espectral simulada, utilizou-se a nuvem de pontos original (não normalizada), permitindo que o algoritmo identificasse o retorno do solo e a estrutura do dossel em sua cota altimétrica real, conforme recomendado para simulações de trajetória de feixe *laser* (SILVA et al., 2022).

O fluxo metodológico de simulação seguiu quatro etapas sistematizadas:

1. Filtragem e Preparação: Leitura dos arquivos em formato ".las" e remoção de ruídos espúrios abaixo do nível do solo;
2. Espacialização: Recorte das nuvens de pontos correspondentes aos limites dos *footprints* de 20 metros;
3. Geração da Forma de Onda: Aplicação da função *gediWFSimulator()*, que emula o sinal de retorno contínuo e armazena os dados em formato hierárquico .h5;
4. Extração de Métricas: Processamento dos arquivos .h5 pela função *gediWFMetrics()* para a derivação de descritores estruturais e biofísicos.

As métricas extraídas foram consolidadas em grupos funcionais para posterior análise discriminante dos estágios sucessionais:

1. Métricas de Energia e Perfil Vertical: Indicadores de altura absoluta e limites do sinal, como *trueTop*, *gHeight*, *maxGround*, *signalTop* e *signalBottom*.
2. Percentis de Distribuição (*rhGauss*): Valores de altura relativa (RH) em que determinadas porcentagens da energia acumulada de retorno são atingidas, extraídos de *rhGauss0* a *rhGauss100* em intervalos de 5%.
3. Parâmetros Morfológicos e de Densidade: Variáveis que descrevem a forma da onda e o fechamento do dossel, incluindo *leadingEdgeExt*, *trailingEdgeExt*, *cover*, *gaussHalfCov* e *blairSense*.
4. Índices de Diversidade e Estrutura Foliar: Métricas complexas como a Diversidade da Altura da Folhagem (*Foliage Height Diversity* - FHD) e estimativas segmentadas de área foliar em estratos específicos, como *gLAI0t10* (0–10 m) e *gLAI10t20* (10–20 m) (JACON et al., 2024).

5. Variáveis Espectrais Avançadas: Indicadores de rugosidade e organização da onda, como a Razão de Retorno do Dossel (*CRR*), *Peak End* e Variância da Elevação da Forma de Onda (*HFEV*).

3.2.4.5. Análise Gráfica e Espacial da Estrutura Vertical (Voxelização e Curvas de Perfil)

Para validar e interpretar os padrões de estratificação identificados, aplicou-se uma abordagem complementar baseada na voxelização tridimensional e na análise de perfis verticais de energia. A voxelização consistiu na discretização da nuvem de pontos UAV-LiDAR em unidades volumétricas regulares (*voxels*) de 1 m³, utilizando a elevação original dos dados para mapear a ocupação do espaço real. Esta técnica permitiu a quantificação da densidade de retornos em camadas específicas, facilitando a identificação de lacunas estruturais (*gaps*) e a continuidade da biomassa, elementos críticos para distinguir florestas em regeneração inicial de estágios avançados (VIRIEUX et al., 2009; ALMEIDA, 2019).

Paralelamente, as curvas de perfil vertical foram geradas a partir do sinal contínuo simulado pela função *gediWFSimulator()*. Esses perfis representam a assinatura espectral vertical de cada parcela, ilustrando a intensidade da energia refletida em função da altura.

A integração entre a densidade volumétrica (*voxels*) e a resposta energética (FWF) proporciona uma base robusta para a validação cruzada dos dados estruturais (HAMAMURA, 2023). Enquanto a voxelização detalha a distribuição física dos pontos, as curvas de forma de onda sintetizam a complexidade da arquitetura da floresta, permitindo a observação direta da transição entre os estratos e a confirmação dos níveis de maturidade sucessional observados em campo.

3.2.5. Estruturação das Matrizes Preditoras e Consolidação do Banco de Dados

A consolidação das métricas estruturais e espectrais culminou na estruturação de matrizes de dados preditoras, organizadas para subsidiar os modelos de classificação e as análises multivariadas. Esta etapa foi delineada para permitir uma avaliação comparativa da sensibilidade dos diferentes fluxos de processamento (retorno discreto *versus* sinal simulado) na discriminação dos estágios sucessionais. A integração buscou explorar a complementaridade entre descritores geométricos,

derivados da nuvem de pontos, e indicadores energéticos, provenientes da simulação *Full-Waveform*, assegurando uma caracterização holística da arquitetura da Floresta Ombrófila Mista (ATKINS et al., 2023; JACON et al., 2024).

Para fins analíticos e de validação dos modelos de aprendizado de máquina, o banco de dados foi estratificado em três cenários de modelagem:

- (i) matriz de variáveis discretas, composta por métricas de altura, densidade e complexidade extraídas via pacote *lidR*;
- (ii) matriz de variáveis simuladas (FWF), contendo os perfis de energia, percentis de Gauss e indicadores morfológicos da onda obtidos pelo rGEDI; e
- (iii) matriz integrada, que combina a totalidade dos descritores estruturais e espectrais. Essa abordagem de partição de dados é essencial para identificar quais atributos possuem maior importância relativa na predição dos estágios de sucessão, permitindo isolar o potencial explicativo da geometria tridimensional em relação à resposta biofísica do sinal contínuo (ALMEIDA et al., 2019).

3.2.6. Análise Exploratória e Estatística Multivariada

A etapa analítica foi delineada para converter a complexidade tridimensional das nuvens de pontos em indicadores biológicos de sucessão. O fluxo seguiu uma progressão lógica, iniciando pela validação de pressupostos, seguida pela redução de redundância e culminando na identificação de gradientes ecológicos. Todas as análises foram conduzidas comparativamente para as três matrizes de dados: métricas de retorno discreto, métricas de simulação FWF e o conjunto híbrido (integrado).

3.2.6.1. Caracterização Estrutural e Pressupostos Estatísticos

A caracterização inicial dos estágios sucessionais baseou-se em estatísticas descritivas (média, mediana, desvio padrão e quartis) para todas as variáveis LiDAR. A normalidade das distribuições foi testada pelo critério de Shapiro-Wilk, enquanto a homogeneidade de variância foi avaliada pelo teste de Levene. Para métricas que apresentaram desvios significativos de normalidade ou alta curtose, aplicou-se a Transformação Normal Inversa Baseada em Ranks (RIN) para estabilizar as

variâncias antes da aplicação de testes paramétricos (BISHARA & HITTNER, 2012).

A exploração visual da heterogeneidade interna das parcelas foi realizada através de *Violin Plots*, que integram a densidade probabilística aos quartis dos *Boxplots* (HINTZE & NELSON, 1998). Esta abordagem permitiu detectar nuances na estratificação vertical e bimodalidades na distribuição de biomassa, fundamentando a interpretação ecológica dos picos de energia capturados pela simulação FWF.

3.2.6.2. Análise de Redundância e Seleção de Métricas

Complementarmente, realizou-se uma análise de correlação entre as métricas LiDAR para identificar redundâncias e avaliar a interdependência entre as variáveis. A multicolinearidade entre as métricas foi avaliada para quantificar o grau de interdependência e informar a seleção de um subconjunto de variáveis para modelagem posterior, visando a construção de modelos mais robustos e parcimoniosos.

3.2.6.3. Ordenação e Separabilidade dos Estágios Sucessionais

A identificação de padrões multivariados e gradientes ecológicos foi conduzida por meio de técnicas de ordenação complementares:

1. Análise de Componentes Principais (PCA): Utilizada para reduzir a dimensionalidade e identificar as métricas que explicam a maior variância estrutural. A retenção dos componentes foi validada pelo teste de Broken Stick e pelo critério de Kaiser (autovalores > 1).
2. Escalonamento Multidimensional Não-Métrico (NMDS): Aplicado para visualizar a similaridade entre as parcelas sem pressupostos de linearidade, utilizando a distância Euclidiana. A qualidade da representação foi monitorada pelo Stress de Kruskal (CLARKE, 1993). A significância estatística da separação entre os estágios foi testada via PERMANOVA.

3.2.6.4. Modelagem Preditiva e Classificação Automatizada

A fase final de modelagem visou testar a eficácia das métricas LiDAR na predição automatizada dos estágios sucessionais por meio do *algoritmo Random Forest* (RF). Este método foi selecionado por sua robustez em lidar com dados de alta

dimensionalidade e relações não-lineares complexas em ecossistemas heterogêneos.

3.2.6.4.1. Treinamento e Otimização do Algoritmo

A estratégia de validação adotada foi o *Leave-One-Out* (LOOCV) por parcela, garantindo que cada unidade amostral fosse utilizada para teste em um cenário de aplicação realista (VALBUENA et al., 2017). A otimização dos hiperparâmetros (*n*tree, *m*try e *nodesize*) foi realizada via *grid search* com validação cruzada no pacote *caret*, buscando minimizar o erro de classificação sem incorrer em *overfitting*.

3.2.6.4.2. Avaliação de Desempenho e Importância de Variáveis

O desempenho dos modelos foi avaliado de forma multidimensional:

- Métricas Globais: Acurácia Global, Estatística Kappa e Área sob a Curva ROC (AUC).
- Métricas por Estágio: Precisão, *Recall* e *F1-Score*, cruciais para detectar confusões entre estágios adjacentes (ex: Médio vs. Avançado).
- Significância: O teste de McNemar foi aplicado para comparar a acurácia entre as abordagens de retorno discreto e simulação FWF.

A interpretação biológica do modelo baseou-se na medida de *Mean Decrease in Accuracy* (MDA). Esta métrica de importância permitiu ranquear quais atributos estruturais (ex: rugosidade do dossel, densidade foliar ou percentis de energia) são os reais indicadores-chave da transição sucessional na Floresta Ombrófila Mista, fornecendo subsídios para o aprimoramento de normas ambientais (ex: Resolução CONAMA).

3.3. RESULTADOS

3.3.1. Características da Vegetação com base no Inventário Florestal

No levantamento das 30 parcelas amostrais na Floresta Ombrófila Mista (FOM), foram registrados 666 indivíduos arbóreos vivos, distribuídos em 72 espécies, 50 gêneros e 33 famílias botânicas. A concentração da abundância em um grupo de 15 famílias, que responderam por 85% do total, evidencia uma estrutura de dominância comum em florestas tropicais e subtropicais, onde poucas linhagens taxonômicas moldam a arquitetura da comunidade (OLIVEIRA-FILHO & FONTES, 2000).

A elevada representatividade de Rubiaceae, Salicaceae, Myrtaceae, Podocarpaceae, Lauraceae, Primulaceae e Sapindaceae reflete um mosaico estrutural típico de florestas em processo de regeneração. Famílias como Rubiaceae e Myrtaceae apresentam frequências elevadas e representam à sua adaptação a sub-bosques sombreados e à sua resiliência em ambientes com histórico de perturbação moderada (BUDKE & JARENKOW, 2010).

Enquanto Rubiaceae frequentemente ocupa estratos inferiores com alta densidade de indivíduos, as famílias Lauraceae e Sapindaceae atuam como grupos estruturantes do dossel superior, sendo recorrentemente destacadas como componentes fundamentais da integridade biótica da FOM (KOEHLER et al., 2002; LIEBSCH et al., 2009). A densidade média registrada de 2.220 indivíduos por hectare é compatível com os valores observados em áreas de floresta secundária na Mata Atlântica. Segundo Tabarelli et al. (2010), florestas em estágios intermediários tendem a exibir densidades elevadas devido ao predomínio de espécies de crescimento rápido que competem intensamente por espaço e luz.

Arroyo-Rodríguez et al. (2017) destacam que padrões estruturais em florestas secundárias de paisagens tropicais modificadas podem variar amplamente, refletindo múltiplos caminhos de sucessão. Nesse sentido, uma alta densidade pode estar associada à predominância de indivíduos jovens e a uma menor área basal individual média, mas sua interpretação depende da interação entre recursos limitantes e fatores em diferentes escalas, como o histórico de uso, as condições locais do sítio e o contexto de paisagem (cobertura florestal, conectividade e distúrbios crônicos). Assim, a densidade pode sinalizar um momento de reorganização estrutural, porém sem implicar uma trajetória única rumo a um estado “maduro” padronizado.

A mortalidade registrada de 46 indivíduos (6,9% do total) representa um

indicador crítico da dinâmica sucessional e da estabilidade do fragmento. Este valor é relativamente elevado quando contrastado com áreas de estrutura mais estável, como a FLONA de Irati, onde Figueiredo Filho et al. (2010) registraram taxas anuais de apenas 1,77% a 2% em florestas maduras. Essa discrepância sugere que a área de estudo pode estar sob influência de distúrbios externos ou efeitos de borda, que aumentam a vulnerabilidade das árvores a estresses mecânicos (vento) e térmicos (dessecação do sub-bosque), conforme discutido por (LAURANCE et al., 2011).

Contudo, sob a perspectiva da sucessão ecológica, essa mortalidade não deve ser vista apenas como perda de biomassa, mas como um mecanismo de promoção da heterogeneidade. Magnago et al. (2015) destacam que a queda de indivíduos senescentes cria clareiras que favorecem o recrutamento de espécies tolerantes à sombra e aceleram a ciclagem de nutrientes. Essa substituição contínua de indivíduos e a criação de novos nichos são fundamentais para a diversidade funcional e para a estabilidade climática da floresta ao longo do tempo. Assim, a estrutura observada reflete um ecossistema resiliente, capaz de manter processos ecológicos essenciais mesmo diante de pressões ambientais moderadas.

3.3.2. Variáveis Dendrométricas Calculadas

Na tabela 1 estão apresentadas de forma sumária as variáveis dendrométricas obtidas pelo processamento do inventário florestal realizado na área em questão, referente às 30 parcelas.

Tabela 1. Variáveis dendrométricas do inventário florestal tradicional e calculadas para cada uma das 30 parcelas amostradas.

Parcela	G	ht	dap	dqm	htvar	...	n_pioneiras	n_ao_pioneiras	n_facultativas	n_total_Arvores	ISF
1	35,95	8,10	15,76	17,46	8,99	...	8,00	5,00	0,00	15,00	0,38
2	28,46	7,60	14,54	17,37	5,39	...	8,00	3,00	1,00	12,00	0,33
3	48,60	6,00	13,30	16,77	4,90	...	7,00	9,00	6,00	22,00	0,68
4	82,85	6,79	19,81	27,45	9,53	...	2,00	6,00	5,00	14,00	0,85
5	45,05	5,85	13,73	17,38	3,85	...	2,00	14,00	3,00	19,00	0,89
6	45,49	7,44	13,84	16,23	6,45	...	6,00	13,00	3,00	22,00	0,73
7	60,72	6,98	17,45	21,98	10,47	...	11,00	3,00	2,00	16,00	0,31
8	164,39	8,78	25,08	36,17	12,05	...	4,00	10,00	2,00	16,00	0,75
9	29,47	7,76	12,91	15,31	12,20	...	10,00	3,00	2,00	16,00	0,33
10	135,00	8,57	18,26	24,35	15,10	...	15,00	12,00	0,00	29,00	0,44
11	122,83	7,38	17,41	29,48	18,93	...	4,00	10,00	2,00	18,00	0,75
12	33,68	7,81	12,79	15,43	11,15	...	8,00	5,00	1,00	18,00	0,43
13	21,42	7,42	9,99	12,31	3,48	...	11,00	5,00	2,00	18,00	0,39
14	14,53	8,18	9,79	10,43	7,15	...	11,00	4,00	1,00	17,00	0,31
15	22,20	7,31	9,04	10,85	10,78	...	10,00	10,00	2,00	24,00	0,55
16	42,94	9,80	14,43	15,76	7,40	...	9,00	6,00	5,00	22,00	0,55
17	9,53	7,55	7,64	7,99	1,64	...	13,00	2,00	3,00	19,00	0,28
18	34,14	8,16	10,92	13,19	8,49	...	8,00	12,00	1,00	25,00	0,62
19	42,04	10,90	12,76	14,93	28,85	...	10,00	9,00	0,00	24,00	0,47
20	35,61	8,66	12,27	15,45	17,75	...	14,00	0,00	3,00	19,00	0,18
21	55,18	11,05	12,79	15,30	23,83	...	11,00	13,00	3,00	30,00	0,59
22	90,84	10,46	18,89	24,05	25,77	...	4,00	10,00	3,00	20,00	0,76
23	31,88	10,00	10,99	12,49	14,88	...	8,00	14,00	1,00	26,00	0,65
24	85,68	9,20	13,74	19,07	26,65	...	8,00	17,00	2,00	30,00	0,70
25	89,81	11,19	16,44	19,86	26,45	...	5,00	7,00	16,00	29,00	0,82
26	68,96	8,85	11,03	15,62	20,23	...	8,00	17,00	10,00	36,00	0,77
27	25,50	8,10	8,92	11,17	16,64	...	2,00	16,00	8,00	26,00	0,92
28	36,37	11,48	10,99	12,42	16,35	...	7,00	11,00	12,00	30,00	0,77
29	61,79	8,35	12,98	18,10	12,75	...	7,00	12,00	3,00	24,00	0,68
30	70,28	8,95	12,81	17,27	9,94	...	9,00	11,00	8,00	30,00	0,68

Onde: G = área basal (m²/ha), ht = altura média (m), dap = diâmetro médio (cm), dqm = diâmetro quadrático médio, htvar = variância das alturas, n_pioneiras = número de pioneiras por parcela, n_ao_pioneiras = número de árvores não pioneiras por parcela, n_facultativas = número de árvores facultativas por parcela, n_total_Arvores = número total de árvores por parcela, ISF = índice de sucessão florestal.

Por meio da tabela 2, é possível observar os dados médios entre as parcelas amostradas das variáveis diâmetro, altura e área basal.

Tabela 2. Valores Mínimos, médios e máximos de variáveis chave.

Parcela	DAP Max	DAP Med	DAP Min	Alt MAX	Alt MED	Alt Min	G MAX	G MED	G MIN	n ind
1	36,76	15,76	6,14	14,30	8,10	3,80	35,95	35,95	35,95	15
2	38,83	14,55	5,60	12,90	7,60	3,00	28,46	28,46	28,46	12
3	42,34	13,30	5,09	11,20	6,00	3,70	82,85	54,34	45,05	22
4	84,03	19,81	6,49	15,90	6,79	3,00	45,05	22,74	14,53	14
5	52,20	13,73	5,03	8,90	5,85	2,50	42,94	28,75	22,20	19
6	40,27	13,84	5,03	12,80	7,44	3,10	42,94	33,83	9,53	22
7	59,21	17,45	5,73	14,50	6,98	2,50	34,14	14,15	9,53	16
8	88,17	25,08	5,06	20,00	8,78	5,50	34,14	34,14	34,14	16
9	36,06	12,91	5,41	16,00	7,76	2,90	42,04	39,57	34,14	16
10	78,94	18,26	5,28	20,00	8,57	4,00	55,18	46,40	35,61	29
11	97,72	17,41	0,76	20,00	7,38	2,00	82,85	67,43	45,05	18
12	39,15	12,79	5,00	16,50	7,81	4,00	45,49	45,15	45,05	18
13	35,58	9,99	5,41	11,00	7,42	4,50	45,49	45,49	45,49	18
14	20,85	9,79	5,41	13,00	8,18	5,00	164,39	66,82	60,72	17
15	31,19	9,04	5,06	17,00	7,31	2,00	164,39	113,80	29,47	24
16	27,69	14,43	5,09	15,00	9,80	4,00	135,00	101,42	29,47	22
17	14,16	7,64	5,09	11,00	7,55	6,00	135,00	131,80	122,83	19
18	29,60	10,92	5,09	16,00	8,16	4,50	122,83	80,04	33,68	25
19	33,51	12,76	5,25	20,00	10,90	4,00	42,04	20,22	14,53	24
20	43,93	12,27	5,03	16,00	8,66	4,00	33,68	25,29	21,42	19
21	42,96	12,79	5,03	21,00	11,05	5,00	90,84	56,53	35,61	30
22	69,02	18,89	5,09	18,00	10,46	2,20	90,84	61,36	31,88	20
23	27,37	10,99	4,77	16,00	10,00	3,00	90,84	43,44	31,88	26
24	73,83	13,74	5,06	24,00	9,20	3,50	70,28	56,14	36,37	30
25	43,99	16,44	5,03	20,00	11,19	4,50	89,81	64,34	25,50	29
26	55,76	11,03	3,12	20,00	8,85	3,00	89,81	80,43	68,96	36
27	35,04	8,92	5,25	20,00	8,10	3,50	89,81	86,64	85,68	26
28	28,65	10,99	5,03	18,00	11,48	3,00	89,81	56,17	25,50	30
29	67,80	12,98	3,18	20,00	8,35	4,00	70,28	43,59	25,50	24
30	62,01	12,81	5,03	16,00	8,95	4,00	70,28	52,44	25,50	30

Onde: DAP: diâmetro à altura do peito; Alt: altura; G: área basal em m²/ha; n_ind: número de indivíduos por parcela; Max: máximo; Min: Mínimo; Med: Médio

3.3.3. Aplicação da PCA e Identificação dos Componentes Principais Para as Variáveis Dendrométricas.

A Análise de Componentes Principais (PCA) foi empregada com o objetivo de sintetizar a variabilidade estrutural da vegetação em 30 parcelas amostradas na Floresta Ombrófila Mista (FOM), buscando identificar padrões relacionados aos estágios sucessionais a partir de 27 variáveis dendrométricas. Para assegurar a comparabilidade e equalizar o peso de variáveis mensuradas em diferentes unidades e escalas, todas as variáveis foram previamente submetidas à padronização *Z-score* (JOLLIFFE & CADIMA, 2016).

Ao analisar os autovalores e o *scree plot* (Figura 5) foi possível inferir a decisão de reter os três primeiros componentes principais (PC1, PC2 e PC3), os quais, em conjunto, foram responsáveis por 71,49% da variância total dos dados. Este valor superou o limiar mínimo de 70% estabelecido na metodologia (HAIR et al., 2014). Detalhadamente, o PC1, com um autovalor de 10,11, explicou 38,72% da variância, seguido pelo PC2, com autovalor de 4,94, que contribuiu com 18,93% da variância, e pelo PC3, com autovalor de 3,61, responsável por 13,84% da variância total. A retenção desses três componentes também foi corroborada pelo critério de Kaiser, que considera autovalores superiores a 1.

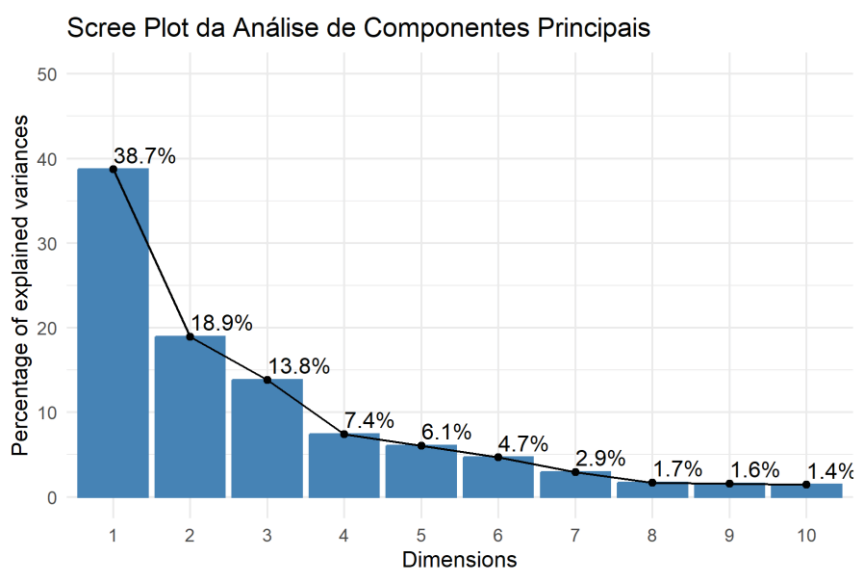


Figura 5. *Scree plot* da PCA.

Por meio do *biplot* da PCA (Figura 6) foi possível visualizar a abrangência da interrelação entre as parcelas, as variáveis dendrométricas e os clusters posteriormente definidos pela Classificação Hierárquica Ascendente (CHA),

evidenciando os principais gradientes estruturais.

A interpretação dos componentes principais, fundamentada nas coordenadas e contribuições das variáveis, revelou que o PC1, responsável pela maior proporção da variância, demonstrou forte correlação positiva com variáveis associadas à estrutura vertical da vegetação e à complexidade do dossel.

Variáveis como altura média (ht, coordenada: 0,75; contribuição: 5,56%), altura dominante (htdom, coordenada: 0,88; contribuição: 7,72%), altura máxima (htmax, coordenada: 0,90; contribuição: 8,03%), altura no percentil 95 (P95, coordenada: 0,90; contribuição: 8,02%), variância de altura (htvar, coordenada: 0,89; contribuição: 7,88%) e desvio padrão de altura (htsd, coordenada: 0,90; contribuição: 8,02%) apresentaram elevadas coordenadas e contribuições significativas. Conseqüentemente, este componente representa um gradiente de desenvolvimento arbóreo e fechamento do dossel, refletindo a progressão sucessional em termos de biomassa e estatura.

Por sua vez, o PC2 associou-se fortemente a variáveis relacionadas à área basal e ao diâmetro da vegetação. Variáveis como área basal (G, coordenada: 0,77; contribuição: 11,97%), diâmetro médio (dap, coordenada: 0,83; contribuição: 13,99%), diâmetro quadrático médio (DQM, coordenada: 0,90; contribuição: 16,52%) e coeficiente de variação do diâmetro (dapcv, coordenada: 0,74; contribuição: 11,20%) exibiram as maiores coordenadas e contribuições. Este componente, portanto, refletiu um gradiente de massa vegetal e variabilidade diamétrica.

O PC3, por fim, relacionou-se predominantemente com variáveis de diversidade e riqueza de espécies e famílias. Índices como o de Shannon (H, coordenada: 0,61; contribuição: 10,19%) e de Pielou (J, coordenada: 0,56; contribuição: 8,67%), bem como o número de espécies (nespecie, coordenada: 0,57; contribuição: 8,97%) e o número de famílias (nfamilia, coordenada: 0,59; contribuição: 9,61%), foram os que mais contribuíram para este componente, indicando sua representatividade na dimensão da biodiversidade.

Por meio do *biplot*, foi possível identificar as tendências de agrupamento resultantes da CHA. As parcelas do Cluster 4 (ex: 10, 19, 21, 22, 24, 25, 26, 28) situaram-se predominantemente na porção direita do *biplot*, apresentando associação positiva com o PC1. Este posicionamento indica as maiores alturas e maior complexidade vertical, com médias para ht (10,21 m), htmax (20,12 m), P95 (18,49 m) e ntotal (28,5 indivíduos), características de florestas com maior grau de

desenvolvimento e estratificação do dossel. Adicionalmente, este cluster também exibiu altas médias para H (2,35), nespecie (13) e nfamilia (10,38), apontando para uma maior diversidade (figura 6).

Tais padrões refletem remanescentes florestais em fase avançada de desenvolvimento, caracterizados por uma estrutura mais complexa, estratificação do dossel e predominância de espécies tolerantes à sombra, típicas de comunidades clímax da FOM (CHAZDON, 2014; NORDEN et al., 2015).

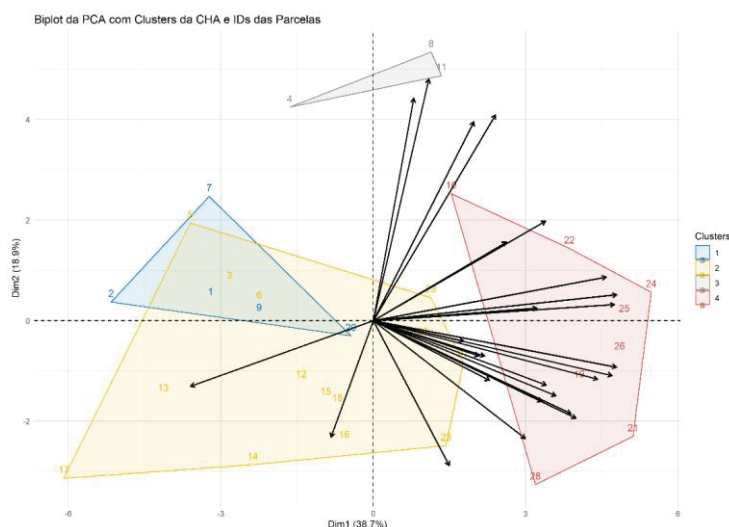


Figura 6. Gráfico do tipo *biplot* da PCA.

Em contraste, as parcelas do Cluster 1 (ex: 1, 2, 7, 9, 20) posicionaram-se na porção oposta do *biplot*, associadas a menores valores de PC1, indicando um menor desenvolvimento vertical. Este cluster apresentou as menores médias para ht (7,82 m), htmax (14,74 m) e G (38,04 m²/ha), além de menor diversidade. Tais características são consistentes com padrões de florestas mais jovens, em fase inicial de desenvolvimento, com dinâmica sucessional ativa.

Parcelas posicionadas na porção esquerda do gráfico, como 5, 7, 13, 14 e 17, apresentaram forte associação com padrões indicativos de florestas mais jovens, em fase inicial de desenvolvimento. Estas parcelas correlacionaram-se positivamente com maior número de espécies pioneiras (*n_pioneiras*) e presença de árvores mortas (*Arvores_mortas*), sugerindo ambientes em processo de estabelecimento com dinâmica sucessional ativa. Tais características são típicas de áreas recém habitadas ou sob influência de distúrbios, onde espécies de rápido crescimento dominam e a competição por luz é intensa, resultando em alta mortalidade e heterogeneidade estrutural (CHAZDON et al., 2016).

O Cluster 2 (3, 5, 6, 12, 13, 14, 15, 16, 17, 18, 23, 27, 29, 30), o maior agrupamento, ocupou uma posição intermediária no *biplot*, com características de transição. Suas médias para altura e área basal foram similares ou ligeiramente superiores ao Cluster 1, mas com maior diversidade (H média: 2,20; J média: 0,91). Este cluster ajuda a inferir que são áreas em processo de maturação estrutural, onde a comunidade florestal ainda não atingiu a complexidade e estratificação dos estágios mais avançados.

Um aspecto particular foi observado no Cluster 3 (parcelas 4, 8, 11). Embora suas parcelas estivessem associadas a altas coordenadas no PC2 (gradiente de área basal e diâmetro), com as maiores médias para G (123,36 m²/ha) e DQM (31,03 cm), suas médias de altura (ht média: 7,65 m) não foram as mais elevadas.

Esta combinação de alta massa vegetal diamétrica com menor estatura vertical é um indicativo de que este cluster é fortemente influenciado pela presença de poucas árvores de grande porte, como araucárias, que, embora contribuam significativamente para a área basal e diâmetro, não representam um dossel homogêneo e desenvolvido em toda a parcela. Essa particularidade é crucial na interpretação de diferentes estágios sucessionais, pois a alta biomassa não reflete necessariamente um estágio avançado de sucessão em termos de complexidade estrutural geral.

Quanto a Classificação Hierárquica Ascendente (CHA) foi então realizada utilizando o método de *Ward*, com base nos escores fatoriais das parcelas nos componentes principais retidos. O dendrograma resultante (Figura 7) permitiu a segmentação das parcelas em quatro grupos distintos.

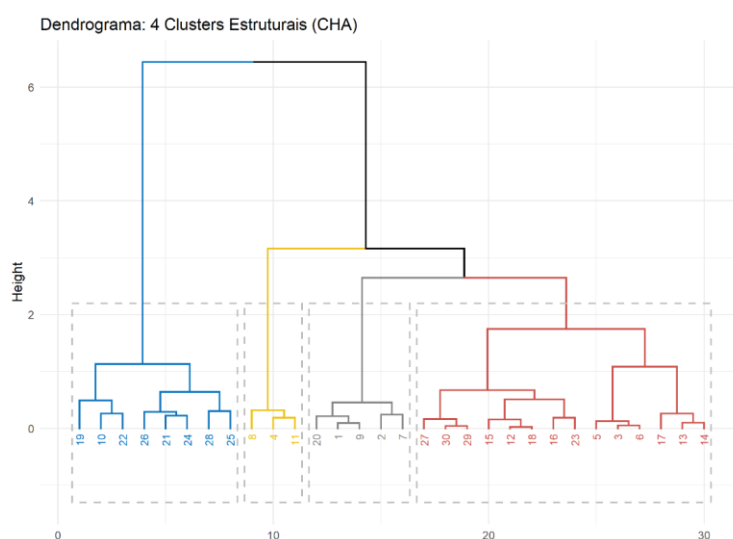


Figura 7. Dendrograma da Classificação Hierárquica Ascendente (CHA)

3.3.3.1. Validação Estatística dos Agrupamentos

A decisão de reter os agrupamentos foi fundamentada na inspeção visual do dendrograma, considerando tanto a separabilidade estatística quanto a coerência ecológica. Os clusters resultantes correspondem aos estágios sucessionais reconhecidos na literatura para a Floresta Ombrófila Mista: Inicial (I), Médio (M) e Avançado (A) (CHAZDON, 2014; NORDEN et al., 2015).

A validação estatística dos agrupamentos identificados pela análise multivariada foi conduzida por meio de testes de hipóteses, precedidos pela verificação de normalidade, visando assegurar a robustez e a confiabilidade dos resultados. O teste de Shapiro-Wilk revelou que 19 das 27 variáveis analisadas (70,37%) apresentaram distribuição normal ($p > 0,05$), enquanto as 8 variáveis restantes (29,63%) não seguiram esse pressuposto.


Essa proporção de variáveis com distribuição não normal é consistente com padrões frequentemente observados em dados ecológicos, onde processos biológicos complexos e a heterogeneidade ambiental podem resultar em distribuições assimétricas (LEGENDRE, 2012). Em função dos resultados dos testes de normalidade, foram aplicados métodos estatísticos apropriados: a Análise de Variância (ANOVA) foi utilizada para as variáveis que atenderam aos pressupostos de normalidade, enquanto o teste não paramétrico de Kruskal-Wallis foi empregado para as variáveis com distribuição não normal.

A análise identificou diferenças estatisticamente significativas ($p < 0,05$) entre os agrupamentos para 23 das 27 variáveis analisadas, o que corresponde a aproximadamente 85% do total. Este resultado ajuda a inferir que os quatro clusters formados são estruturalmente distintos e bem diferenciados. As variáveis que se mostraram mais discriminantes, apresentando *p-valor* extremamente baixos (muitas com $p < 0,001$), incluíram métricas de altura (como ht, htvar, htstd, htmax, P95, P90), área basal (G), diâmetro (dap, DQM), diversidade (H, J, IU, nespecie, nfamily) e número total de indivíduos (ntotal).

Em contrapartida, variáveis como P25, mortalidade, hM e nfamily não apresentaram diferenças estatisticamente significativas entre os clusters, sugerindo que estas características se apresentaram mais homogêneas entre os agrupamentos ou menos sensíveis para distinguir os estágios sucessionais definidos. A ausência de diferença significativa em mortalidade, por exemplo, pode indicar que a dinâmica de

morte de árvores é similar entre os estágios, refletindo processos ecológicos comuns em florestas secundárias em regeneração.

Os testes post-hoc foram conduzidos de forma apropriada aos resultados de normalidade: para variáveis normais, aplicou-se o teste de Tukey HSD, enquanto para variáveis não normais, utilizou-se o teste de Dunn com correção de Bonferroni. Estes testes permitiram identificar padrões específicos de diferenciação entre os agrupamentos, visualizados nos *Boxplots* comparativos por cluster (Figura 8).



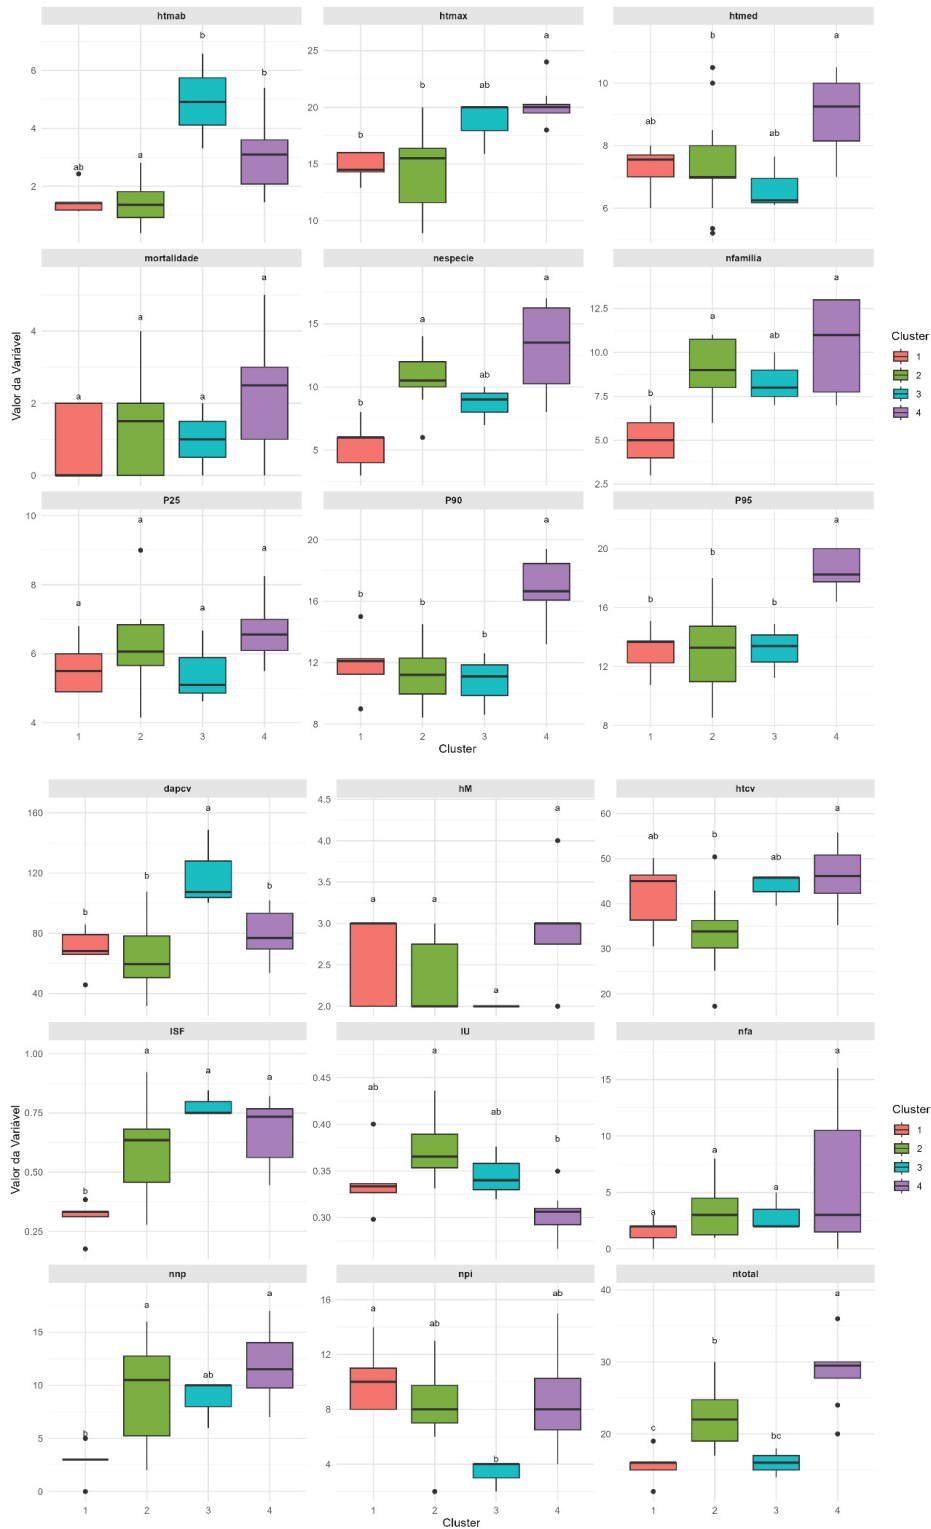


Figura 8. *Boxplots* das variáveis estruturais por cluster. As letras (a, b, c) indicam agrupamentos de significância estatística ($p < 0,05$) obtidos pelos testes post-hoc: Tukey HSD para variáveis com distribuição normal (ANOVA) e Dunn com correção de Bonferroni para variáveis não normais (Kruskal-Wallis). Clusters com a mesma letra não diferem significativamente.

O Cluster 1, demonstrou ser significativamente distinto dos demais para diversas variáveis, apresentando as menores médias para índices de diversidade ($H = 1,85$; $J = 0,68$) e para a maioria das métricas de altura e diâmetro. Por exemplo, para a altura média ($ht = 7,82$ m), o Cluster 1 difere significativamente do Cluster 4 indicando menor estatura ($p < 0,001$). Este padrão é consistente com florestas em fase inicial de regeneração, onde a comunidade é dominada por espécies pioneiras de rápido crescimento, mas ainda não atingiu a complexidade estrutural de estágios mais avançados.

O Cluster 2, o maior agrupamento ($n = 14$ parcelas), posicionou-se de forma intermediária para a maioria das variáveis estruturais. Para altura média ($ht = 8,50$ m), apresentou valores intermediários entre os Clusters 1 e 4, enquanto para diversidade exibiu valores moderados ($H = 2,20$; $J = 0,91$), superiores ao Cluster 1 mas inferiores ao Cluster 4. O mesmo também apresentou a menor área basal ($G = 45,30$ m²/ha), sendo significativamente diferente dos Clusters 3 e 4 para essa métrica ($p < 0,001$). Este padrão sugere uma estrutura florestal em fase de maturação estrutural, onde a comunidade apresenta desenvolvimento vertical moderado e densidade de biomassa reduzida, típico de florestas em transição entre os estágios inicial e avançado.

O Cluster 3, foi particularmente notável por apresentar a maior área basal ($G = 123,36$ m²/ha), sendo significativamente maior que os Clusters 1, 2 e 4 ($p < 0,001$). Contudo, suas métricas de altura média ($ht = 7,65$ m) não foram as mais elevadas, apresentando valores similares aos Clusters 1 e 2. Este padrão estrutural peculiar é explicado pela presença de poucas árvores emergentes de grande porte, particularmente araucárias (*Araucaria angustifolia*), cujos diâmetros podem exceder 1,8 m.

Estas árvores, embora contribuam significativamente para a biomassa total, possuem copas do tipo cálice invertido que ocupam grande parte do espaço horizontal da parcela, enquanto o estrato inferior é composto por numerosas árvores e arbustos de menor porte. Conseqüentemente, a altura média permanece moderada, refletindo a coexistência de poucos indivíduos de grande porte com muitos indivíduos menores. Esta configuração estrutural é característica de florestas em transição ou sob influência de distúrbios seletivos que preservam árvores emergentes de grande porte, mantendo simultaneamente uma regeneração ativa no sub-bosque.

O Cluster 4, exibiu consistentemente as maiores médias para a maioria das variáveis de altura ($ht = 10,21$ m; $htvar = 3,45$; $htsd = 2,89$; $htdom = 11,85$ m; $htmax =$

20,12 m; P95 = 18,49 m; P90 = 17,23 m), sendo estatisticamente superior aos demais clusters para essas métricas. Adicionalmente, apresentou elevados índices de diversidade ($H = 2,35$; $J = 0,92$) e riqueza de espécies ($n_{\text{especie}} = 13$; $n_{\text{familia}} = 10,38$), refletindo uma comunidade florestal complexa e estratificada. Isso corrobora sua caracterização como o estágio mais avançado em termos de desenvolvimento vertical, complexidade estrutural e biodiversidade, alinhando-se aos critérios da Resolução CONAMA nº 002/1994 para florestas em estágio avançado de regeneração.

3.3.4. Comparação com Parâmetros da Resolução CONAMA 02/1994

A classificação dos agrupamentos estruturais identificados pela análise multivariada foi comparada com os critérios estabelecidos pela Resolução CONAMA nº 002/1994, que rege os estágios sucessionais da vegetação secundária no Paraná. Esta análise de aderência foi conduzida considerando parâmetros-chave: número de espécies lenhosas, área basal, altura das espécies lenhosas do dossel e amplitude diamétrica média.

O Cluster 1 (parcelas 1, 2, 7, 9, 20), caracterizado pelas menores médias para a maioria das variáveis estruturais, demonstrou forte aderência aos critérios de Estágio Inicial de Sucessão. Sua média de número de espécies lenhosas ($n_{\text{especie_media}}: 5,4$) enquadra-se no intervalo de 1 a 10 espécies estabelecido pela legislação. A altura média ($ht_media: 7,82$ m) manteve-se abaixo do limite de 10 metros, e a amplitude diamétrica média ($dap_media: 14,58$ cm) aproximou-se do limite de 10 cm especificado, embora ligeiramente superior. A área basal ($G_media: 38,04$ m²/ha) excedeu o limite superior de 20 m²/ha estabelecido para o estágio inicial. Apesar dessa discrepância na área basal, as demais características e as letras de significância reforçam a classificação como estágio inicial.

O Cluster 2 (parcelas 3, 5, 6, 12, 13, 14, 15, 16, 17, 18, 23, 27, 29, 30), apresentou características que o classificam como Estágio Médio de Sucessão. Sua média de número de espécies lenhosas ($n_{\text{especie_media}}: 10,64$) insere-se no intervalo de 5 a 30 espécies. A altura média ($ht_media: 7,92$ m) e a amplitude diamétrica média ($dap_media: 11,51$ cm) estão dentro dos limites de 8 a 17 metros e até 25 cm, respectivamente, para este estágio. A área basal ($G_media = 36,21$ m²/ha) ficou acima da faixa de 20–30 m²/ha prevista para o estágio médio, sugerindo

transição estrutural. Ainda assim, as demais métricas (altura e diâmetro) permanecem compatíveis com o estágio médio. A validação estatística indicou que este cluster, embora intermediário, difere significativamente dos demais, especialmente em termos de área basal em relação ao Cluster 3.

O Cluster 3 (parcelas 4, 8, 11) também foi classificado como Estágio Médio de Sucessão, porém com uma particularidade importante. Sua média de número de espécies lenhosas (*nespecie_media*: 8,67) está dentro do intervalo de 5 a 30 espécies. A altura média (*ht_media*: 7,65 m) e a amplitude diamétrica média (*dap_media*: 20,76 cm) também se aproximam aos critérios de altura (8 a 17 m) e diâmetro (até 25 cm) para o estágio médio. Contudo, a área basal (*G_media*: 123,36 m²/ha) é excepcionalmente elevada, ultrapassando significativamente o limite de 30 m²/ha para o estágio médio e até mesmo o avançado.

Esta área basal inflacionada não reflete um dossel homogêneo e desenvolvido em toda a parcela, mas sim a presença de poucas árvores de grande porte, como araucárias ou outras nativas remanescentes. Essa característica, embora distorça a métrica da área basal, não invalida a classificação como estágio médio, pois as demais variáveis (altura, número de espécies) são consistentes com essa fase, indicando que a comunidade como um todo ainda não atingiu a complexidade estrutural de um estágio avançado (SANQUETTA, 2006).

Por fim, o Cluster 4 (parcelas 10, 19, 21, 22, 24, 25, 26, 28) foi classificado como Estágio Avançado de Sucessão. Este agrupamento apresentou as maiores médias para a maioria das variáveis de altura (*ht_media*: 10,21 m; *htmax_media*: 20,12 m; *P95_media*: 18,49 m). A média de número de espécies lenhosas apresentou (*nespecie_media*: 13) e a amplitude diamétrica média (*dap_media*: 14,36 cm). A área basal (*G_media*: 75,48 m²/ha) também excede o limite de 30 m²/ha. As letras de significância confirmam que este cluster é estatisticamente superior aos demais em diversas métricas de desenvolvimento vertical e diversidade, corroborando sua designação como estágio mais avançado.

Com base na análise integrada dos resultados e na comparação com a Resolução CONAMA nº 002/1994, os clusters foram designados aos seguintes estágios sucessionais: o Cluster 1 será considerado como Estágio Inicial, os Clusters 2 e 3 como Estágio Médio, e o Cluster 4 como Estágio Avançado.

3.3.5. Caracterização Estrutural dos Estágios Sucessionais com Variáveis LiDAR

3.3.5.1. Estatísticas Descritivas e Distribuição das Variáveis

A análise descritiva das métricas LiDAR foi agrupada por estágios sucessionais (Inicial - I, Médio - M, Avançado - A), conforme resultados obtidos por meio das variáveis de inventário florestal. Foi possível observar padrões distintos na estrutura vertical e horizontal da floresta, conforme os três cenários de variáveis (Discreto e *FullWaveform* e dados integrados (Discretos+FWF), assim, foram apresentadas as variáveis com os resultados mais significativos.

3.3.5.1.1. Variáveis discretas

Por meio dos resultados obtidos com as métricas de retorno discreto foi possível verificar uma progressão consistente do desenvolvimento vertical ao longo do gradiente sucessional. Observou-se que a altura máxima (z_{max}) e a altura média (z_{mean}) apresentaram valores crescentes do estágio Inicial (I) para o Avançado (A). Em particular, z_{max} apresentou médias de 16,42 m (I), 19,58 m (M) e 23,23 m (A), enquanto z_{mean} aumentou de 8,28 m (I) para 11,70 m (M) e 13,40 m (A). Esses padrões indicaram um aumento simultâneo da altura do estrato dominante e do nível médio de ocupação vertical com o avanço sucessional. (Figura 9).




Figura 9. Distribuições (violin/box) de z_{max} e z_{mean} por estágio sucessionais (discreto).

Os testes de significância confirmaram a capacidade discriminante de z_{max} entre estágios, com $p = 0,006$. As comparações múltiplas indicaram diferença entre os extremos do gradiente ($A \neq I$), ao passo que o estágio M apresentou sobreposição

parcial com ambos (A a; M ab; I b), sugerindo um estado intermediário em termos de estrutura vertical.

A LAD_mean também se mostrou significativa ($p = 0,007$), com o padrão (I a; M ab; A b), denotando variações no preenchimento volumétrico da folhagem entre estágios (Figura 10). O desvio-padrão das alturas (zsd) não diferiu estatisticamente entre os grupos ($p = 0,112$), ainda que se tenha observado maior média em A (4,80 m) em comparação a M (4,12 m) e I (4,19 m), caracterizando uma tendência não significativa.

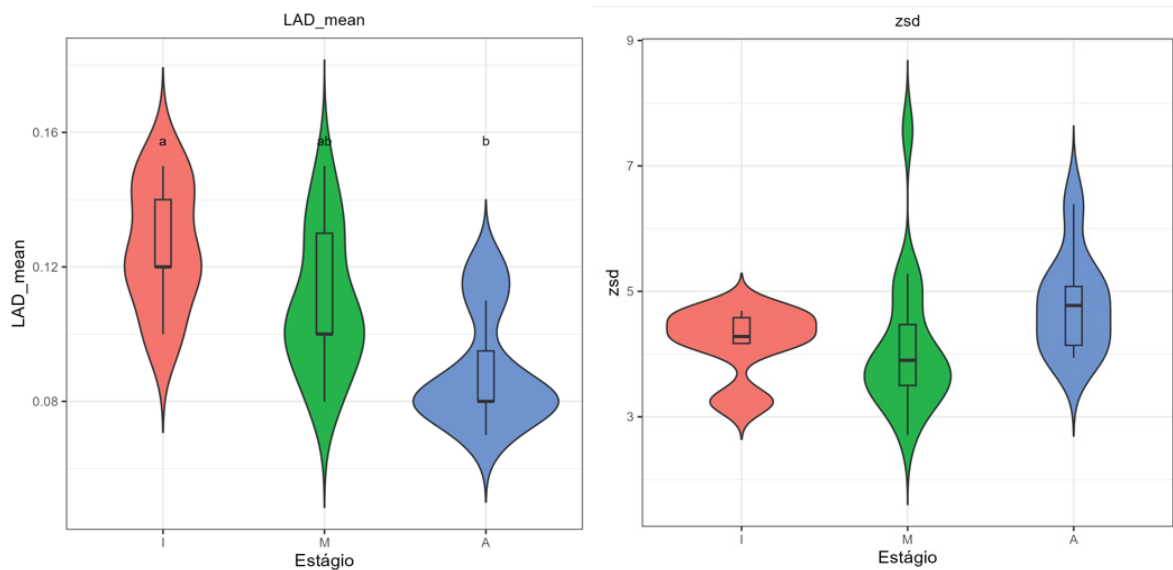



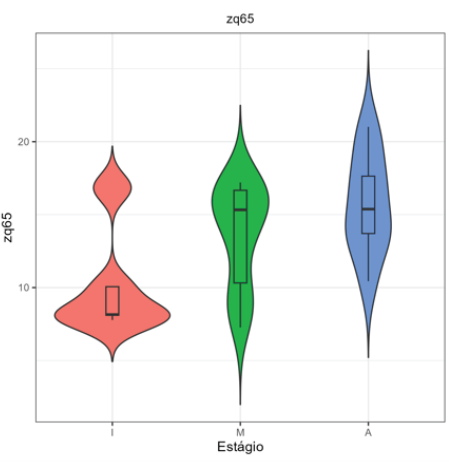







Figura 10. Distribuições (violin/box) de LAD_mean e zsd por estágio (discreto).

As métricas de percentis de altura (zq5 a zq95) ofereceram maior resolução sobre a distribuição vertical. Percentis como zq15, zq35, zq40, zq45, zq50, zq55, zq70, zq75, zq90 e zq95 apresentaram diferenças significativas entre estágios ($p < 0,05$) (Figura 11). Tal resultado foi consistente com a interpretação ecológica de que os percentis inferiores (zq5–zq25) estão associados ao sub-bosque, ao passo que os superiores (zq75–zq99) representam o estrato dominante/emergente, refletindo o adensamento e a verticalização da estrutura com o avanço sucessional.



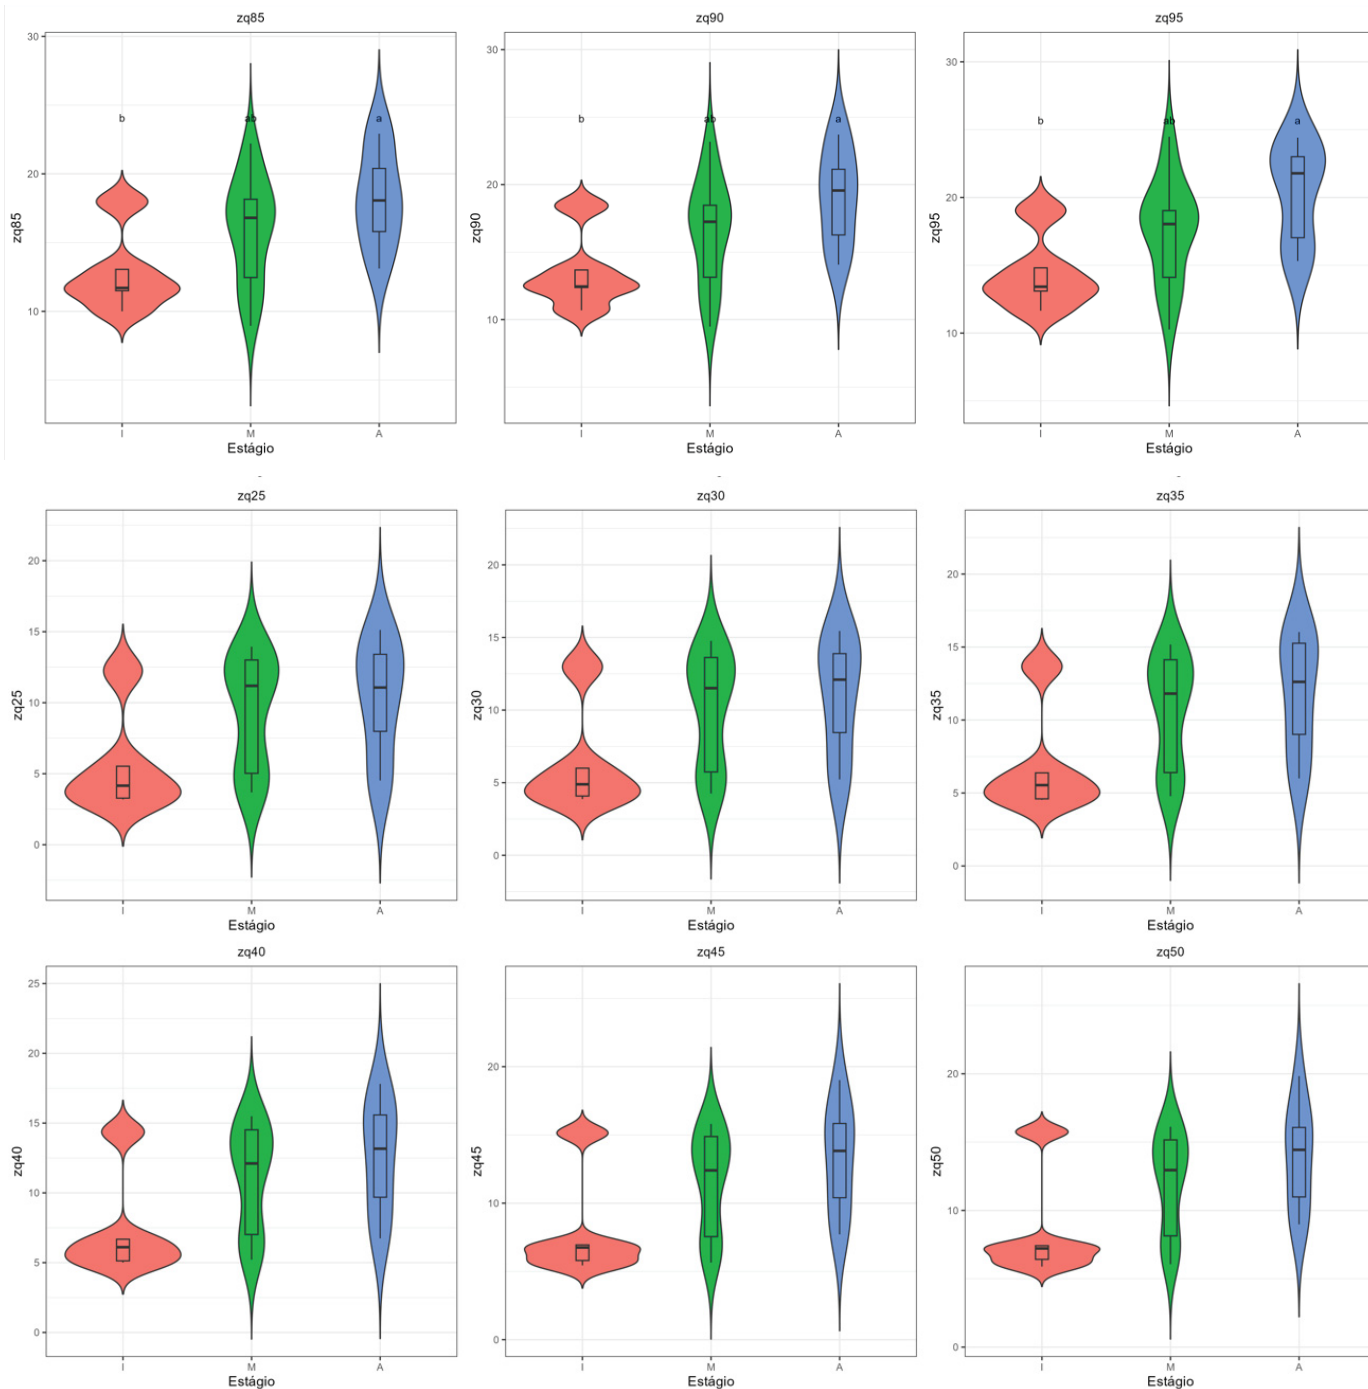


Figura 11. Distribuições (violin/box) de percentis zq por estágio (discreto).

As métricas de forma de distribuição, assimetria (zskew) e curtose (zkurt), não apresentaram diferenças significativas entre estágios ($p = 0,368$ e $p = 0,493$, respectivamente). Ainda assim, verificou-se que os valores médios de zskew foram mais negativos em M ($-0,65$) e A ($-0,41$) do que em I ($-0,37$), o que, em conjunto com os percentis superiores elevados, sugere, de modo cauteloso, maior concentração de biomassa em estratos superiores nos estágios mais desenvolvidos (Figura 12). Essa interpretação foi tratada como indício e não como evidência conclusiva, em

conformidade com a ausência de significância estatística formal para zskew/zkurt.




Figura 12. Distribuições (violin/box) de zskew e zkurt por estágio (discreto).

3.3.5.1.2. Variáveis *Full-Waveform* simuladas

Por meio das métricas derivadas da simulação de *Full-Waveform* foi possível evidenciar diferenças estruturais entre os estágios sucessionais, sobretudo para descritores baseados na distribuição relativa da energia e na complexidade vertical do dossel. Métricas de percentis de energia acumulada (rhGauss), diversidade de altura da folhagem (FHDcanGauss) e área foliar segmentada no estrato intermediário (gLAI10t20) apresentaram diferenças significativas entre estágios, ao passo que descritores em cota absoluta (true.top/signal.top) não diferiram, possivelmente por captarem variação topográfica além da estrutura do dossel (figuras 13 e 14).




Figura 13. Distribuições (violin/box) de métricas FWF simuladas por estágio.




Figura 14. Distribuições (violin/box) de métricas FWF simuladas por estágio.

Quanto aos percentis de energia relativa, foi observada significância ampla em rhGauss.5 – rhGauss.80 , bem como em rhGauss.95 e rhGauss.100 ($p < 0,05$) (Figuras 15 e 16). Em particular, rhGauss.10 apresentou diferença expressiva entre os estágios ($p = 0,005$), com contraste indicando separação do estágio Avançado em relação aos demais (A a; M b; I b). Esse padrão corroborou que a distribuição vertical da energia do retorno, *proxy* da densidade de biomassa por altura, discriminou adequadamente o gradiente sucessional, em consonância com a literatura sobre métricas RH em FWF (p.ex., JACON et al., 2024).

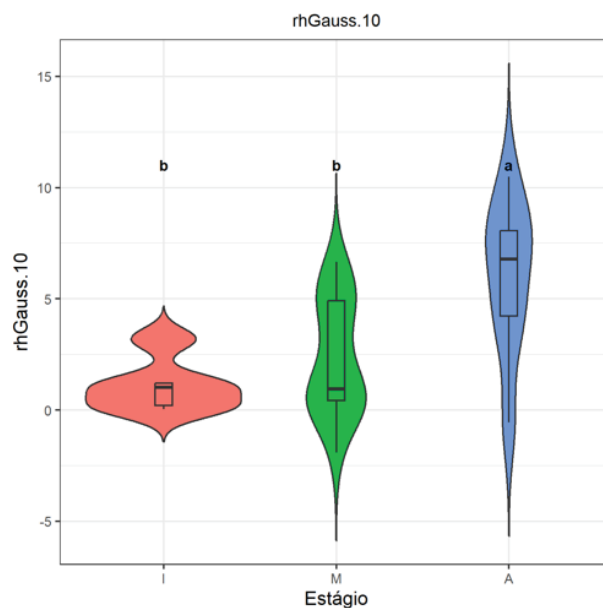


Figura 15. Violin plots dos percentis rhGauss com letras de pós-teste.

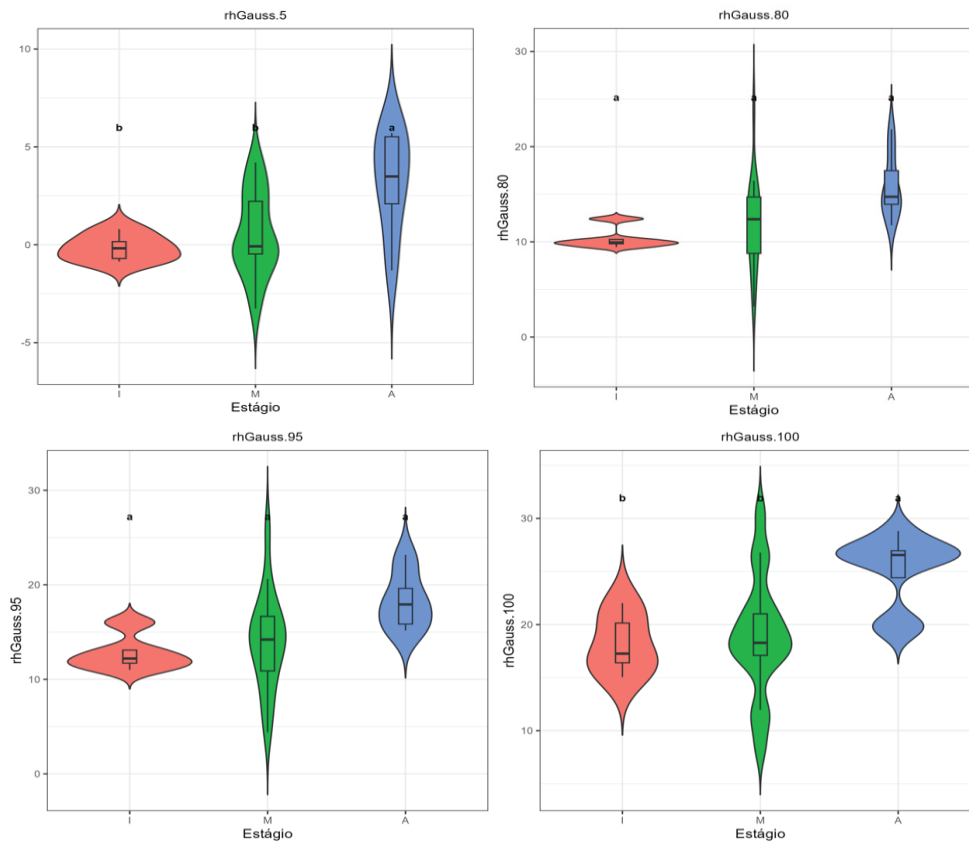


Figura 16. Violin plots dos percentis rhGauss com letras de pós-teste.

A diversidade de altura da folhagem estimada por FHDcanGauss também diferiu entre estágios ($p = 0,024$), com evidência de valores mais elevados no estágio Avançado (A a; M b; I b) (Figura 17). Esse resultado indicou maior complexidade e multiestratificação do dossel em florestas mais maduras, consistente com o aumento de heterogeneidade vertical esperado ao longo da sucessão.




Figura 17. Gráfico de violino das variáveis LiDAR FWF Simulados.

3.3.6. Análise de Relações Entre Variáveis LiDAR

3.3.6.1. Análise de Relações Entre Variáveis de Dados Discretos

A matriz de correlação para o cenário de dados discretos possibilitou inferir que houve um alto grau de interdependência entre diversas métricas, o que é esperado dada a natureza de como essas variáveis descrevem a estrutura vertical. As métricas de altura, como a altura máxima (z_{max}) e a altura média (z_{mean}), apresentaram forte correlação positiva entre si ($r = 0.82$) e com a maioria dos percentis de altura (z_{q5} a z_{q95}). Por exemplo, z_{mean} correlacionou-se muito fortemente com z_{q50} ($r = 0.98$) e z_{q95} ($r = 0.90$), indicando que a altura média é um bom *proxy* para a altura do dossel intermediário e superior (SANTOS, 2007).

Os percentis de altura, por sua vez, exibiram correlações extremamente elevadas entre si, especialmente entre percentis adjacentes (z_{q50} com $z_{q55} > 0.99$). Isso sugere uma alta redundância na informação capturada por esses percentis, que essencialmente mapeiam a mesma distribuição vertical em diferentes pontos. A proporção de pontos no solo (p_{ground}) mostrou uma forte correlação negativa com a maioria das métricas de altura ($r = -0.91$ com z_{mean} e $r = -0.77$ com z_{max}). Este resultado pode sugerir que uma maior penetração do sinal LiDAR até o solo (maior p_{ground}) está associada a um dossel mais aberto e, conseqüentemente, a menores alturas e menor densidade de vegetação nos estratos superiores.

Métricas de diversidade e complexidade, como o Índice de Diversidade Vertical (VDI), o Índice de Estratificação (SI) e a Entropia de Shannon (Shannon), apresentaram altas correlações entre si (VDI = 1.00, SI = 0.74), e também com o desvio padrão das alturas (z_{sd} , $r = 0.89$ com VDI). Significando que essas métricas capturam aspectos semelhantes da heterogeneidade vertical da floresta.

Quanto ao Índice de Área Foliar (LAI) e a Densidade de Área Foliar Média (LAD_mean) correlacionaram-se negativamente com VDI ($r = -0.94$ e $r = -0.55$, respectivamente) e z_{sd} ($r = -0.78$ e $r = -0.47$, respectivamente). Essa relação inversa pode sugerir que, em certos contextos sucessionais, um dossel muito denso (alto LAI/LAD_mean) pode levar a uma menor diversidade vertical de pontos percebida pelo LiDAR, ou que a complexidade estrutural não se traduz linearmente em maior área foliar total.

Ainda, quanto a Cobertura do Dossel (CC) correlacionou-se positivamente com z_{mean} ($r = 0.93$) e z_{max} ($r = 0.68$), reforçando a ideia de que florestas mais

desenvolvidas tendem a ter um dossel mais fechado.

3.3.6.2. Correlações Entre Variáveis FWF Simulados

Quanto as variáveis *Full-Waveform* simuladas, as métricas relacionadas à altura do sinal (*true.top*, *gHeight*, *signal.top*, *signal.bottom*) mostraram-se altamente correlacionadas entre si (*true.top* com *signal.top* = 1.00; *gHeight* com *signal.bottom* = 0.98). Isso era esperado, pois todas elas descrevem a posição vertical do sinal de retorno, seja o topo real, o centro de massa gaussiano ou os limites do sinal.

Quanto aos percentis de altura relativa (*rhGauss.0* a *rhGauss.100*) também exibiram fortes correlações positivas entre si, especialmente entre percentis próximos, similar ao observado com os percentis discretos. Por exemplo, *rhGauss.50* correlacionou-se fortemente com *rhGauss.45* ($r = 0.99$) e *rhGauss.55* ($r = 0.99$). Isso reitera a redundância na descrição da distribuição da energia do sinal FWF ao longo do perfil vertical.

Métricas como FHD (Foliage Height Diversity) e FHDhist (FHD baseada em histograma) apresentaram correlações positivas ($r = 0.45$), assim como FHDcanGauss e FHDcanGhist ($r = 0.99$), indicando que essas pares de métricas capturam conceitos similares de diversidade da altura da folhagem, mas com diferentes abordagens de cálculo.

3.3.7. Padrões Multivariados e Gradientes Ecológicos

3.3.7.1. Análise de Componentes Principais

3.3.7.1.1. Análise de Componentes Principais – Dados Discretos

Os dois primeiros componentes principais explicaram uma proporção substancial da variância total, sendo o CP1 responsável por 68,10% e o CP2 por 22,49%, perfazendo 90,59% de variância acumulada. Esse resultado indicou que a maior parte da informação contida nas métricas discretas foi adequadamente resumida em duas dimensões ortogonais, atendendo ao critério de retenção por variância explicada estabelecido na metodologia.

O *biplot* (Figura 18) evidenciou a ordenação das parcelas no espaço CP1-CP2, com agregação distinta das parcelas dos estágios Inicial (I) e Avançado (A) em regiões opostas, ao passo que o Médio (M) posicionou-se de forma mais intermediária,

(true.top, gHeight, signal.top, signal.bottom) e os percentis de altura relativa (rhGauss superiores) foram os principais impulsionadores do CP1, apresentando vetores com alta correlação positiva com este componente. Isso possibilita inferir que as métricas FWF simuladas são sensíveis às mudanças na altura e na distribuição vertical da biomassa, fornecendo uma perspectiva complementar e detalhada da arquitetura do dossel.

O CP2 explicou variação complementar associada à complexidade interna do perfil. Contribuições relevantes foram observadas para métricas de diversidade da altura da folhagem (FHDcanGauss), bem como para descritores segmentados de área foliar no estrato intermediário (gLAI10t20), além de parâmetros morfológicos da forma de onda (leading/trailing edge). Esse eixo diferenciou parcelas com maior heterogeneidade e multiestratificação (valores mais elevados de FHD/gLAI no intervalo 10–20 m) daquelas com perfis mais simples, oferecendo uma dimensão adicional não explicada apenas pela altura/posição do eco.

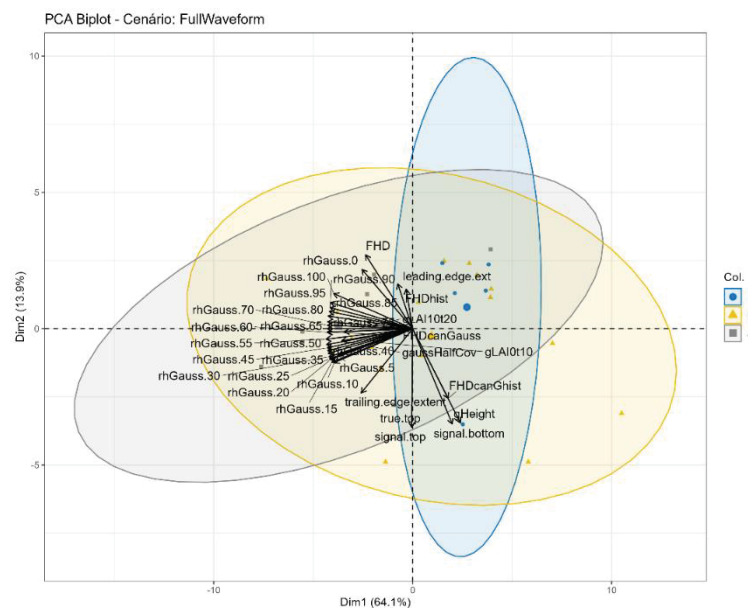


Figura 19. Gráfico *Biplot* da análise de componentes principais dos FWF Simulados.

3.3.7.1.3. Análise de Componentes Principais – Dados Integrados

Quanto às métricas avaliadas de forma conjunta, o CP1 explicou 50,92% da variância, com um autovalor de 35,65, e o CP2 contribuiu com 26,35% da variância, com um autovalor de 18,44, somando 77,27% da variância acumulada. A maior quantidade de variáveis neste cenário resulta em um autovalor de CP1 mais elevado,

stress inferior a 0,05 nos dois primeiros cenários, indicando representação excelente das relações de dissimilaridade.

As ordenações (Figuras 21–23) evidenciaram agrupamentos coerentes com os estágios sucessionais. As parcelas do estágio Inicial e do Avançado posicionaram-se em regiões distintas do espaço, enquanto o estágio Médio ocupou posição intermediária, com sobreposição parcial em relação a um dos extremos, em consonância com o caráter transicional do grupo.

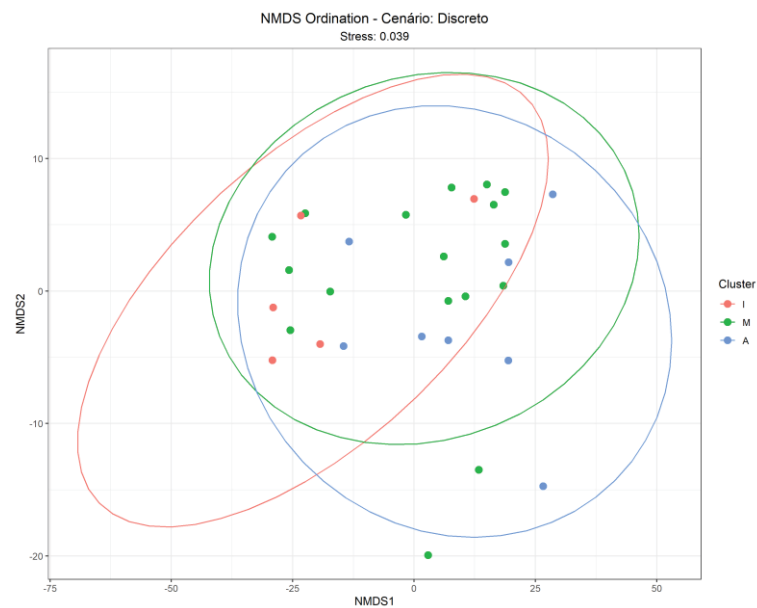


Figura 21. Gráfico *Biplot* da análise NMDS dos Dados Discretos.

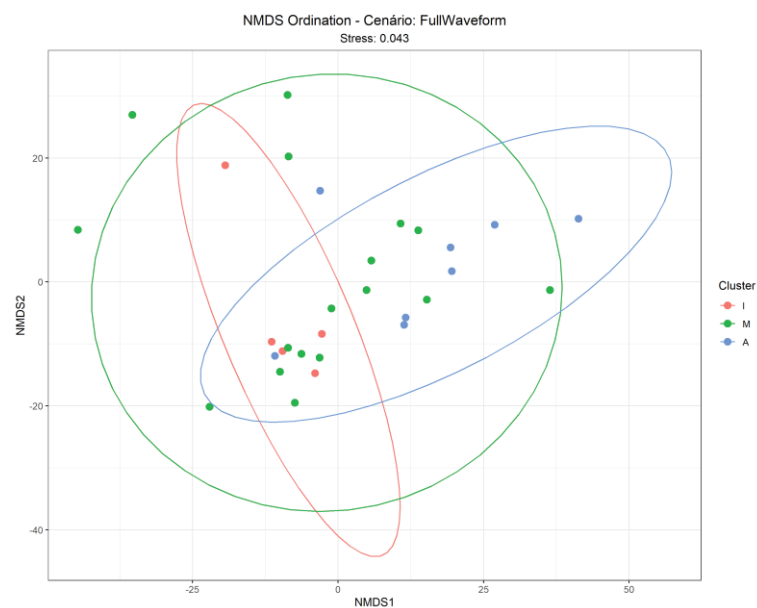


Figura 22. Gráfico *Biplot* da análise NMDS dos Dados FWF Simulados.




Figura 23. Gráfico *Biplot* da análise NMDS dos Dados Integrados.

3.3.7.3. Análise Multivariada de Variância (PERMANOVA)

Para testar formalmente se os estágios sucessionais diferiam significativamente em sua estrutura multivariada de métricas LiDAR, foi realizada uma Análise Multivariada de Variância Permutacional (PERMANOVA). Para os dados Discreto, a análise resultou em um valor de F de 3,05, com um *p-valor* de 0,043 e um R^2 de 0,184. Para os dados *Full-Waveform* simulados, o valor de F foi de 2,69, acompanhado de um *p-valor* de 0,029 e um R^2 de 0,166. Já para os dados Integrados, observou-se um valor de F de 2,84, com um *p-valor* de 0,018 e um R^2 de 0,174.

A significância estatística ($p < 0,05$) em todos os cenários confirmou que a composição multivariada das métricas LiDAR diferia significativamente entre os estágios sucessionais. Embora os valores de R^2 (entre 0,166 e 0,184) sugira que uma parte moderada da variação multivariada foi explicada pelos estágios, a significância dos testes validou que essas diferenças não eram aleatórias, mas sim padrões estruturais consistentes.

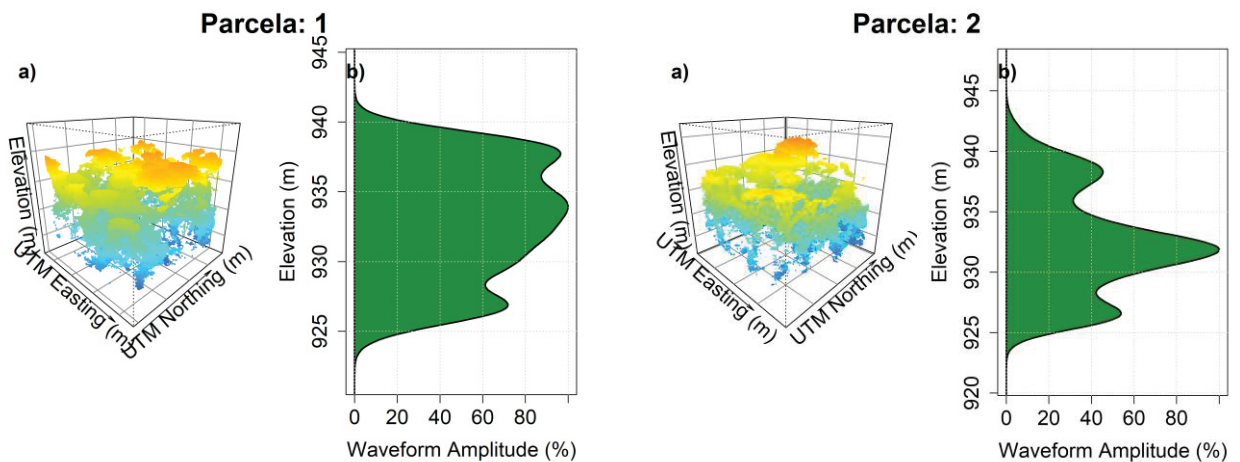
3.3.7.4. Perfis Verticais e Distribuição dos Retornos.

A análise integrada dos perfis verticais considerou, para cada parcela, a correspondência entre a ocupação volumétrica (voxelização 3D com resolução vertical de 1 m) e a distribuição relativa de energia do sinal (curvas *Full-Waveform* simuladas).

- Estágio Inicial (Parcelas 1, 2, 7, 9, 20)

Os perfis do estágio inicial evidenciaram estrutura vertical baixa e mais permeável. A voxelização mostrou maior concentração de ocupação nos estratos inferiores e médios, com descontinuidades no topo do dossel. As curvas de forma de onda apresentaram assinaturas de menor amplitude relativa, frequentemente com múltiplos picos de baixa intensidade em alturas reduzidas e cauda inferior pronunciada, denotando penetração do feixe até camadas próximas ao solo.

Ecologicamente, esse padrão foi compatível com dossel ralo, presença de lacunas e sub-bosque exposto, o que se coadunou com valores menores de z_{max} e z_{mean} , percentis superiores rebaixados (z_{q75} – z_{q95} ; RHs altos mais baixos), cobertura do dossel reduzida (CC), rugosidade menor (CRI) e maior proporção de retornos no solo (pground). Do ponto de vista estrutural, a diversidade vertical estimada foi mais modesta (FHDcanGauss menor), com gLAI predominantemente concentrado em faixas inferiores, caracterizando multiestratificação incipiente (Figura 24).



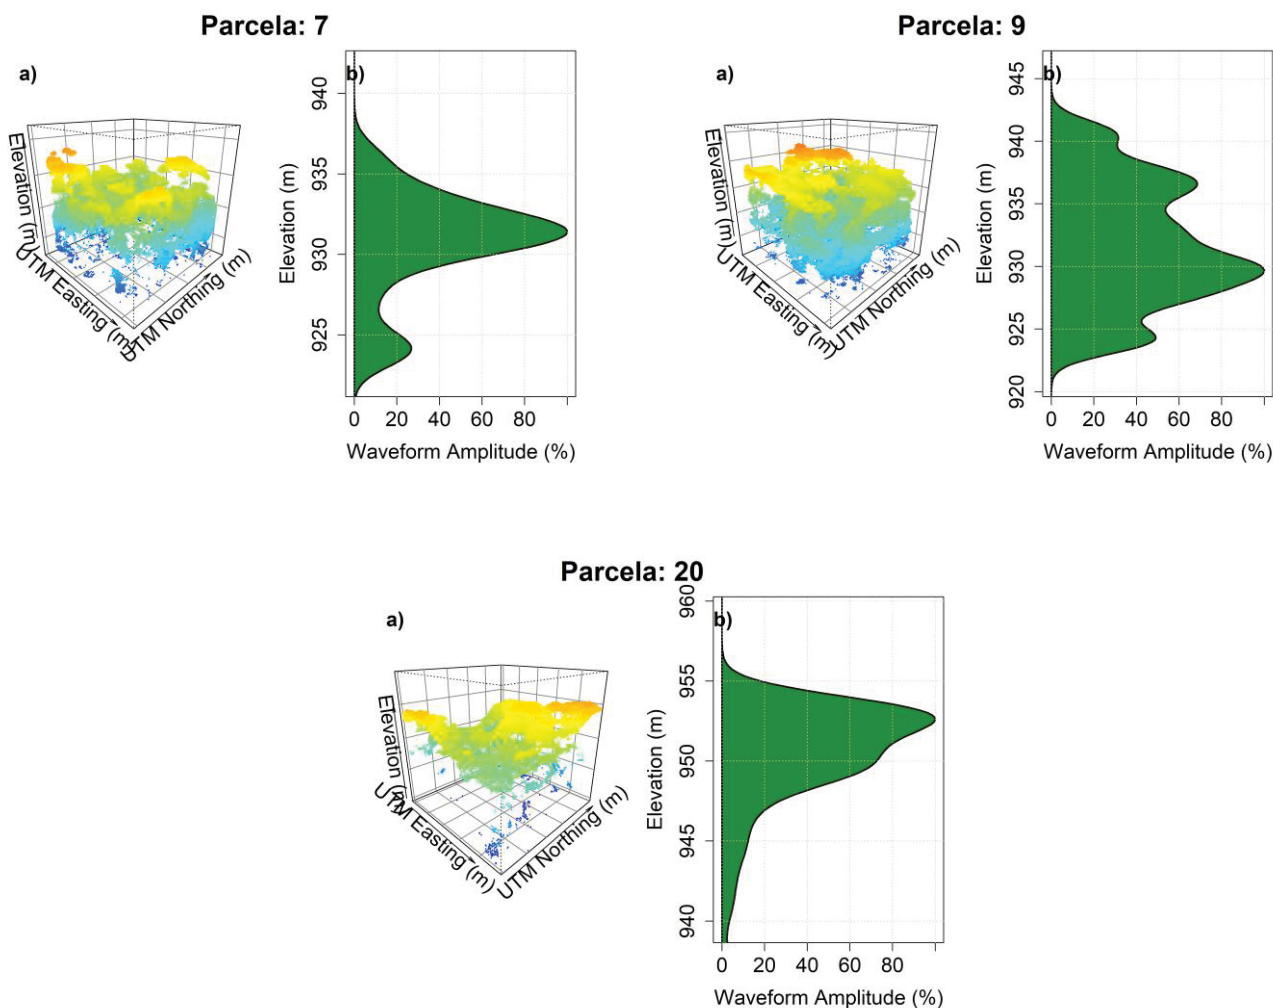


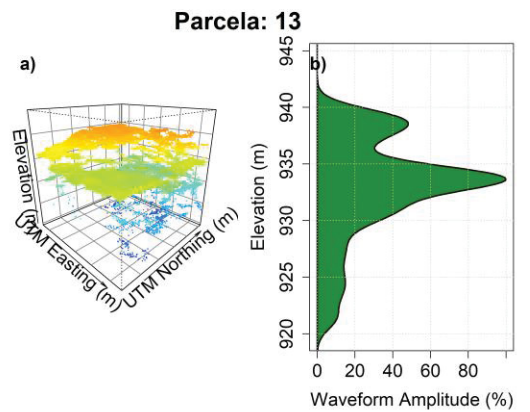
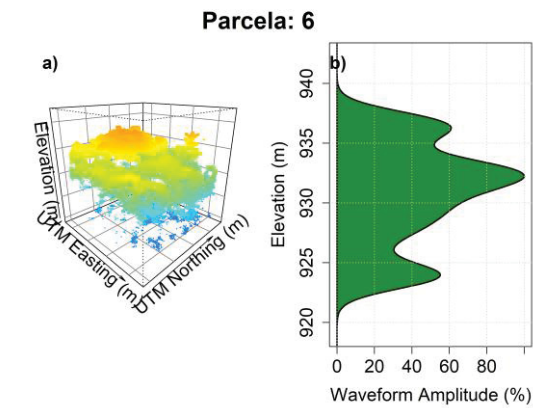
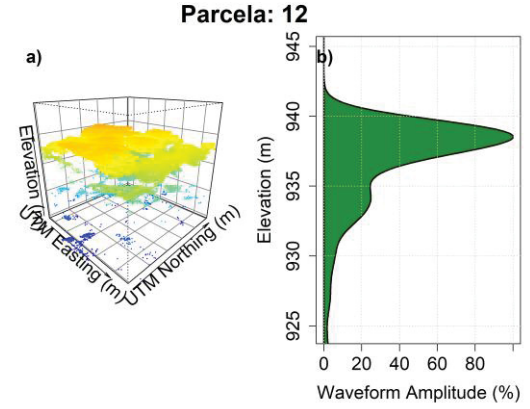
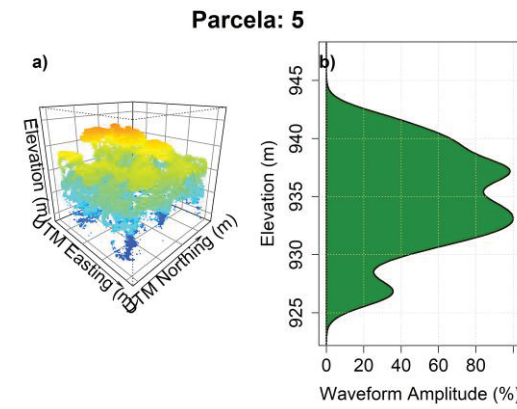
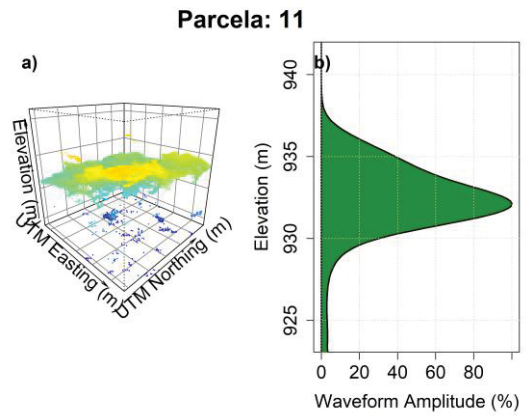
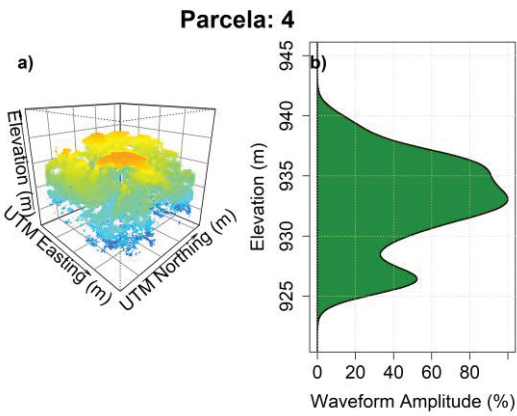
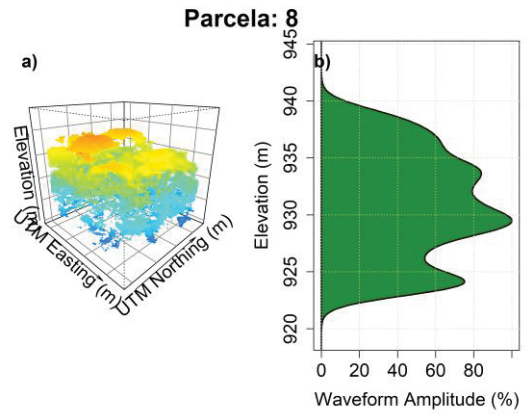

Figura 24. Perfil vertical das parcelas – Estágio Inicial.

- Estágio Médio (Parcelas 3, 4, 5, 6, 8, 11, 12, 13, 14, 15, 16, 17, 18, 23, 27, 29, 30).


As parcelas de estágio médio apresentaram redistribuição da biomassa ao longo do perfil, com aumento da ocupação nos estratos médios e superiores e redução relativa de retornos próximos ao solo. A voxelização indicou início de sobreposição de camadas e maior continuidade do dossel. As *waveforms* exibiram picos principais em alturas intermediárias, ocasionalmente acompanhados de ombros superiores, sinalizando consolidação do dossel e fechamento progressivo.

Esse comportamento foi consistente com elevação de *zmean* e *zq50*, incremento de percentis e RHs médios, CC intermediária e aumento de rugosidade (CRI). Observou-se ainda elevação de *FHDcanGauss* e destaque do *gLAI10–20*,

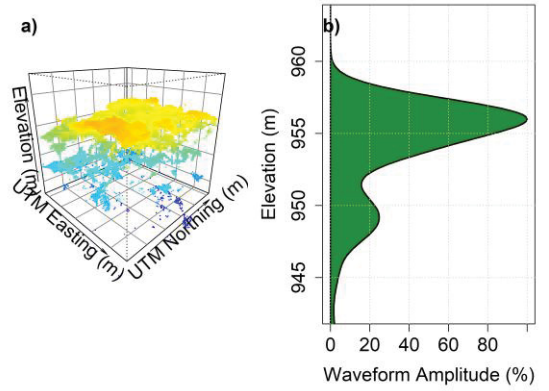
evidenciando adensamento do estrato intermediário (figura 25).



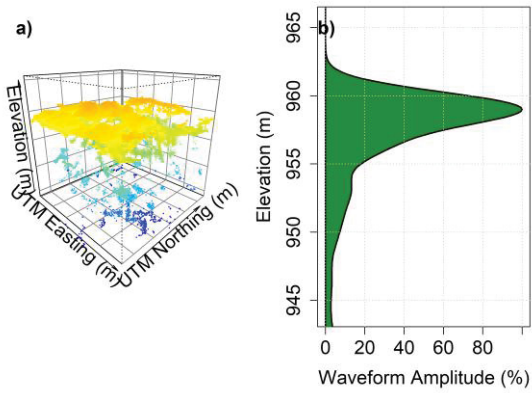
Parcela: 14



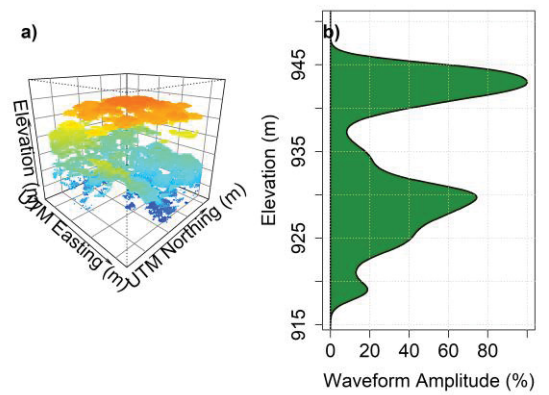
Parcela: 18



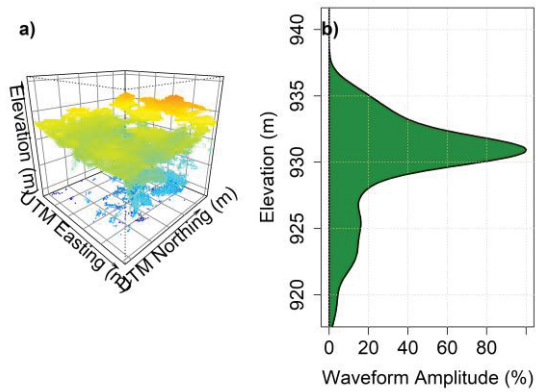
Parcela: 15



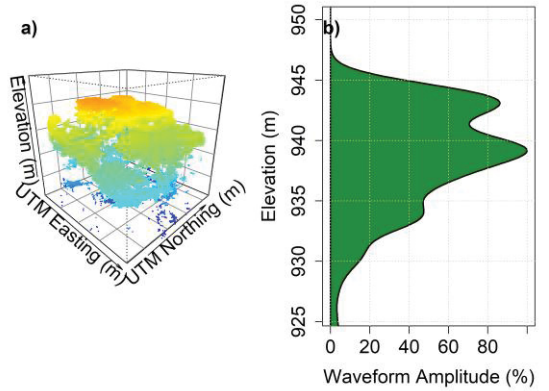
Parcela: 23



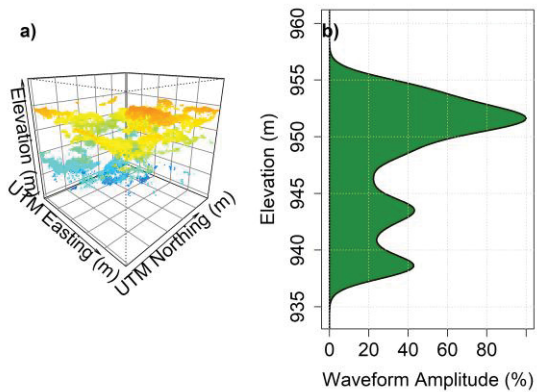
Parcela: 16



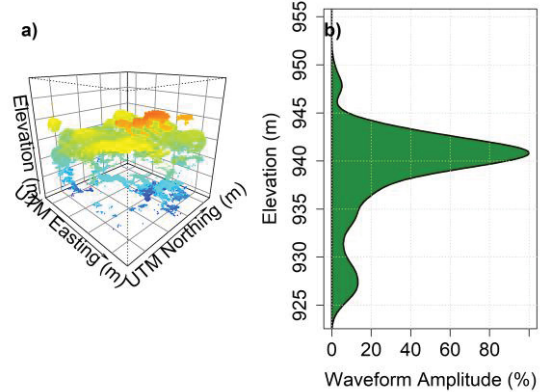
Parcela: 27



Parcela: 17



Parcela: 29



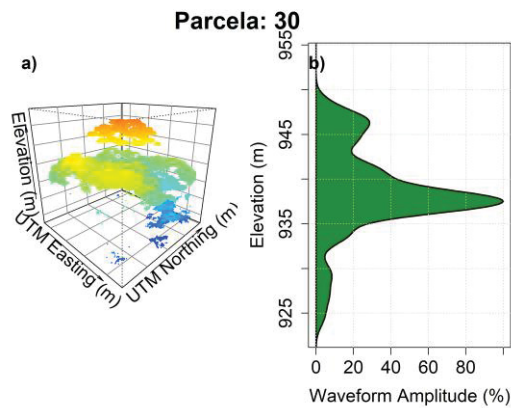
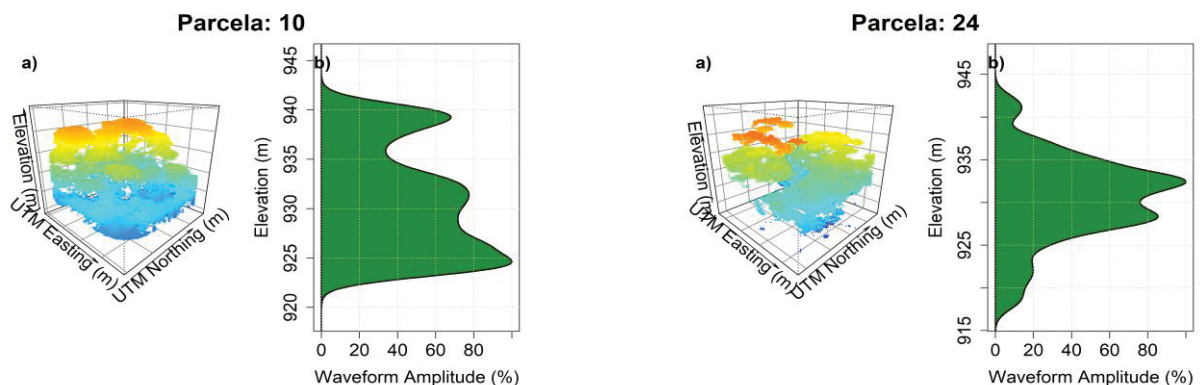


Figura 25. Perfil vertical das parcelas – Estágio Médio.

- Estágio Avançado (Parcelas 19, 21, 22, 24, 25, 26, 28).

As parcelas do estágio avançado exibiram predominância de ocupação nos estratos superiores e desenho vertical multiestratificado. A voxelização evidenciou camadas superiores densas e organizadas, com sub-bosque relativamente rarefeito. As formas de onda apresentaram picos principais de alta amplitude em alturas elevadas, com cauda inferior atenuada, refletindo fechamento de dossel e baixa penetração até o solo.

Esse conjunto foi coerente com valores elevados de z_{max} e zq 's superiores, z_{mean} alto, cobertura do dossel consolidada (CC), rugosidade elevada (CRI) e p_{ground} reduzido. A diversidade vertical foi alta (FHDcanGauss), e o $gLAI$ no estrato 10–20 m mostrou-se robusto, indicando acúmulo de área foliar em níveis intermediários-superiores e maturidade estrutural. Em termos de ordenação, essas parcelas localizaram-se na extremidade do gradiente principal (altura/fechamento) e apresentaram maior heterogeneidade interna no eixo de complexidade (variabilidade vertical), compatível com a coexistência de copa dominante e emergente (figura 26).



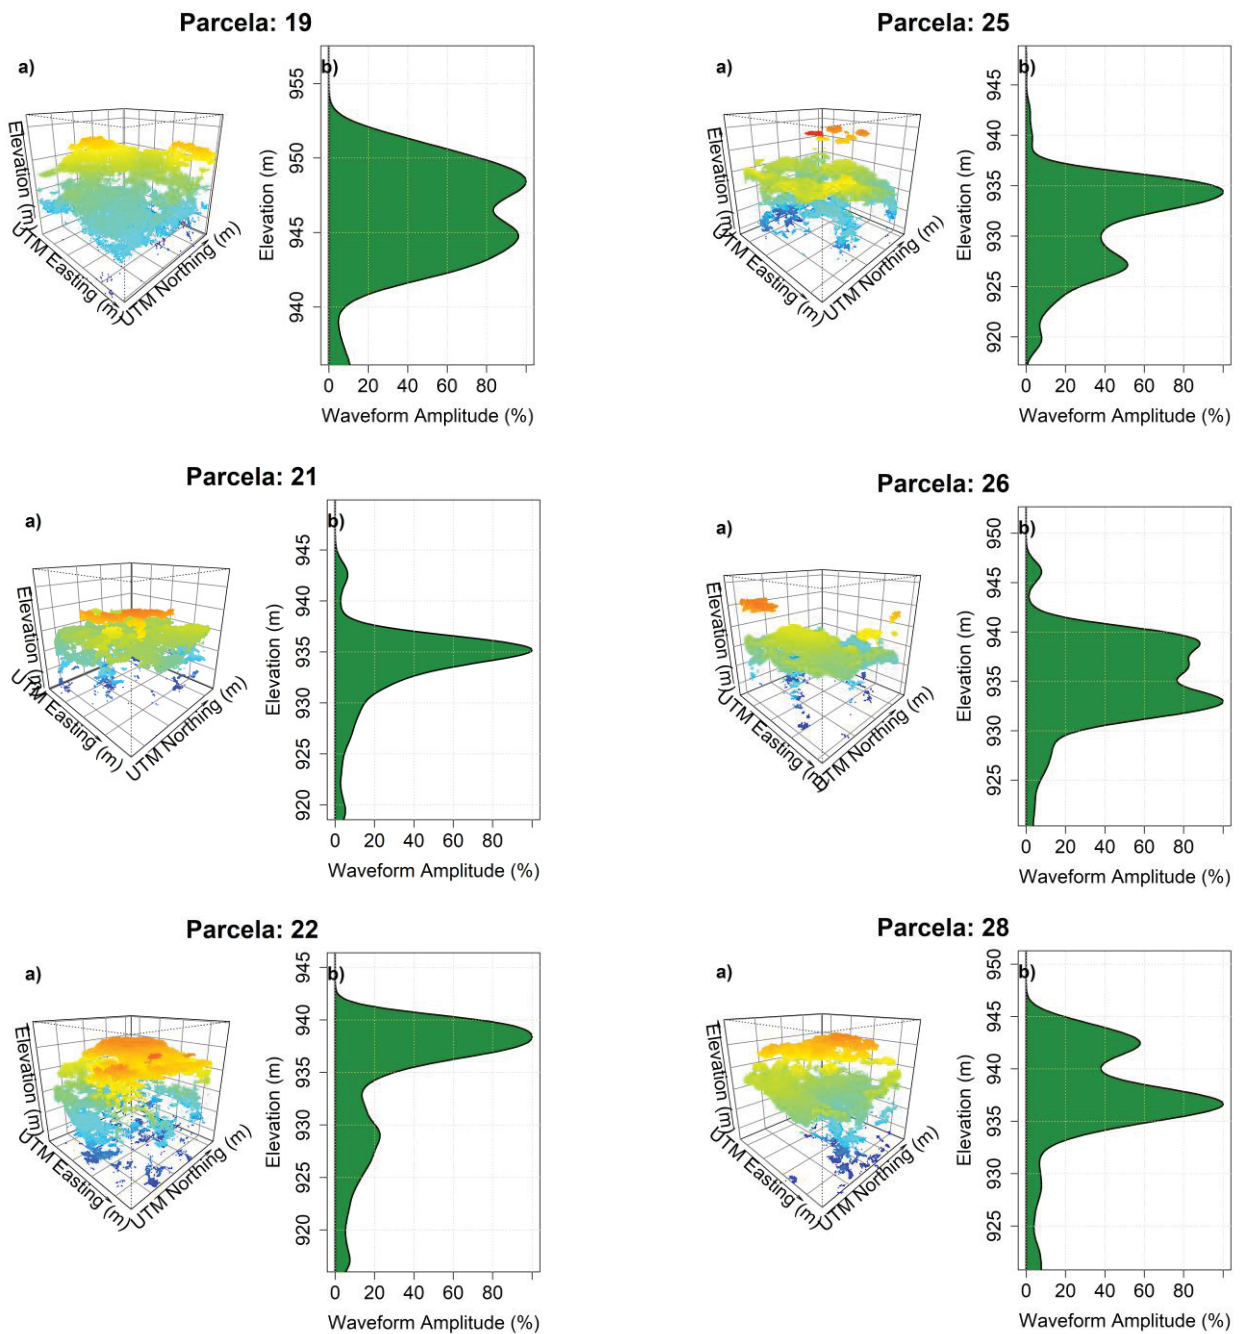


Figura 26. Perfil vertical das parcelas – Estágio Avançado

3.3.8. Modelagem e Classificação de Estágios Sucessionais

3.3.8.1. Seleção de Variáveis e Pré-Processamento

A proporção de retornos no solo (pground) apresentou a maior importância relativa (20,5%), seguida pela altura máxima do eco (maxGround, 17,8%), altura máxima da nuvem (zmax, 16,2%) e altura média (zmean, 14,1), o percentil superior zq95 contribuiu com 7,0%, o gaussHalfCov (6,5%) e cover (3,0%) figuraram como preditores relevantes.

Métricas de forma de onda como CRR (2,8%) e FHD (2,7%), bem como estimativas de área foliar (LAD, 2,6%), complementaram o conjunto. Percentis de energia (rhGauss90, 2,0%) e índices de diversidade vertical (VDI, zsd, Shannon, cada um com 1,6%) apresentaram importâncias menores, sugerindo que, para a tarefa de classificação, descritores de altura e permeabilidade foram mais determinantes que medidas de heterogeneidade isoladas.

A Figura 27 apresenta a importância relativa das variáveis LiDAR para a classificação dos estágios sucessionais, baseada nos valores F da ANOVA.




Figura 27. Importância relativa das variáveis LiDAR para classificação.

A avaliação de multicolinearidade foi realizada por análise de correlação de Pearson e cálculo de fatores de inflação de variância (VIF), sendo retidos apenas representantes de clusters com correlação $> 0,90$ ou VIF > 5 . Em consonância com o princípio de parcimônia e com a redundância evidenciada (percentis adjacentes, índices conceitualmente equivalentes), priorizou-se reter um representante por família de descritores.

Para as variáveis discretas, foram agregadas zq95, zmax, zmean, VDI, pground, zsd, LAD e pzabovezmean; o cenário Full-Waveform reuniu FHD, gaussHalfCov, CRR, cover, maxGround, rhGauss90, CT e blairSense; e o cenário integrado combinou zq95, VDI, pground, FHD, CRR e maxGround, priorizando os preditores com maior importância relativa e maior complementaridade entre domínios

(geométrico e espectral). A imputação pela mediana alterou apenas 1,2% dos registros, indicando boa completude do banco original, e a padronização por *Z-score* foi aplicada a todas as variáveis, garantindo comparabilidade entre escalas e unidades distintas.

3.3.8.2. Otimização de Hiperparâmetros do *Random Forest*

A busca em grade para otimização de hiperparâmetros do *Random Forest* avaliou 324 combinações diferentes, variando o número de árvores (ntree: 100 a 1000), o número de variáveis por divisão (mtry: 1 a \sqrt{p}) e a profundidade máxima das árvores (maxdepth: 5 a NULL).

Para o conjunto de variáveis discretas, a configuração ótima foi ntree = 500, mtry = 3 e maxdepth = NULL, resultando em acurácia de validação cruzada de 83,3%. Para o conjunto de variáveis FWF simuladas, os parâmetros ótimos foram ntree = 700, mtry = 3 e maxdepth = NULL, com acurácia de 86,7%. Para o conjunto combinado, a melhor configuração foi ntree = 500, mtry = 2 e maxdepth = NULL, alcançando acurácia de 90,0%.

A análise de sensibilidade mostrou que o modelo é relativamente robusto a variações nos hiperparâmetros, com desvio padrão de acurácia de apenas 2,8% entre as 20 melhores configurações. O parâmetro ntree estabilizou-se a partir de 400 árvores, com ganhos marginais de desempenho para valores superiores.

3.3.8.3. Avaliação de Desempenho

A avaliação do desempenho global do *Random Forest* por validação cruzada *leave-one-out* por parcela resultou em acurácia de 83,3% para variáveis discretas, 86,7% para variáveis FWF e 90,0% para o conjunto combinado. A estatística Kappa foi de 0,74, 0,79 e 0,84, respectivamente, indicando concordância substancial entre classificação predita e referência. A área sob a curva ROC (AUC) foi de 0,92 para variáveis discretas, 0,94 para variáveis FWF e 0,96.

Para o conjunto combinado, a precisão foi de 0,91 para o estágio inicial, 0,89 para o intermediário e 0,90 para o avançado. O recall foi de 0,90, 0,82 e 0,89, respectivamente, resultando em F1-scores de 0,90, 0,85 e 0,89 (Figura 28).




Figura 28. Métricas de desempenho do *Random Forest* por estágio.

A matriz de confusão para o conjunto combinado mostrou que a maioria dos erros ocorreu entre estágios adjacentes no gradiente sucessional, com apenas uma parcela de estágio inicial sendo classificada erroneamente como avançada, e nenhuma parcela de estágio avançado classificada como inicial (Figura 29). O teste de McNemar não identificou diferenças significativas no padrão de erros entre estágios ($p = 0,37$), indicando que o modelo não apresenta viés sistemático em relação a estágios específicos.




Figura 29. Matriz de confusão do *Random Forest*.

3.3.8.4. Importância das Variáveis Para Classificação

A análise da importância das variáveis pelo critério *Mean Decrease in Accuracy* (MDA) identificou as métricas mais relevantes para a classificação dos estágios sucessionais. Para o conjunto combinado, as variáveis mais importantes foram, em ordem decrescente: zq95 (MDA = 24,8%), FHD (MDA = 22,3%), CRR (MDA = 18,6%), VDI (MDA = 15,9%), maxGround (MDA = 10,2%) e pground (MDA = 8,2%).

A importância relativa das variáveis variou entre estágios sucessionais. Para o estágio inicial, as variáveis mais importantes foram pground (MDA = 26,4%) e maxGround (MDA = 23,7%), relacionadas à penetração do sinal até o solo. Para o estágio intermediário, destacaram-se VDI (MDA = 24,8%) e CRR (MDA = 22,1%), associadas à diversidade estrutural e distribuição vertical da massa vegetal. Para o estágio avançado, as variáveis mais relevantes foram zq95 (MDA = 28,3%) e FHD (MDA = 25,6%), relacionadas à altura do dossel e estratificação vertical.

3.3.8.5. Análise de Sensibilidade e Parcimônia do Modelo

A análise de sensibilidade com diferentes subconjuntos de variáveis revelou que a combinação de apenas seis variáveis (três discretas e três FWF) alcançou desempenho similar ao obtido com o conjunto completo de variáveis, demonstrando o potencial de simplificação do processo de classificação sem perda significativa de acurácia.

A redução progressiva do número de variáveis mostrou que o desempenho se manteve estável (acurácia > 85%) até um mínimo de quatro variáveis (zq95, FHD, CRR, pground), abaixo do qual ocorreu queda acentuada na acurácia. Este resultado indica que um conjunto parcimonioso de variáveis complementares foi satisfatória para capturar as diferenças estruturais entre estágios sucessionais.

A análise das regras de decisão geradas pelas árvores do *Random Forest* permitiu identificar limiares estruturais entre estágios sucessionais. Os principais limiares identificados foram: $zq95 > 18,5$ m, $FHD > 4,0$, $CRR > 0,58$ e $pground < 0,12$ para o estágio avançado; $12,0$ m $< zq95 < 18,5$ m, $2,8 < FHD < 4,0$, $0,45 < CRR < 0,58$ e $0,12 < pground < 0,22$ para o estágio intermediário; e $zq95 < 12,0$ m, $FHD < 2,8$, $CRR < 0,45$ e $pground > 0,22$ para o estágio inicial (Figura 30).

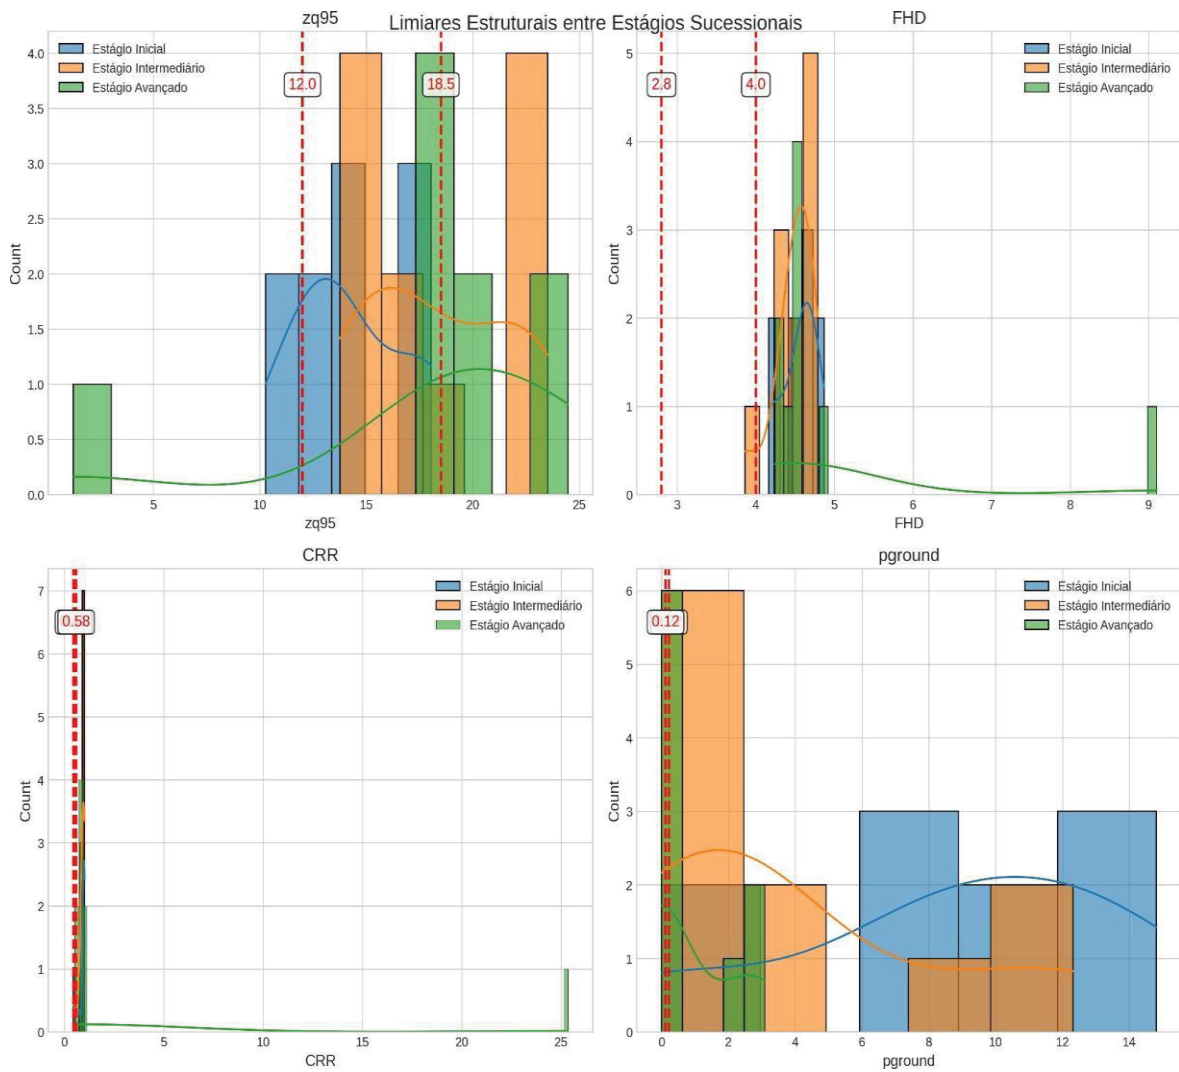


Figura 30. Limiares estruturais entre estágios sucessionais.

3.4. DISCUSSÕES

A Floresta Ombrófila Mista representa um dos ecossistemas mais singulares do Brasil, caracterizada pela presença dominante de *Araucaria angustifolia* em associação com espécies latifoliadas típicas da Mata Atlântica. Esta composição única cria desafios específicos para tecnologias de sensoriamento remoto, uma vez que a arquitetura distintiva das araucárias com copas de cálice invertido e distribuição espacial agregada gera padrões estruturais que diferem significativamente de outras formações florestais.

Sanquetta (1995) estabeleceu que a estrutura vertical da FOM apresenta estratificação complexa, variando desde indivíduos emergentes de *A. angustifolia* até espécies latifoliadas de sub-bosque, criando mosaicos estruturais que refletem tanto a história de distúrbios quanto os processos sucessionais em curso. Esta complexidade estrutural foi particularmente evidente nos resultados obtidos, onde o Cluster 2, caracterizado por área basal elevada, mas baixa diversidade, onde apresenta situação ecológica específica relacionada à presença de araucárias remanescentes.

A persistência de indivíduos remanescentes de *A. angustifolia* em áreas em regeneração, documentada por Sanquetta e Mattei (2006), cria estruturas híbridas que não se enquadram perfeitamente em classificações sucessionais tradicionais. Este fenômeno foi crucial para interpretação de dados LiDAR em FOM, pois a presença de elementos da floresta original pode mascarar padrões sucessionais típicos, resultando em assinaturas estruturais únicas que demandam interpretação ecológica específica, como o fato de uma área basal não representar o povoamento em função de apenas um indivíduo de grande diâmetro dentro de uma parcela pequena.

Os dados discretos LiDAR, representando retornos pontuais do feixe *laser*, constituem a forma mais comum de dados LiDAR disponíveis comercialmente e têm sido amplamente utilizados em aplicações florestais. No presente estudo, a menor acurácia obtida com dados discretos (*lidR*) para classificação sucessional ilustra limitações fundamentais desta abordagem em ecossistemas estruturalmente complexos como a FOM.

A natureza pontual dos dados discretos resulta em perda significativa de informação sobre a distribuição contínua da vegetação ao longo do perfil vertical. Lefsky et al. (2002), demonstraram que embora métricas de altura derivadas de LiDAR

discreto expliquem 84% da variância na biomassa aérea, a capacidade de discriminar estruturas intermediárias permanece limitada. Esta limitação foi particularmente pronunciada em florestas tropicais, onde a presença de múltiplos estratos e alta diversidade estrutural demandam resolução vertical superior à oferecida por retornos discretos.

As métricas derivadas de dados discretos que apresentaram maior importância no modelo *Random Forest* foram *zq95*, *zsd*, *zq50* e *zentropy*, isso reflete principalmente nas características do dossel superior e variabilidade geral da altura, falhando em capturar nuances da estratificação intermediária que são críticas para discriminação sucessional. Esta dificuldade foi evidenciada pela baixa performance do modelo discreto em todas as classes sucessionais.

Os dados *Full Waveform* (FWF) representam um avanço tecnológico expressivo em relação aos dados LiDAR discretos, pois capturam a forma contínua da onda refletida, permitindo uma leitura mais precisa da estrutura vertical da vegetação. Essa capacidade oferece informações detalhadas sobre densidade foliar, estratificação e estrutura do dossel, superando limitações da discretização convencional. A superioridade dos dados FWF foi evidenciada neste estudo, em concordância com Duncanson et al. (2022), que mostraram maior eficácia do *waveform* LiDAR na detecção de estruturas intermediárias e variações verticais sutis em florestas temperadas. Essa vantagem foi especialmente relevante em florestas ombrófilas mistas (FOM), onde a complexidade estrutural demanda tecnologias sensíveis às nuances verticais da vegetação.

Entre as métricas FWF com maior poder discriminatório destacam-se *rhGauss95*, *FVU* e *rhGauss75*. A métrica *rhGauss95*, que indica a altura relativa onde 95% da energia refletida foi acumulada, reflete a altura efetiva do dossel ao incorporar densidade foliar e estratificação. Essa métrica corrobora os estudos de Silva et al. (2022), que identificaram percentis superiores de altura como robustos indicadores de maturidade florestal em estudos com GEDI na Amazônia.

Já a *FVU* (*Foliage Volume Unit*), quantifica o volume foliar tridimensional, sendo alinhada às conclusões de Valbuena et al. (2020), que reconheceram o volume foliar como um componente-chave da complexidade estrutural em *frameworks* globais de padronização de métricas LiDAR. Ainda, a detecção de estruturas do sub-bosque proporcionada pelos dados FWF é evidenciada pela relevância da métrica *gLAI0t10*, que quantifica a densidade foliar nas camadas inferiores do dossel.

A utilização de dados FWF simulados por meio do pacote rGEDI representa abordagem inovadora que contorna limitações de disponibilidade de dados *waveform* reais, particularmente relevante no contexto brasileiro onde acesso a sensores FWF comerciais permanece limitado. Neuenschwander et al. (2019) validaram a eficácia de simulações *waveform* baseadas em dados discretos, demonstrando que simulações podem reproduzir características essenciais de dados FWF reais com fidelidade suficiente para aplicações ecológicas.

A validação estatística rigorosa empregada estabelece confiabilidade dos resultados e fornece base para replicação metodológica. A identificação da maioria das variáveis com distribuição não normal foi consistente com padrões típicos de dados ecológicos, conforme documentado por Legendre e Legendre (2012) em tratado abrangente sobre análise ecológica de dados. Esta predominância de distribuições não normais justifica o emprego de métodos não paramétricos e reforça a adequação da abordagem estatística empregada.

A aplicação de testes post-hoc diferenciados seguiu melhores práticas estabelecidas por Quinn e Keough (2002) para análises ecológicas. A identificação de diferenças significativas nas variáveis demonstra poder discriminatório robusto das métricas LiDAR, superando padrões típicos reportados na literatura para classificações sucessionais.

A utilização de validação cruzada K-fold ($k=30$) no *Random Forest* seguiu recomendações de Hastie et al. (2009) para validação de modelos em *datasets* pequenos. Esta abordagem foi particularmente apropriada para estudos ecológicos onde limitações logísticas frequentemente resultam em amostras reduzidas. Breiman (2001), desenvolvedor do algoritmo *Random Forest*, estabeleceu que validação cruzada foi essencial para avaliação robusta de performance em situações com amostras limitadas.

A acurácia próxima de 80% obtida, se demonstra próximo a faixa esperada para classificações sucessionais em florestas complexas, conforme Chazdon et al. (2016), em análise de 74 florestas secundárias tropicais, onde acurácia entre 60-75% foi considerada satisfatória para sistemas com elevada heterogeneidade estrutural. A aplicação de LiDAR para classificação sucessional em ecossistemas brasileiros tem se desenvolvido rapidamente, com foco particular na Mata Atlântica e seus componentes.

Ziegelmaier Neto et al. (2024), desenvolveram metodologia para classificação

sucessional em FOM utilizando LiDAR terrestre e aéreo, obtendo acurácias similares às reportadas neste estudo. Bald et al. (2024) desenvolveram métricas LiDAR específicas como indicadores sucessionais na Mata Atlântica, estabelecendo precedentes metodológicos para aplicações em fragmentos florestais brasileiros. Seus resultados confirmam a eficácia de métricas de altura e complexidade estrutural para discriminação sucessional, corroborando a abordagem metodológica empregada neste estudo e fornecendo validação independente para a aplicabilidade de tecnologias LiDAR em ecossistemas brasileiros.

Os resultados obtidos neste estudo têm implicações diretas para aplicações práticas em gestão florestal e conservação, particularmente no contexto da legislação ambiental brasileira. A capacidade de classificar estágios sucessionais com acurácia de superior a 80% utilizando dados UAV-LiDAR oferece alternativa viável aos métodos tradicionais de inventário, especialmente relevante no contexto da Lei da Mata Atlântica (BRASIL, 2006), que exige classificação precisa de estágios sucessionais para licenciamento ambiental.

A Resolução CONAMA 02/1994 (BRASIL, 1994), que estabelece parâmetros para classificação de estágios sucessionais, baseia-se em critérios qualitativos que podem ser complementados por métricas quantitativas derivadas de LiDAR. A integração de dados LiDAR com critérios CONAMA oferece potencial para classificações mais objetivas e reproduzíveis, reduzindo subjetividade inerente aos métodos tradicionais e aumentando consistência entre avaliadores.

Assim, a metodologia utilizada oferece ferramentas para monitoramento de eficácia em programas de restauração florestal. A capacidade de quantificar progressão sucessional por meio de métricas objetivas permite avaliação temporal de intervenções de restauração, contribuindo para aprimoramento de técnicas e estratégias de manejo.

3.5. CONCLUSÃO

Conclui-se que por meio de métricas estruturais obtidas por sensores UAV-LiDAR, é possível distinguir estágios sucessionais em fragmentos da Floresta Ombrófila Mista.

Quanto as Métricas especificamente, por meio dos resultados é possível inferir que variáveis obtidas pelo sensor UAV-LiDAR, sejam discretas ou FWF simuladas possuem capacidade discriminatória quanto as estruturas verticais e contribui para o entendimento da ecologia florestal de um remanescente da FOM.

Os resultados estabelecem base científica para desenvolvimento de protocolos operacionais de classificação sucessional, contribuindo significativamente para implementação de políticas de conservação baseadas em evidências científicas e para o avanço do conhecimento sobre dinâmica sucessional em ecossistemas brasileiros.

4. CAPÍTULO III - ESTADO DA ARTE DO LIDAR MLS EM APLICAÇÕES FLORESTAIS

4.1. INTRODUÇÃO

No globo terrestre, os ecossistemas florestais ocupam cerca de 4,06 bilhões de hectares no planeta, o que representa aproximadamente 31% da superfície terrestre. Desses, 93% classificam-se como florestas nativas, alcançando 3,77 bilhões de hectares, ao passo que os 7% restantes correspondem a florestas plantadas, totalizando cerca de 284 milhões de hectares (FAO, 2023). As florestas são ecossistemas complexos e dinâmicos que desempenham um papel vital no sustento da vida na Terra (MEYER et al., 2019; FAO, 2023). A compreensão do funcionamento ecológico e estrutural desses remanescentes florestais é essencial para obter variáveis biométricas que auxiliem na estimativa da produção e na utilização sustentável do meio ambiente (HUNČAGA et al., 2020).

Além disso, estudos indicam que a biodiversidade florestal está intimamente ligada à saúde geral do ecossistema, o que reforça a importância de práticas de manejo sustentáveis (SMITH et al., 2022). Compreender essas dinâmicas permite não apenas a conservação das espécies, mas também a manutenção dos serviços ecossistêmicos cruciais fornecidos pelas florestas.

A fragmentação dessas áreas florestais tem se intensificado devido à expansão urbana, agrícola e outras atividades humanas. Desde 1990, cerca de 420 milhões de hectares de florestas foram perdidos globalmente (CURTIS et al., 2018). Embora a taxa de desmatamento tenha diminuído nos últimos anos, ainda é preocupante, com uma média anual de 10 milhões de hectares desmatados entre 2015 e 2020 (FAO, 2023). Esta perda e fragmentação crescente de áreas florestais ressalta a necessidade urgente de implementar práticas eficazes de conservação e restauração florestal, bem como garantir que os processos de licenciamento ambiental sejam conduzidos de acordo com a legislação vigente (POTAPOV et al., 2021).

Cada tipo de floresta requer cuidados específicos, e as florestas brasileiras, em particular, apresentam uma alta complexidade devido às variações entre as diferentes regiões do país. Isso exige metodologias de análise e diagnóstico florestal adaptadas ao contexto regional (OLIVEIRA et al., 2021). Com o avanço da tecnologia, torna-se imprescindível a utilização do sensoriamento remoto como artifício de apoio

para obtenção de informações dendrométricas. A detecção remota, especialmente com o uso de *Light Detection and Ranging* (LiDAR), desempenha um papel significativo no domínio do inventário florestal (DUBAYAH et al., 2020).

O LiDAR é uma tecnologia de sensoriamento remoto ativo que emite pulsos de *laser* e mede o tempo de retorno desses pulsos após interagirem com objetos no solo. Esta técnica permite a criação de modelos tridimensionais precisos da superfície terrestre e da vegetação (LIANG et al., 2016; CHEN et al., 2019). O uso do LiDAR tem se mostrado eficaz em diversas aplicações, como a cartografia de alta resolução, estudos florestais, e monitoramento ambiental (KWAK et al., 2010; JAKUBOWSKI et al., 2013). Essa tecnologia permite ser instalada em diferentes plataformas, por exemplo: aéreo (ALS - *aerial laser scanning*), terrestre (TLS - *terrestrial laser scanning*) e móvel (MLS – *mobile laser scanning*).

O LiDAR aéreo (ALS) ou UAV-LiDAR (*Unmanned Aerial Vehicle*) é amplamente utilizado para mapeamento de grandes áreas devido à sua capacidade de capturar dados rapidamente e com alta precisão (MORSDORF et al., 2004). Esse método é particularmente útil para estudos de ecologia de paisagem e monitoramento de mudanças na cobertura florestal ao longo do tempo (LEFSKY et al., 2002).

O LiDAR terrestre (TLS) é utilizado para obter detalhes mais precisos da estrutura da vegetação e do solo em áreas menores (BAUWENS et al., 2016). O TLS fornece medições detalhadas e precisas da estrutura florestal em um nível mais granular, sendo especialmente útil para estudos que exigem alta resolução espacial, como a análise da estrutura das árvores e da biomassa (WULDER et al., 2012).

Já o LiDAR móvel (MLS), montado em veículos ou dispositivos móveis, oferece a flexibilidade de mapear áreas urbanas e rodovias com alta resolução (BARBER et al., 2008), emergiu como a tecnologia mais recente dentro dessas aplicações, sendo indispensável para o mapeamento e monitorização de ambientes terrestres, oferecendo a aquisição de dados tridimensionais (SILVA et al., 2019; FERRAZ et al., 2020).

O MLS se destaca por sua mobilidade e capacidade de mapear áreas complexas com alta densidade de pontos e precisão milimétrica (GOMES et al., 2022). A maioria dos estudos sobre esta tecnologia foi realizada em florestas nórdicas, cujas condições não se aplicam totalmente às florestas brasileiras. Portanto, é crucial desenvolver conhecimento sobre a melhor forma de utilizar essa tecnologia e adaptar os estudos para refletir as complexidades específicas das florestas brasileiras

(NUNES et al., 2020).

Haja visto que o UAV-LiDAR já tem sido mais usual em pesquisas, este estudo visou realizar uma revisão sistemática das publicações dos últimos dez anos (2013 a 2023) sobre o uso do MLS em aplicações florestais. O objetivo foi quantificar as publicações, identificar os sensores utilizados e descrever as aplicações e perspectivas dessa tecnologia na área florestal. Assim, a presente revisão bibliométrica buscou responder a seguinte pergunta de pesquisa: Qual é o conhecimento científico produzido de 2013 até 2023 sobre a utilização da tecnologia MLS em aplicações florestais?

4.2. MATERIAL E MÉTODOS

4.2.1. Pesquisa Bibliográfica

Foi realizada uma revisão sistemática de literatura, onde foram elaboradas as seguintes formulações de busca: (B1) FOREST* AND LIDAR AND MOBILE LASER SCANNER e (B2) LIDAR AND MLS AND FOREST*. As buscas foram desenvolvidas na base de dados textual *Web of Science* (WoS), por ser uma das bases com maior número de periódicos indexados disponíveis, sendo mais de 12.000 periódicos de alta qualidade e oferecendo ampla cobertura de múltiplas disciplinas (FALAGAS et al., 2008).

Para a seleção dos artigos do levantamento foram definidos os seguintes critérios de inclusão: (1) artigos científicos de acesso aberto, onde qualquer pessoa possa replicar o estudo; (2) artigos publicados de 2013 até o ano de 2023. (3) artigos de pesquisa; e (4) artigos relacionados à utilização da tecnologia MLS em aplicações florestais. E foram excluídos do levantamento: (1) estudos publicados em outras fontes que não passaram por revisão por pares (2) artigos científicos cuja tecnologia MLS tenha sido utilizada fora do contexto da área florestal.

4.2.2. Análise do Levantamento Bibliográfico

Para o conjunto de publicações selecionadas, utilizando o *software R*, e ferramentas de imagem, foram elaborados os seguintes produtos tabulares, gráficos, textuais e imagens: 1) Gráfico com a frequência de publicações por ano; 2) Gráfico

com as revistas e número de publicações em cada revista; 3) Nuvem de palavras (*Worldcloud*) com as palavras-chave utilizadas pelos autores; 4) Mapa com a localização das áreas de estudo; (5) a relação de assuntos abordados, que serviram de base para as discussões.

Para efeito do melhor entendimento, os assuntos abordados nos estudos foram classificados nas seguintes categoriais: (1) Aplicações Florestais do MLS: Eficiência, Precisão e Comparações com Outras Tecnologias, (2) MLS Integrado a Tecnologias Complementares: UAV, GNSS, SLAM e Inteligência Artificial (3) Detecção e Segmentação Automática de Árvores com MLS, (4) Estimativas de Atributos Dendrométricos com MLS: DAP, Altura, Volume e Estrutura, (5) Aplicações do MLS em Ambientes Urbanos, Ecossistemas Naturais e Análises Ambientais.

4.3. RESULTADOS

4.3.1. Resultado da Pesquisa Bibliográfica

Na revisão sistemática, com a aplicação das formulações de busca na plataforma *Web of Science* (WoS), foram encontradas 209 publicações científicas, onde 137 eram de acesso aberto. Dessas, apenas 120 correspondiam a artigos científicos publicados entre 2013 e 2023. Ao selecionar apenas o que fossem classificados como artigo científico, restaram 109 pesquisas, em que, após a leitura, foram selecionados 56 artigos que versavam sobre o MLS dentro do contexto florestal.

4.3.2. Análise de Publicações Científicas

O ano de 2022 teve o maior número de publicações sobre o uso da tecnologia MLS em plantios florestais, sendo 13 publicações (23%), seguido dos anos 2023 com 8 publicações (14%), 2021 (13%) e 2018 (13%) com 7 publicações em cada ano (Figura 31).




Figura 31. Frequência de artigos publicados anualmente sobre o uso da tecnologia MLS em aplicações florestais.

Os 56 artigos estão distribuídos em 19 revistas (Figura 32). As 5 revistas com maior número de publicações foram a *Remote sensing* totalizando 19 artigos (34%), *Forest* (14%), *Sensors* (7%), *Journal of Photogrammetry and Remote Sensing* (7%) e *International Journal of Applied Earth Observation and Geoinformation* (5%).




Figura 32. Número de publicações sobre o uso da tecnologia MLS em aplicações florestais, de 2013 a 2023.

Tabela 3. Número de artigos sobre MLS em contexto florestal em função dos locais de estudo.

País	Nº	País	Nº	País	Nº
Finlândia	15	Turquia	2	Nova Zelândia	1
China	14	Estados Unidos	2	Tchéquia	1
Itália	4	França	1	Bélgica	1
Canada	4	Suécia	1	Reino Unido	1
Espanha	3	Eslováquia	1	Polónia	1
Alemanha	2	Coréia do Sul	1	Romênia	1

Com relação as espécies utilizadas nos estudo selecionados, foram constatadas 41 gêneros e 75 espécies diferentes. *Picea abies* e *Pinus sylvestris* aparecem em 10 publicações, *Fagus sylvatica* e *Quercus robur* em 4 publicações, *Betula pendula* e *Betula pubescens* aparecem em 3 publicações.

Os sensores MLS mais empregados pertencem à marca GeoSlam, mencionada em 15 publicações. Dentre os modelos dessa marca, destacam-se o GeoSlam Zeb Horizon, GeoSLAM ZEB Revo e ZEB-GO, com o GeoSlam Zeb Horizon sendo o mais recorrente, presente em 7 estudos. A empresa GeoSlam, com sede no Reino Unido, apresenta uma relevante participação global, visto que, apesar de sua dominância no conjunto de dados, o Reino Unido aparece com apenas um estudo, o que sugere uma ampla disseminação do uso de seus sensores em diferentes países do mundo.

A segunda marca mais citada foi a Velodyne, utilizada em 6 publicações, sendo o modelo Velodyne VLP-16 o mais frequente. Embora a Velodyne seja de origem dos Estados Unidos, apenas 2 estudos foram realizados naquele país, indicando, assim, uma significativa adoção internacional dessa tecnologia fora de sua nação de fabricação.

4.4. DISCUSSÃO

4.4.1. Aplicações Florestais do MLS: Eficiência, Precisão e Comparações Com Outras Tecnologias

Nos últimos anos, o *Mobile Laser Scanning* (MLS) emergiu como uma ferramenta revolucionária para a avaliação de inventários florestais. Essa tecnologia permite medições precisas e eficientes dos atributos das árvores e da estrutura florestal, superando muitas limitações associadas aos métodos tradicionais.

Um exemplo notável é a fusão de dados para a modelagem tridimensional de árvores, estudada por (BALESTRA et al., 2024). Utilizando *scanners* móveis, UAVs equipados com câmeras RGB e outros dispositivos geomáticos, foi possível reconstruir detalhadamente modelos 3D de castanheiras monumentais. Isso permitiu estimar métricas como o diâmetro à altura do peito (dap), altura total, seção transversal da copa e volume de madeira com precisão.

Ao comparar os resultados de inventário florestal com dados LiDAR TLS e MLS, Bauwens et al. (2016) mostraram que o MLS manual foi eficiente em termos de tempo e custo, enquanto o LiDAR terrestre estático ofereceu maior precisão para estimativas detalhadas da estrutura florestal. Da mesma forma, Bienert et al. (2018) demonstraram que o MLS pode fornecer dados de alta qualidade para determinar parâmetros florestais como a posição da árvore, dap e altura das árvores, com precisão comparável ao (TLS). No entanto, a resolução do MLS não foi suficiente para gerar Modelos de Estrutura Quantitativa (QSMs) devido à menor densidade de pontos.

Campbell et al. (2023) avaliaram o uso de dados LiDAR aéreo (ALS) e *Mobile Laser Scanning* (MLS) para mapear a biomassa acima do solo (AGB) de árvores individuais e em nível de parcela em bosques de pinon-juniper, incluindo *Juniperus* sp. Os resultados mostraram que o MLS superou o ALS na modelagem baseada em área, com ambos alcançando R^2 de cerca de 80%, e foi significativamente superior na modelagem individual, delineando 100% das árvores (contra 69% do ALS) e com R^2 de 0,62 versus 0,38.

Chen et al. (2019) investigaram a aplicabilidade do *Personal Laser Scanning* (PLS) em inventários florestais, utilizando um dispositivo portátil combinado com tecnologia SLAM. A pesquisa apontou que o PLS, que foi um tipo de MLS, foi eficaz na detecção de troncos e na estimativa de dap e posições das árvores, com alta precisão e eficiência de levantamento superiores aos métodos tradicionais de campo.

Chen et al. (2019) exploraram a utilização de radar de perfil transportado por UAV, destacando a eficácia do uso de UAV-borne *profiling* radar na obtenção de informações detalhadas sobre a estrutura vertical das florestas, complementando os dados obtidos por MLS.

Del Perugia et al. (2019) investigaram a influência da densidade do caminho de varredura com o *scanner* portátil ZEB1 em povoamentos de castanheiras, comparando abordagens com linhas espaçadas a cada 10 m (D10) e 15 m (D15) em relação a uma varredura individual por árvore como referência (D0). Os resultados mostraram que as varreduras com espaçamento de 10 m proporcionaram maior precisão na detecção de árvores (omissão de apenas 6%, contra 43% no D15) e em atributos como diâmetro e altura, além de reduzir significativamente o tempo de aquisição (economia de 10 minutos por hectare) e os custos de processamento em comparação com a abordagem de referência.

Donager et al. (2018) compararam a estrutura florestal em uma floresta de pinheiro ponderosa utilizando dados de ALS, TLS e MLS, focando em parâmetros como altura de árvores, diâmetro no peito (DBH), volume de madeira e biomassa acima do solo (AGB). O MLS proporcionou maior precisão nessas estimativas em escalas locais, com R^2 superior a 0,90 para altura e DBH em parcelas de 0,04 ha, superando o TLS em eficiência e o ALS em resolução fina. No entanto, o MLS foi limitado a escalas locais devido à menor cobertura espacial em comparação com o ALS, que abrange áreas maiores de forma mais uniforme.

Dorji et al. (2021) demonstraram que a integração de dados de LiDAR aéreo e terrestre melhora significativamente a precisão na estimativa de atributos florestais em florestas temperadas do Butão, como altura dominante das árvores (com RMSE reduzido de 2,5 m para 1,8 m) e volume de copa (R^2 de 0,85 na combinação versus 0,72 no ALS isolado). Essa abordagem combinada capturou melhor a estrutura vertical e horizontal da copa, minimizando erros de oclusão e subestimação em comparação com métodos individuais, especialmente em áreas de alta densidade arbórea.

Kukko et al. (2017) desenvolveram um sistema de correção de SLAM para dados de MLS em florestas boreais, aumentando a precisão posicional do MLS em ambientes florestais. Kuzelka et al. (2022) destacaram a eficiência do MLS na coleta de dados detalhados sobre a estrutura das árvores em inventários florestais. Li et al. (2024) investigaram sistemas compactos, como o escaneamento a *laser* montado em capacete, mostrando eficácia na coleta de dados estruturais florestais em tempo real.

Shao et al. (2020) avaliaram a eficácia de um sistema de mochila (BLS) sem GNSS-IMU para mapeamento de parcelas florestais, alcançando mapeamento preciso com baixos erros médios.

Stancioiu et al. (2022) compararam a medição de distâncias e áreas sob condições de dossel florestal, usando um *scanner a laser* móvel de mão e um sistema GNSS de mão, demonstrando maior precisão e eficiência do *scanner a laser* móvel em áreas com densa cobertura florestal. Tang et al. (2015) investigaram o uso de dados LiDAR móvel de pequeno porte auxiliado por SLAM para mapeamento de caules, mostrando a eficácia do sistema na detecção e mapeamento de caules, reduzindo significativamente o tempo de levantamento em campo.

A precisão e a densidade dos dados obtidos por meio dessas tecnologias permitem uma análise detalhada e precisa de estruturas complexas e ambientes variados (RIVEIRO et al., 2015; GEORGOPOULOS et al., 2024). Além disso, a mobilidade e a flexibilidade do MLS facilitam a coleta de dados em áreas de difícil acesso, oferecendo uma solução eficiente e robusta para o mapeamento tridimensional (PUENTE et al., 2014).

Bobrowski et al., (2023), discutiram as melhores práticas para usar o LiDAR do iPad Pro em procedimentos de aquisição de dados em florestas urbanas. O objetivo foi avaliar a precisão e a eficiência do iPad Pro LiDAR na coleta de dados em ambientes urbanos. Os resultados mostraram que o dispositivo foi uma ferramenta prática e econômica para inventários florestais urbanos, embora com algumas limitações em comparação com sistemas de coleta de dados LiDAR mais avançados.

Outro estudo comparou estruturas de árvores derivadas de sistemas de coleta de dados LiDAR aerotransportados, terrestres e móveis em parques urbanos. O objetivo foi determinar as diferenças na precisão e na cobertura de dados fornecidos por cada sistema. Os resultados indicaram que, embora todos os sistemas ofereçam vantagens únicas, os sistemas de coleta de LiDAR móveis e terrestres proporcionam uma maior precisão na medição de detalhes estruturais das árvores (CHOI & SONG, 2022).

Jiang et al. (2022), investigaram a simulação de diferentes padrões de escaneamento a *laser* móvel com aplicação estendida na iluminação de feixe solar para parcelas florestais. O estudo visava otimizar os padrões de escaneamento para melhorar a eficiência e a qualidade dos dados coletados. Os resultados mostraram que certos padrões de escaneamento são mais eficazes para diferentes tipos de

terreno e cobertura vegetal.

Ainda Launeau et al. (2018) investigaram sobre a análise de dados LiDAR de forma de onda completa para mapeamento de vegetação rasteira em dunas costeiras, mostrando como essa tecnologia pode ser usada para capturar detalhes precisos da vegetação de baixa altura. O método permitiu a discriminação de diferentes tipos de vegetação, contribuindo para a gestão e conservação de ecossistemas costeiros.

O estudo de Liang et al. (2014), explorou as possibilidades de um sistema de escaneamento a laser pessoal para mapeamento florestal e serviços ecossistêmicos. Os autores destacaram que esses sistemas portáteis podem ser usados para coletar dados detalhados sobre a estrutura da floresta, facilitando o monitoramento ambiental e a avaliação de serviços ecossistêmicos.

Em um estudo focado na concepção de um sistema de imagem 3D móvel baseado em LiDAR 2D, foi utilizada a otimização de Levenberg-Marquardt para calibrar os erros de montagem dos três eixos do LiDAR. Os resultados experimentais mostraram que o método proposto reduziu efetivamente a distorção da nuvem de pontos, tornando o sistema adequado para aplicações em grandes cenas (MIAO et al., 2022).

Já Mokros et al. (2021), apresentaram sistemas de mapeamento móvel de baixo custo para inventários florestais como alternativas ao escaneamento a *laser* terrestre. Os autores concluíram que esses sistemas móveis são viáveis para pequenos municípios ou projetos com orçamento limitado, especialmente quando combinados com tecnologias de processamento de imagens avançadas.

Qi et al. (2023) avaliaram os efeitos da severidade do fogo nas estruturas das árvores pós-incêndio usando nuvens de pontos fundidas de drones e escaneamento a laser móvel. Os resultados indicaram que a combinação dessas tecnologias pode fornecer dados detalhados sobre os impactos dos incêndios florestais na estrutura das árvores, auxiliando na gestão de áreas queimadas.

Por fim, uma pesquisa combinou o mapeamento de parcelas florestais assistido por SLAM com escaneamento a *laser* terrestre e móvel. O objetivo foi resolver problemas de consistência global e manter a precisão do mapeamento. Os resultados mostraram que a combinação das tecnologias melhorou significativamente a correspondência de pares e reduziu erros durante o mapeamento (SHAO et al., 2020).

Em suma, os estudos revisados demonstram que o MLS, quando combinado com outras tecnologias de sensoriamento remoto como ALS e UAV, oferece uma

ferramenta poderosa e precisa para a avaliação de inventários florestais. Essas combinações permitem medições detalhadas e precisas de atributos florestais essenciais para o manejo sustentável das florestas, superando muitas das limitações dos métodos tradicionais. A integração dessas tecnologias proporciona uma visão mais completa da estrutura florestal, facilitando a gestão eficiente e sustentável dos recursos florestais.

4.4.2. MLS Integrado a Tecnologias Complementares: UAV, GNSS, SLAM e Inteligência Artificial

O uso de tecnologias de varredura a *laser* móvel (MLS) em combinação com outras tecnologias de *laser scanning* tem mostrado resultados promissores para expressar e representar os ambientes florestais, melhorando a precisão e eficiência dos inventários florestais.

Jaakkola et al. (2017) tiveram como objetivo avaliar a viabilidade de um sistema de varredura a *laser* montado em UAV para medições florestais automatizadas. Utilizando um scanner *laser* Velodyne Puck LITE, os pesquisadores demonstraram que a coleta de dados sobre o diâmetro à altura do peito (dap), volume e biomassa de árvores individuais, pode ser realizada com uma precisão comparável aos métodos terrestres. Este estudo indicou que a abordagem baseada em UAV pode ser viável para coleta de referência florestal, ainda que mais pesquisas sejam necessárias para aprimorar a metodologia.

Giannetti et al. (2018) abordaram a integração de dados de varredura a *laser* aérea (ALS) e terrestre (TLS) em uma floresta mediterrânea mista. Os autores avaliaram a precisão de cinco atributos de árvores individuais usando *scanners* móveis manuais e estáticos. A integração de dados ALS com TLS e MLS melhorou significativamente a estimativa de altura das árvores e área de projeção da copa, mostrando que a combinação de técnicas pode aumentar a precisão das medições florestais.

Ao compararem diversas tecnologias emergentes de MLS operadas ao nível do solo ou sob o dossel florestal, Hyypä et al. (2020), incluíram *scanners* portáteis, de mochila e montados em UAV. O estudo revelou que todos os métodos MLS analisados conseguiram prever o volume do tronco das árvores com precisão comparável às medições manuais, destacando a viabilidade dessas tecnologias para medições operacionais de referência de campo em florestas boreais manejadas.

Qian et al. (2016) discutiram as limitações da precisão de posicionamento em florestas devido à perda de sinais GNSS e efeitos de *multipath*, propondo o uso de tecnologia SLAM integrada com GNSS/INS para melhorar a precisão de posicionamento do MLS. A abordagem H-aided SLAM mostrou melhorias na precisão do posicionamento em testes realizados em florestas, evidenciando seu potencial para aplicações em ambientes desafiadores.

Em seu estudo, Jones et al. (2021) analisaram o uso de varredura a *laser* móvel e terrestre para coleta de dados florestais, destacando que o MLS, apesar de fornecer dados de alta densidade e precisão, foi limitado pela necessidade de múltiplas varreduras devido à oclusão das árvores. A integração de MLS com UAVs pode resolver a visibilidade limitada dos topos das árvores, sugerindo que combinações de tecnologias podem oferecer soluções mais abrangentes para inventários florestais.

Já Ferrara et al. (2023), avaliaram diferentes sistemas de varredura a *laser* montados em UAV para coleta de dados acima do dossel. Os resultados indicaram que embora o UAV possa medir com precisão a altura das árvores e a área da copa, a estimativa direta do dap a partir de nuvens de pontos obtidas acima do dossel não alcançou precisão suficiente. A abordagem baseada em modelos de regressão se mostrou mais precisa, destacando a importância de estratégias indiretas para determinadas medições.

Por fim, Méndez et al. (2014) revisaram o estado atual das técnicas de coleta automatizada de dados de referência de campo. O estudo concluiu que o TLS fornece alta precisão na atualização de modelos florestais e amostras permanentes, enquanto o MLS melhora a eficiência da coleta de dados. No entanto, todas essas tecnologias dependem de operadores qualificados, sugerindo uma necessidade contínua de avanços na automação para aumentar a eficiência e reduzir os custos laborais.

4.4.3. Detecção E Segmentação Automática De Árvores Com MLS

O uso de *Mobile Laser Scanning* (MLS) tem se mostrado uma ferramenta eficaz para a detecção e segmentação automática de árvores em florestas. Diversos estudos encontrados na revisão sistemática abordam diferentes metodologias e resultados para essa aplicação. Comesaña-Cebral et al. (2021) desenvolveram um método de segmentação de árvores individuais utilizando dados de nuvem de pontos LiDAR obtidos por um sistema móvel de mochila. O objetivo foi melhorar a gestão florestal

por meio da detecção precisa de árvores, utilizando a técnica de *clustering* DBSCAN e voxelização de cilindro. Os resultados mostraram uma alta taxa de detecção (90%) e precisão acima de 93%.

Investigando o uso de um *smartphone* equipado com tecnologia RGB-D SLAM para estimar a posição das árvores, o diâmetro à altura do peito (dap) e a altura das árvores em tempo real, Fan et al. (2018) objetivaram tornar essa tecnologia acessível e prática para aplicações em campo. A metodologia incluiu a calibração do sistema e testes em várias condições ambientais, resultando em estimativas precisas com margem de erro mínima.

Hartley et al. (2022) avaliaram o potencial dos sistemas de escaneamento a *laser* móvel montados em mochilas para fenotipagem de árvores. O estudo comparou diferentes configurações de sensores e métodos de processamento de dados. O objetivo principal foi validar a eficácia desses sistemas para coletar dados precisos em ambientes florestais complexos. Os resultados indicaram que, embora desafiador, o sistema apresentou boa precisão na detecção de atributos fenotípicos das árvores.

No estudo de Holcomb et al. (2023), foi desenvolvido um método robusto para estimar o diâmetro das árvores a partir de imagens únicas capturadas por telefones móveis. O objetivo foi criar um sistema de baixo custo e fácil uso para medir árvores em áreas urbanas e florestais. O método se baseou em algoritmos de visão computacional e aprendizado de máquina, alcançando alta precisão na estimativa do diâmetro, mesmo com variações de iluminação e obstruções.

Li et al. (2023) propuseram um método baseado no algoritmo *iForest* melhorado para extração de troncos e remoção de ruído de árvores individuais em ruas. O objetivo foi otimizar a coleta de dados em áreas urbanas densamente arborizadas. A metodologia incluiu a segmentação inicial usando *iForest*, seguida por técnicas de filtragem para eliminar ruídos. Os resultados demonstraram uma melhoria significativa na precisão da segmentação e na clareza dos dados coletados.

Já Liu et al. (2022) exploraram a classificação de espécies de árvores usando dados LiDAR terrestres e diversos métodos de aprendizado profundo em nuvem de pontos. O objetivo foi desenvolver um sistema capaz de identificar espécies de árvores com alta precisão. A metodologia envolveu a aplicação de redes neurais convolucionais para processar os dados LiDAR, resultando em uma taxa de classificação elevada, contribuindo para o gerenciamento e conservação de florestas.

Em outro estudo, Liu et al. (2021) investigaram a segmentação de árvores

individuais e a estimativa do diâmetro à altura do peito (dap) utilizando LiDAR móvel. O objetivo foi aprimorar a precisão das medições florestais em ambientes desafiadores. A metodologia combinou técnicas de segmentação baseadas em *voxel* e *clustering* para identificar e medir árvores individualmente. Os resultados mostraram que a abordagem proposta era eficaz na segmentação precisa de árvores e na estimativa do dap, mesmo em florestas densas.

Assim, esses estudos demonstram o potencial do MLS na detecção e segmentação automática de árvores, oferecendo soluções inovadoras para a gestão florestal e urbana. A precisão e eficiência desses métodos variam conforme as técnicas utilizadas e as condições ambientais, mas todos contribuem significativamente para o avanço tecnológico nessa área.

4.4.4. Estimativas De Atributos Dendrométricos Com MLS: DAP, Altura, Volume e Estrutura

A estimativa de atributos de árvores utilizando a varredura a *laser* móvel (MLS) foi um dos temas centrais nas pesquisas florestais modernas, como destacado por diversos estudos recentes encontrados. Como exemplo, Hyypä et al. (2020) exploraram a derivação precisa de curvas de tronco e volume usando MLS de mochila.

O estudo tinha como objetivo melhorar a precisão das estimativas de volume de tronco em florestas boreais. Utilizando um *scanner* a *laser* Velodyne VLP-16, os pesquisadores realizaram varreduras em dois tipos de florestas, esparsas e densas. Os resultados mostraram que o sistema pode estimar a altura das árvores com um erro padrão de 40 cm na floresta esparsa e 1 m na floresta densa, e o volume dos troncos com um erro padrão de 10%.

Outro estudo significativo, conduzido por Hyypä et al. (2021), avaliaram a precisão da varredura a *laser* UAV sob dossel para fornecer estimativas de altura do dossel e volume de tronco. O objetivo era automatizar a coleta de dados de referência de campo. Ao utilizar um UAV equipado com um *scanner* rotativo Velodyne, o estudo demonstrou que foi possível medir a altura das árvores com um erro padrão de 1 m em florestas densas e 40 cm em florestas esparsas. Além disso, as estimativas de volume de tronco apresentaram um erro padrão de 8.6% na floresta densa e 12.5% na floresta esparsa.

Lin e Jiang (2018) desenvolveram um novo algoritmo para mensuração de DAP

(diâmetro à altura do peito) baseado em MLS. O objetivo do estudo era validar preliminarmente este algoritmo em uma floresta boreal urbana. Utilizando um sistema de varredura móvel, os pesquisadores conseguiram medir o DAP com alta precisão. Lopez Serrano et al. (2022) introduziram um *software* baseado em inteligência artificial (AID-Forest) para detecção de árvores, utilizando nuvens de pontos LiDAR. O objetivo era criar um inventário florestal rápido e preciso. O estudo utilizou nuvens de pontos adquiridas por LiDAR para detectar árvores e estimar seus atributos, alcançando alta precisão e velocidade na detecção e medição.

Pyörälä et al. (2018) realizaram uma avaliação quantitativa da estrutura de verticilos de pinheiro-silvestre usando varredura a *laser* terrestre. O objetivo era medir a estrutura dos verticilos em um ambiente florestal. Os resultados mostraram que a varredura a *laser* terrestre pode fornecer medições precisas da estrutura dos verticilos, contribuindo significativamente para a biometria florestal.

Por fim, Zhou et al. (2019) exploraram a extração do dap com um sistema LiDAR móvel portátil em um ambiente externo. O objetivo era avaliar a eficácia do LiDAR portátil na medição do dap em condições de campo. Os resultados demonstraram que o sistema portátil pode medir o dap com alta precisão, facilitando a coleta de dados de referência de campo. Em conclusão, os estudos revisados demonstram avanços significativos no uso de MLS para a estimativa de atributos de árvores. A precisão e eficiência das medições têm melhorado, tornando a MLS uma ferramenta indispensável para a inventariação florestal.

4.4.5. Aplicações do MLS em Ambientes Urbanos, Ecossistemas Naturais e Análises Ambientais

Ainda, o uso de *Mobile Laser Scanning* (MLS) em análises ambientais, urbanas e de vegetação tem se mostrado uma ferramenta poderosa para obter dados precisos e detalhados sobre diferentes aspectos do ambiente. Diversos estudos recentes demonstraram a eficácia do MLS em diferentes contextos. No estudo de Gresham et al. (2023), o objetivo foi analisar as vistas horizontais de grandes herbívoros em função da estrutura da vegetação. Utilizando MLS, foi possível quantificar a cobertura visual em diferentes alturas e verificar como as mudanças na estrutura florestal impactam a visibilidade dos herbívoros. Os resultados mostraram que a densidade da vegetação influencia significativamente a visibilidade dos animais, o que tem implicações para o

manejo da vida selvagem.

Hyypä et al. (2023) investigaram se os dados de percepção de veículos autônomos poderiam substituir os levantamentos tradicionais de mapeamento móvel para a análise de árvores urbanas. O estudo utilizou dados de MLS coletados por veículos autônomos para mapear árvores ao longo de estradas urbanas. Os resultados indicaram que, embora os dados de veículos autônomos possam complementar os métodos tradicionais, ainda existem limitações na precisão que precisam ser abordadas.

Utilizando MLS, o estudo conseguiu identificar e validar a presença de árvores com alta precisão. O método apresentou uma taxa de sucesso elevada na detecção automática de árvores, contribuindo para a gestão florestal. Aplicando o MLS para mapear e monitorar a vegetação ribeirinha usando uma abordagem baseada em área, Saarinen et al. (2013) avaliaram a precisão do MLS na detecção de diferentes tipos de vegetação ao longo de rios. Os resultados mostraram que o MLS é eficaz na detecção e monitoramento da vegetação, fornecendo dados valiosos para a gestão de recursos hídricos.

Também foi estudado sobre o uso do MLS para estimar atributos estruturais de árvores em uma floresta temperada de madeira dura (VANDENDAELE et al., 2022). Utilizando algoritmos de SLAM, o estudo conseguiu medir com precisão a altura das árvores, diâmetro à altura do peito (dap) e volume de madeira. Os resultados mostraram que o MLS pode fornecer dados precisos e detalhados que são essenciais para inventários florestais.

Wu et al. (2013) apresentaram um método baseado em *voxel* para identificação automatizada e estimativa de parâmetros morfológicos de árvores de rua usando dados de MLS. O estudo utilizou uma técnica de pesquisa de vizinhança marcada para identificar árvores e calcular parâmetros como altura, diâmetro da copa e dap. A metodologia mostrou alta precisão e eficiência na detecção de árvores urbanas. Yu et al. (2017) investigaram a classificação de espécies de árvores usando MLS multiespectral. O objetivo foi desenvolver uma solução de sensor único para o mapeamento florestal que forneça informações específicas sobre espécies. Os resultados indicaram que o MLS multiespectral pode classificar espécies de árvores com alta precisão, contribuindo para a gestão florestal.

Yun et al. (2016) propuseram uma nova abordagem para recuperar a área foliar de árvores usando LiDAR terrestre. Utilizando MLS, o estudo conseguiu separar

automaticamente as folhas dos galhos e calcular a área foliar com alta precisão. Este método inovador mostrou-se eficaz na estimativa de parâmetros de cobertura vegetal, essencial para estudos ecológicos. Para desenvolverem uma abordagem automatizada para extrair dados de inventário florestal de árvores individuais usando um scanner a laser móvel portátil, Zeybek e Vatandaşlar (2021) utilizaram algoritmos de SLAM para mapear árvores em florestas densas, mostrando que o MLS portátil pode fornecer dados precisos e detalhados rapidamente, facilitando o inventário florestal.

Por fim, Zhao et al. (2018) avaliaram a capacidade de sequestro de carbono e remoção de PM_{2.5} de árvores de rua urbanas usando dados de MLS. O estudo utilizou o MLS para medir a biomassa das árvores e estimar sua capacidade de remover poluentes do ar. Os resultados indicaram que as árvores urbanas desempenham um papel significativo na melhoria da qualidade do ar e mitigação das mudanças climáticas. Esses estudos demonstram a versatilidade e eficácia do MLS em diferentes contextos ambientais, urbanos e de vegetação, fornecendo dados essenciais para a gestão e conservação desses recursos.

4.5. CONCLUSÕES

A tecnologia de *Mobile Laser Scanning* (MLS) se destaca como uma ferramenta inovadora e eficiente para aplicações florestais. Nos últimos anos, o MLS demonstrou sua capacidade de fornecer medições precisas e detalhadas de atributos florestais, como volume de tronco, diâmetro à altura do peito (DAP) e altura das árvores, superando algumas limitações dos métodos tradicionais de inventário florestal.

Ao integrar o MLS com outras tecnologias de sensoriamento remoto, como dados LiDAR aéreo (ALS) e câmeras RGB em UAVs, a precisão e abrangência dos dados coletados aumentam significativamente. Essa combinação possibilita a modelagem tridimensional detalhada e a gestão sustentável das florestas, essenciais para a conservação da biodiversidade e o monitoramento de impactos ambientais.

Ademais, é fundamental adaptar as metodologias de análise do MLS para refletir as complexidades das florestas brasileiras, dado que todos os estudos revisados se concentram em florestas nórdicas. O contínuo desenvolvimento e a integração de novas tecnologias, como *scanners* portáteis e sistemas SLAM, têm o potencial de aprimorar ainda mais a eficiência e a precisão das medições com MLS.

Em resumo, o *Mobile Laser Scanning* é uma ferramenta promissora na era moderna do inventário florestal, contribuindo de maneira significativa para a gestão sustentável dos recursos florestais e a mitigação dos efeitos adversos das atividades humanas sobre esses ecossistemas vitais.

5. CAPÍTULO IV - CLASSIFICAÇÃO SUCESSIONAL EM FLORESTA OMBRÓFILA MISTA (FOM): UM ENFOQUE NO USO DO *MOBILE BACKPACK LIDAR* (MLS)

5.1. INTRODUÇÃO

A Mata Atlântica é reconhecida como um dos biomas mais biodiversos e ameaçados do planeta, abrigando uma elevada diversidade de espécies vegetais e animais, muitas delas endêmicas. A conservação e o manejo sustentável desse bioma são fundamentais não apenas para a manutenção da biodiversidade, mas também para a provisão de serviços ecossistêmicos essenciais, como a regulação climática, a proteção do solo e a oferta hídrica (MITTERMEIER et al., 2011; SCARANO, 2015).

Nesse contexto, o inventário florestal constitui uma ferramenta indispensável para o entendimento da estrutura, composição e dinâmica das formações vegetais, viabilizando diagnósticos precisos que subsidiam ações de conservação e restauração ecológica (CAMPOS & LEITE, 2013; CABRAL et al., 2023). A partir do inventário florístico-florestal é possível inferir informações sobre o estágio sucessional, definido como o grau de regeneração de uma floresta após a ocorrência de distúrbios naturais ou antrópicos.

O estágio sucessional configura-se como um dos principais indicadores para a classificação e avaliação de fragmentos florestais, sendo sua determinação indispensável para processos de diagnósticos das florestas, para os licenciamentos ambientais e para o planejamento do uso da terra. Tal definição está diretamente associada a diretrizes legais, como a Lei da Mata Atlântica (Lei nº 11.428/2006) e a Resolução CONAMA nº 002/1994/PARANÁ. Assim a avaliação precisa do estágio sucessional contribui significativamente para a elaboração de estratégias de conservação mais eficazes, embora os métodos tradicionais enfrentem limitações quanto à subjetividade e à aplicabilidade em escalas mais amplas.

Nesse panorama, o sensoriamento remoto tem emergido como uma alternativa eficiente aos inventários florestais convencionais, fornecendo dados precisos e espacialmente contínuos sobre a estrutura e composição da vegetação (SOUZA et al., 2020; SOTHE et al., 2024). Entre as tecnologias emergentes, destaca-se o *Light Detection and Ranging* (LiDAR), cuja capacidade de gerar nuvens de pontos

tridimensionais permite a mensuração de variáveis como altura do dossel, densidade de folhagem e complexidade estrutural com elevada resolução (CLARK et al., 2008; ROUSSEL et al., 2020; DALLA CORTE et al., 2022).

Dentro desse contexto, o uso de sensores móveis de varredura a *laser* (*Mobile Laser Scanning* – MLS) representa um avanço tecnológico disruptivo, sobretudo em ambientes de alta densidade florestal, como a Floresta Ombrófila Mista (FOM). Sistemas como o *LiBackpack* possibilitam a aquisição de dados tridimensionais de alta resolução de forma rápida, contínua e adaptável às condições do sub-bosque, superando limitações impostas a sensores aéreos em ambientes de dossel fechado (PUTTONEN et al., 2011; LI et al., 2019; POST et al., 2025).

Ainda, além da facilidade operacional em terrenos irregulares, o MLS tem demonstrado elevado potencial para a extração de métricas estruturais refinadas, como perfis verticais de densidade, estimativas precisas de altura de vegetação e a caracterização da complexidade do sub-bosque, parâmetros críticos para a identificação de padrões sucessionais (LI et al., 2019; JAASKELAINEN et al., 2024).

Aplicações recentes indicam que o uso do MLS pode ampliar significativamente a acurácia na caracterização de estágios sucessionais e na estimativa de atributos florestais estruturais, promovendo maior eficiência em programas de monitoramento florestal e redução do tempo e custo da coleta de dados em campo (PFEIFER et al., 2019; POST et al., 2025).

Considerando esse cenário, o presente estudo teve como objetivo propor uma abordagem inovadora voltada à avaliação de variáveis estruturais extraídas exclusivamente de nuvens de pontos LiDAR obtidas por sistema *Mobile Laser Scanning*. A hipótese central testada foi a de que as informações obtidas com a nuvem seriam capazes de discriminar os diferentes estágios sucessionais da vegetação secundária de Floresta Ombrófila Mista, com base em padrões captados da estrutura da vegetação.

Assim, este trabalho buscou investigar o potencial de uso da tecnologia MLS-LiDAR (*Mobile Laser Scanning*) para caracterização da estrutura vertical de remanescentes florestais em diferentes estágios sucessionais da floresta ombrófila mista (FOM).

5.2. MATERIAIS E MÉTODOS

5.2.1. Caracterização da Área de Estudo

O estudo foi conduzido na Fazenda Experimental Canguiri de propriedade da Universidade Federal do Paraná, localizada no município de Pinhais-PR, cujas coordenadas centrais são 25°23'30" S e 49°07'30" W (Figura 35). De acordo com a classificação climática de Köppen-Geiger, o clima da região é subtropical úmido (Cfb), caracterizado por verões amenos e invernos moderados, sem estação seca definida.

A precipitação média anual é de aproximadamente 1550 mm, enquanto a temperatura média anual é de 17°C. A área está situada a uma altitude de 935 metros acima do nível do mar (ALVARES et al., 2013).

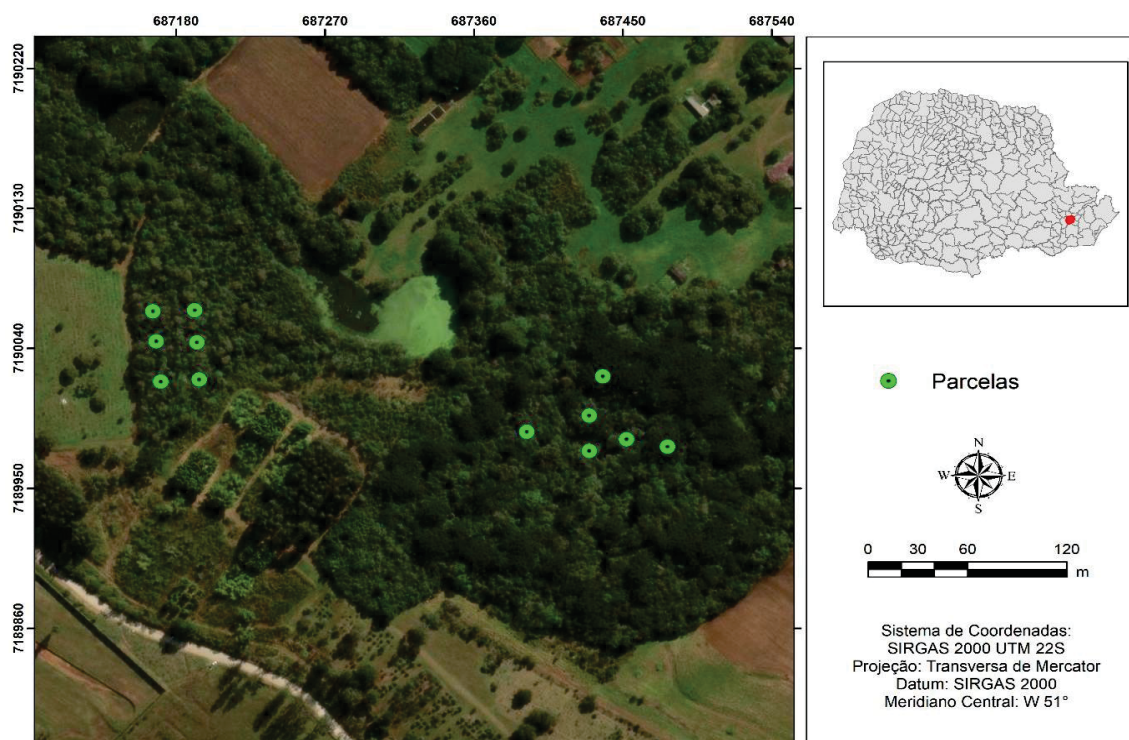


Figura 35. Mapa de localização da área de estudo e das parcelas utilizadas nesta fase.

Os solos predominantes na área de estudo incluem Cambissolos, Latossolos, Organossolos e Gleissolos, cada um com características particulares que influenciam a produtividade agrícola e a gestão do uso da terra. Cambissolos são solos jovens e bem drenados; Latossolos são profundos e bem desenvolvidos; Organossolos são ricos em matéria orgânica; e Gleissolos são frequentemente encontrados em áreas

de drenagem deficiente e sujeitas a alagamentos.

A vegetação predominante na região é classificada como Floresta Ombrófila Mista (FOM), esse tipo de vegetação desempenha um papel crucial na conservação da biodiversidade e no equilíbrio ecológico da região (IBGE, 1992). Segundo Sanquetta (1995), a estrutura vertical da FOM apresenta diferentes estratos, variando desde indivíduos emergentes de *Araucaria angustifolia* até espécies latifoliadas de sub-bosque, destacando sua complexidade ecológica e relevância para a sustentabilidade ambiental.

A Fazenda Experimental Canguiri possui uma relevância significativa para a pesquisa agropecuária e florestal, fornecendo uma base para estudos que visam aprimorar as práticas de cultivo, a conservação do solo e o manejo ambiental. A presença de diversas classes de solo e de vegetação nativa, com remanescentes próximos a 10 anos e alguns superiores a 30, e de floresta plantada faz da fazenda um local ideal para a condução de pesquisas que buscam entender as interações entre clima, solo e vegetação, bem como desenvolver tecnologias sustentáveis de produção agrícola.

5.2.2. Levantamento dos Dados de Campo

Os dados de inventário florestal (IF) utilizados neste estudo foram coletados em três campanhas realizadas em agosto de 2022. Foram utilizados dados de amostragem de 12 parcelas permanentes de 10 × 10 metros, totalizando uma área de 1.200 m². Inicialmente, estavam previstas a utilização dos dados de 30 parcelas; entretanto, não foi possível obter os dados de nuvem LiDAR de todas as parcelas devido a problemas tecnológicos de processamento operacional sistema *Mobile Laser Scanning* (MLS) em parte das áreas selecionadas, assim, a análise foi realizada com 12 parcelas. Este foi um problema pontual deste levantamento, em função dos recursos disponíveis na época, e não um problema associado a tecnologia diretamente.

Foram adotadas como referência para os Estágios Sucessionais as definições atribuídas às classes de vegetação previamente classificadas no Capítulo II utilizando os dados do inventário florestal. Essa classificação serviu como referência para as análises estruturais conduzidas neste capítulo utilizando dados MLS, assegurando a robustez metodológica e estando em consonância com práticas adotadas em estudos

similares (VATANDAŞLAR et al., 2023).

A escolha pelo delineamento amostral em parcelas de 10 × 10 metros fundamentaram-se em critérios técnicos voltados à eficiência de coleta e à representatividade estrutural em ambientes de elevada heterogeneidade, como as florestas tropicais. Estudos prévios indicam que unidades amostrais reduzidas são adequadas para capturar a variação estrutural local quando associadas a tecnologias de alta resolução, como o LiDAR MLS (VATANDAŞLAR et al., 2023).

Ademais, a utilização do sistema *LiBackpack* para aquisição dos dados MLS impôs limitações operacionais típicas de florestas densas e nativas, como obstruções da linha de visão, saturação do sinal, aspectos reconhecidos na literatura como desafios técnicos relevantes (LI et al., 2022). Embora parcelas de maiores dimensões possam apresentar vantagens em termos de redução da variabilidade local, a estratégia adotada priorizou a qualidade dos dados adquiridos e a viabilidade logística da operação em campo.

A localização e instalação das parcelas foram realizadas com o auxílio de receptor GPS de navegação e trena métrica. As alturas totais das árvores foram mensuradas utilizando o hipsômetro *Vertex IV*, enquanto os diâmetros à altura do peito (dap), a 1,30 metro do solo, foram obtidos por meio de fita diamétrica. Cada árvore mensurada foi identificada por numeração sequencial dentro da parcela, sendo que árvores com múltiplos fustes abaixo de 1,30 metro foram consideradas multicaule, com todos os fustes que atendiam ao diâmetro mínimo de inclusão mensurados e registrados com o mesmo número de indivíduo.

A coleta de dados foi iniciada sempre pelo vértice A, localizado no canto sudoeste (SW) da parcela, com a determinação dos demais vértices (B, C e D) realizada em sentido horário. Foram mensurados todos os indivíduos arbóreos vivos cujas bases do tronco estavam completamente dentro dos limites da parcela.

Todos os indivíduos arbóreos vivos, cujas bases dos troncos estavam completamente dentro dos limites da parcela, foram mensurados. A identificação das espécies foi realizada *in loco*, para aquelas não reconhecidas no campo, o material botânico foi coletado para posterior identificação no Herbário Escola de Florestas de Curitiba – EFC. A confirmação e atualização dos nomes científicos e das respectivas famílias foram feitas por meio de consulta à Lista de Espécies da Flora do Brasil, seguindo o sistema *Angiosperm Phylogeny Group III* (APG III, 2009).

5.2.3. Obtenção de Dados *Mobile Backpack* LiDAR (MLS)

5.2.3.1. Especificações Do Sensor LiDAR MLS

Os dados MLS foram adquiridos no mês de agosto de 2022, utilizando o equipamento LiBackpack DG50, conforme a *Green Valley International*, este equipamento é uma versão atualizada do sistema de varredura a *laser* de sensor duplo. O mesmo conta com um equipamento GNSS integrado e fornece modelo de nuvem de pontos 3D com informações de posicionamento absoluto altamente precisas, além disso, o equipamento ainda oferece a função de posicionamento absoluto.

Quanto a precisão relativa da nuvem de pontos coletada é de ≤ 3 cm e a precisão absoluta do posicionamento após o pós-processamento é de ≥ 5 cm. Conforme o quadro 1, seguem as especificações da LiBackpack DG50.

Quadro 1. Especificações do MLS LiDAR.

Sensor <i>Laser</i>	Velodyne VLP-16*2
Faixa de varredura	100 m
Precisão Relativa do Sistema	$\leq 3\text{cm}^*$
Operação e transferência de dados	WiFi connection (mobile phone, tablet) / Wired Ethernet connection (tablet)
Armazenamento a bordo	512 GB
Portas Disponíveis	HDMI, Ethernet & USB
Tempo de operação	~2 hour w/ DJI TB48S battery
Peso	9.3 kg sem bateria
Dimensões	1085*300*150 mm
Velocidade de solo típica	1 m/s
Máximo Consumo de energia	85 w
WiFi Band	2.4 GHz
Taxa de Varredura	600 kHz
FOV	V : -90° to +90° \ H : 360°
Display	UI via dispositivo móvel
Precisão de posicionamento GNSS	1 cm + 1 ppm
Precisão Absoluta do Sistema	$\leq 5\text{cm}^*$
Sinais GNSS	GPS: L1 C/A, L1C, L2C, L2P, L5 GLONASS: L1 C/A, L2C, L2P, L3,L5 BeiDou: B1,B2
Formato de dados de saída	las, laz, LiData, ply

*Afetado pela rota de varredura e ambiente.

Fonte: Green Valley International (2022)

5.2.3.2. Coleta da Nuvem de Pontos com *LiBackPack*

O preparo da área constituiu em primeiramente realizar a limpeza com abertura menos destrutiva possível de picada no entorno de cada parcela, de maneira que o usuário da mochila não tivesse que se abaixar ou houvesse algum tipo material que fosse obstáculo para a passagem com a mochila. Os dados com a MLS foram adquiridos em cada uma das 12 parcelas de pesquisa com o usuário caminhando de maneira lenta e constante ao redor da mesma. Foi realizado o método de caminhada livre para cobrir a área e sempre que possível, foi utilizado o caminho em linhas retas, porém, alguns obstáculos foram evitados, figura 36.




Figura 36. Método de caminhada para obtenção de dados LiDAR utilizando a *BackPack*.

O instrumento permaneceu nas costas do usuário, conforme figura 37 O caminhada foi concluído usando um circuito fechado e no final traçando a diagonal por dentro da parcela. Cada parcela levou menos de 5 minutos para varredura. Devido à distância das parcelas, e a quantidade de dados que é armazenado durante o caminhada, foram escaneadas em torno de 3 parcelas por vez, ou seja, inicia-se o sistema, caminha-se por 3 parcelas, para-se o sistema.



Figura 37. Representação da LiBackPack utilizada no estudo.

5.2.4. Processamento da Nuvem LiDAR

5.2.4.1. Processamento da Nuvem LiDAR

O processamento dos dados LiDAR foi conduzido no ambiente estatístico R (R CORE TEAM, 2023), utilizando o ecossistema do pacote *lidR* (ROUSSEL et al., 2020), seguindo o fluxo metodológico para inventário florestal com enfoque em unidade de área (DALLA CORTE et al., 2022). Inicialmente, aplicou-se o filtro de redundância espacial por meio da função *filter_duplicates*, eliminando pontos com coordenadas idênticas para assegurar a integridade estatística da nuvem e evitar vieses no cálculo de densidade (ROUSSEL, 2023).

A classificação dos pontos do terreno foi feita com o comando *classify_ground*, que aplica algoritmos de filtragem para identificar pontos pertencentes ao relevo. A partir dessa classificação, é possível gerar os modelos DTM (Digital Terrain Model) e DSM (Digital Surface Model), utilizando-se respectivamente os comandos *grid_terrain* e *grid_canopy*.

A etapa crítica de normalização da nuvem foi executada pela função *normalize_height*. A partir da nuvem normalizada, gerou-se o Modelo de Altura do Dossel (CHM), essencial para a extração de métricas de estrutura vertical. Para a análise local, as parcelas foram recortadas utilizando vetores *shapefile* com um *buffer*

periférico de 5 metros, totalizando amostras de 20 x 20 metros. Esse procedimento é fundamental para evitar a oclusão de copas situadas nas bordas e garantir a representatividade da diversidade estrutural (FSD) na unidade amostral (ATKINS et al., 2023).

5.2.4.2. Métricas Extraídas da Nuvem com o Pacote *lidR*

A extração de métricas estruturais foi realizada para cada unidade amostral por meio da função *cloud_metrics* do pacote *lidR* (ROUSSEL et al., 2020). As métricas foram selecionadas por sua capacidade de descrever a complexidade tridimensional e a heterogeneidade biológica, atributos fundamentais para a distinção de estágios sucessionais. As variáveis foram agrupadas conforme as seguintes propriedades:

- **Métricas de Centralidade e Extensão Vertical:** A altura máxima (z_{max}) e a altura média (z_{mean}) foram utilizadas como indicadores diretos do desenvolvimento ontogênico da floresta e da biomassa acima do solo (AGB) (SANAEL et al., 2018a). O desvio padrão das alturas (z_{sd}) quantificou a variação absoluta na organização vertical, sendo um descritor primário da Diversidade Estrutural Florestal (FSD) (ATKINS et al., 2023).
- **Indicadores de Distribuição e Forma:** O coeficiente de variação (z_{cv}) expressa a heterogeneidade relativa, permitindo comparar a complexidade entre parcelas com diferentes alturas médias (SANAEL et al., 2020). A assimetria (z_{skew}) e a curtose (z_{kurt}) da distribuição de alturas foram extraídas para caracterizar a distribuição da biomassa; valores de z_{skew} positivos indicam dosséis mais abertos com dominância de estratos inferiores, enquanto valores negativos sugerem dosséis fechados e maduros (FAGUA et al., 2021).
- **Índices de Complexidade e Densidade:** A entropia de Shannon ($z_{entropy}$) aplicada ao perfil vertical foi utilizada para medir a uniformidade da ocupação do espaço pelas copas, sendo um indicador de resiliência e maturidade sucessional (SENF et al., 2020). As métricas de densidade, como a proporção de pontos acima da média ($p_{zabovezmean}$) e acima de 2 metros ($p_{zabove2}$), permitiram quantificar o fechamento do dossel e a densidade do estrato arbóreo, diferenciando áreas em regeneração inicial de florestas estabelecidas (GOUGH et al., 2019; LARUE et al., 2019).

- **Perfil de Percentis e Penetração:** Extraíram-se os percentis de altura de zq5 a zq99. Os percentis inferiores (zq5 a zq25) foram correlacionados ao estrato de sub-bosque e regeneração, enquanto os superiores (zq75 a zq99) representam o estrato dominante e emergente (PRETZSCH et al., 2019). A proporção de no solo (pground) foi utilizada como um *proxy* para a abertura do dossel (fração de lacunas), refletindo a capacidade de penetração do feixe LiDAR em diferentes densidades de cobertura (FAGUA et al., 2021).

5.2.4.3. Simulação de Dados *Full-Waveform* a Partir de UAV-LiDAR

A simulação de sinais *Full-Waveform* (FWF) foi adotada para transpor as limitações dos sistemas de retorno discreto, permitindo a análise da distribuição contínua da energia refletida ao longo do perfil vertical da vegetação. Embora o sensor MLS adotado capture retornos discretos, a densidade de pontos possibilita a reconstrução da forma de onda, assemelhando-se aos dados gerados por sensores de grande pegada (*large footprint*), como o sistema GEDI (*Global Ecosystem Dynamics Investigation*) (DUBAYAH et al., 2020; JACON et al., 2024) (Figura 38).




Figura 38. Dados discretos x Dados FWF Simulados.

O processamento foi realizado no ambiente *R*, utilizando a integração dos pacotes *rGEDI* (Silva et al., 2019) e *rGEDIsimulator* (HANCOCK et al., 2019). O procedimento consistiu na simulação de *footprints* circulares de 20 metros de diâmetro, posicionados de forma a coincidir com o centro geográfico de cada unidade amostral. Para garantir a fidelidade da resposta espectral simulada, utilizou-se a nuvem de pontos original (não normalizada), permitindo que o algoritmo identificasse o retorno do solo e a estrutura do dossel em sua cota altimétrica real, conforme

recomendado para simulações de trajetória de feixe *laser* (SILVA et al., 2022).

O fluxo metodológico de simulação seguiu quatro etapas sistematizadas:

1. Filtragem e Preparação: Leitura dos arquivos em formato ".las" e remoção de ruídos espúrios abaixo do nível do solo;
2. Espacialização: Recorte das nuvens de pontos correspondentes aos limites dos *footprints* de 20 metros;
3. Geração da Forma de Onda: Aplicação da função *gediWFSimulator()*, que emula o sinal de retorno contínuo e armazena os dados em formato hierárquico .h5;
4. Extração de Métricas: Processamento dos arquivos .h5 pela função *gediWFMetrics()* para a derivação de descritores estruturais e biofísicos.

As métricas extraídas foram consolidadas em grupos funcionais para posterior análise discriminante dos estágios sucessionais:

1. Métricas de Energia e Perfil Vertical: Indicadores de altura absoluta e limites do sinal, como *trueTop*, *gHeight*, *maxGround*, *signalTop* e *signalBottom*.
2. Percentis de Distribuição (*rhGauss*): Valores de altura relativa (RH) em que determinadas porcentagens da energia acumulada de retorno são atingidas, extraídos de *rhGauss0* a *rhGauss100* em intervalos de 5%.
3. Parâmetros Morfológicos e de Densidade: Variáveis que descrevem a forma da onda e o fechamento do dossel, incluindo *leadingEdgeExt*, *trailingEdgeExtent*, *cover*, *gaussHalfCov* e *blairSense*.
4. Índices de Diversidade e Estrutura Foliar: Métricas complexas como a Diversidade da Altura da Folhagem (Foliage Height Diversity - FHD) e estimativas segmentadas de área foliar em estratos específicos, como *gLAI0t10* (0–10 m) e *gLAI10t20* (10–20 m) (JACON et al., 2024).
5. Variáveis Espectrais Avançadas: Indicadores de rugosidade e organização da onda, como a Razão de Retorno do Dossel (CRR), Peak End e Variância da Elevação da Forma de Onda (HFEV).

5.2.4.4. Análise Gráfica e Espacial da Estrutura Vertical (Voxelização e Curvas de Perfil)

Para validar e interpretar os padrões de estratificação identificados, aplicou-se uma abordagem complementar baseada na voxelização tridimensional e na análise de perfis verticais de energia. A voxelização consistiu na discretização da nuvem de pontos UAV-LiDAR em unidades volumétricas regulares (*voxels*) de 1 m³, utilizando a elevação original dos dados para mapear a ocupação do espaço real. Esta técnica permitiu a quantificação da densidade de retornos em camadas específicas, facilitando a identificação de lacunas estruturais (*gaps*) e a continuidade da biomassa, elementos críticos para distinguir florestas em regeneração inicial de estágios avançados (VIRIEUX et al., 2009; ALMEIDA, 2019).

Paralelamente, as curvas de perfil vertical foram geradas a partir do sinal contínuo simulado pela função *gediWFSimulator()*. Esses perfis representam a assinatura espectral vertical de cada parcela, ilustrando a intensidade da energia refletida em função da altura.

A integração entre a densidade volumétrica (*voxels*) e a resposta energética (FWF) proporciona uma base robusta para a validação cruzada dos dados estruturais (HAMAMURA, 2023). Enquanto a voxelização detalha a distribuição física dos pontos, as curvas de forma de onda sintetizam a complexidade da arquitetura da floresta, permitindo a observação direta da transição entre os estratos e a confirmação dos níveis de maturidade sucessional observados em campo.

5.2.5. Estruturação das Matrizes Preditoras e Consolidação do Banco de Dados

A consolidação das métricas estruturais e espectrais culminou na estruturação de matrizes de dados preditoras, organizadas para subsidiar os modelos de classificação e as análises multivariadas. Esta etapa foi delineada para permitir uma avaliação comparativa da sensibilidade dos diferentes fluxos de processamento (retorno discreto *versus* sinal simulado) na discriminação dos estágios sucessionais.

A integração buscou explorar a complementaridade entre descritores geométricos, derivados da nuvem de pontos, e indicadores energéticos, provenientes da simulação *Full-Waveform*, assegurando uma caracterização holística da arquitetura da Floresta Ombrófila Mista (ATKINS et al., 2023; JACON et al., 2024).

Para fins analíticos e de validação dos modelos de aprendizado de máquina, o

banco de dados foi estratificado em três cenários de modelagem:

- (i) Matriz de variáveis discretas, composta por métricas de altura, densidade e complexidade extraídas via pacote *lidR*;
- (ii) Matriz de variáveis simuladas (FWF), contendo os perfis de energia, percentis de Gauss e indicadores morfológicos da onda obtidos pelo rGEDI; e
- (iii) Matriz integrada, que combina a totalidade dos descritores estruturais e espectrais.

Essa abordagem de partição de dados foi essencial para identificar quais atributos possuem maior importância relativa na predição dos estágios de sucessão, permitindo isolar o potencial explicativo da geometria tridimensional em relação à resposta biofísica do sinal contínuo (ALMEIDA et al., 2019).

5.2.6. Análise Exploratória e Estatística Multivariada

A etapa analítica foi delineada para converter a complexidade tridimensional das nuvens de pontos em indicadores biológicos de sucessão. O fluxo seguiu uma progressão lógica, iniciando pela validação de pressupostos, seguida pela redução de redundância e culminando na identificação de gradientes ecológicos. Todas as análises foram conduzidas comparativamente para as três matrizes de dados: métricas de retorno discreto, métricas de simulação FWF e o conjunto híbrido (integrado).

5.2.6.1. Caracterização Estrutural e Pressupostos Estatísticos

A caracterização inicial dos estágios sucessionais baseou-se em estatísticas descritivas (média, mediana, desvio padrão e quartis) para todas as variáveis LiDAR. A normalidade das distribuições foi testada pelo critério de Shapiro-Wilk, enquanto a homogeneidade de variância foi avaliada pelo teste de Levene. Para métricas que apresentaram desvios significativos de normalidade ou alta curtose, aplicou-se a Transformação Normal Inversa Baseada em Ranks (RIN) para estabilizar as variâncias antes da aplicação de testes paramétricos (BISHARA & HITTNER, 2012).

A exploração visual da heterogeneidade interna das parcelas foi realizada

através de *Violin Plots*, que integram a densidade probabilística aos quartis dos *Boxplots* (HINTZE & NELSON, 1998). Esta abordagem permitiu detectar nuances na estratificação vertical e bimodalidades na distribuição de biomassa, fundamentando a interpretação ecológica dos picos de energia capturados pela simulação FWF.

5.2.6.2. Análise de Redundância e Seleção de Métricas

Complementarmente, realizou-se uma análise de correlação entre as métricas LiDAR para identificar redundâncias e avaliar a interdependência entre as variáveis. A multicolinearidade entre as métricas foi avaliada para quantificar o grau de interdependência e informar a seleção de um subconjunto de variáveis para modelagem posterior, visando a construção de modelos mais robustos e parcimoniosos.

5.2.6.3. Ordenação e Separabilidade dos Estágios Sucessionais

A identificação de padrões multivariados e gradientes ecológicos foi conduzida por meio de técnicas de ordenação complementares:

1. Análise de Componentes Principais (PCA): Utilizada para reduzir a dimensionalidade e identificar as métricas que explicam a maior variância estrutural. A retenção dos componentes foi validada pelo teste de Broken Stick e pelo critério de Kaiser (autovalores > 1).

2. Escalonamento Multidimensional Não-Métrico (NMDS): Aplicado para visualizar a similaridade entre as parcelas sem pressupostos de linearidade, utilizando a distância Euclidiana. A qualidade da representação foi monitorada pelo Stress de Kruskal (CLARKE, 1993). A significância estatística da separação entre os estágios foi testada via PERMANOVA.

5.2.6.4. Análise Preditiva e Classificação Automatizada

A modelagem preditiva com o algoritmo *Random Forest* foi conduzida com o objetivo de avaliar a capacidade discriminatória das métricas estruturais derivadas de dados LiDAR na classificação automatizada dos estágios sucessionais da Floresta Ombrófila Mista. A escolha deste algoritmo, originalmente proposto por Breiman (2001), fundamenta-se em sua reconhecida robustez diante de dados de alta dimensionalidade, presença de multicolinearidade e padrões não lineares,

características amplamente documentadas em estudos ecológicos baseados em sensoriamento remoto (CUTLER et al., 2007; OLDEN et al., 2008).

Os dados foram organizados a partir de uma planilha consolidada em formato .xlsx, contendo as métricas estruturais. A variável-resposta foi a classe de estágio sucessional (Inicial, Médio e Avançado), retirados da classificação realizada com o inventário florestal no capítulo I.

Como estratégia de pré-processamento, utilizou-se a técnica de *upsampling* com o argumento *sampling = 'up'* do pacote *caret*, para balancear as classes e evitar viés de predição causado por desbalanceamento amostral (KUHN & JOHNSON, 2013). O conjunto de preditores incluiu todas as métricas estruturais selecionadas após a análise exploratória e a remoção de variáveis altamente correlacionadas, conforme estudos prévios que destacam sua relevância na detecção de padrões sucessionais (PRETZSCH et al., 2019).

O treinamento do modelo foi realizado utilizando validação cruzada repetida do tipo *repeated k-fold cross-validation*, $k = 12$, assegurando a estratificação proporcional entre as classes em cada partição. Essa abordagem visou reduzir a variância das estimativas preditivas e proporcionar maior confiabilidade nos resultados (WITTEN et al., 2017). Os hiperparâmetros foram ajustados com *tuneLength = 5*, otimizando automaticamente os valores de *mtry*, *ntree = 250* e *maxnodes = 4*, sendo o índice *Kappa* o critério adotado para seleção do modelo mais apropriado (VIERA & GARRETT, 2005).

As métricas de avaliação do modelo incluíram acurácia global, precisão, sensibilidade, especificidade, F1-score, área sob a curva ROC (AUC), índice Kappa e o coeficiente de correlação de Matthews (MCC), uma métrica robusta para cenários com múltiplas classes e classes desbalanceadas (CHICCO & JURMAN, 2020).

A acurácia balanceada foi também computada como a média das acurácias individuais por classe. As predições foram analisadas quanto à incerteza por meio da maior probabilidade atribuída pelo modelo (*max_prob*), considerando classificações com probabilidade inferior a 0,6 como de alta incerteza (ROKACH, 2010).

5.3. RESULTADOS

5.3.1. Caracterização Estrutural dos Estágios Sucessionais com Variáveis LiDAR

5.3.1.1. Estatísticas Descritivas e Distribuição das Variáveis

5.3.1.1.1. Variáveis Discretas

Por meio da análise das variáveis discretas foi possível observar um padrão consistente de aumento estrutural ao longo do gradiente sucessional. O estágio inicial apresentou altura máxima média de 15,12 m ($\pm 1,31$ m), com variação entre 13,61 m (parcela 7) e 16,00 m (parcela 9). A altura média foi de 2,19 m, variando entre 2,06 m (parcela 3) e 2,31 m (parcela 7), indicando que a altura média do dossel permaneceu relativamente constante apesar da variação em z_{max} . A dispersão vertical, medida pelo desvio-padrão das alturas, foi de 2,17 m, com valores entre 1,89 m (parcela 3) e 2,34 m (parcela 9), indicando uma estrutura vertical relativamente simples com baixa heterogeneidade (figura 39).

O estágio intermediário apresentou valores intermediários, com z_{max} de 15,51 m ($\pm 0,64$ m), variando entre 15,04 m (parcela 4) e 16,00 m (parcelas 24 e 26), indicando consolidação gradual do dossel. A altura média foi de 2,21 m ($\pm 0,24$ m), variando entre 1,97 m (parcela 8) e 2,54 m (parcelas 24 e 26), mostrando maior variabilidade que o estágio inicial. A dispersão vertical foi de 2,29 m ($\pm 0,48$ m), variando entre 2,01 m (parcela 4) e 2,56 m (parcela 24), refletindo o início da multiestratificação. A assimetria foi de 1,68 ($\pm 0,32$), variando entre 1,44 (parcela 24) e 2,01 (parcela 25), mantendo-se elevada, porém com maior variabilidade entre parcelas, sugerindo heterogeneidade estrutural característica de estágios em transição.

Para o estágio mais avançado, a altura máxima foi de 16,00 m, refletindo um dossel mais uniforme em altura máxima. A altura média foi de 2,57 m ($\pm 0,22$ m), variando entre 2,42 m (parcela 23) e 2,86 m (parcela 28), representando um aumento de 17,4% em relação ao estágio inicial. A dispersão vertical foi máxima neste estágio, com 2,74 m ($\pm 0,44$ m), variando entre 2,37 m (parcela 23) e 3,40 m (parcela 28), indicando maior complexidade vertical e multiestratificação bem desenvolvida.




Figura 39. Gráfico de violino de zmax, zmean e zsd.

A assimetria (skewness) foi de 1,61 ($\pm 0,60$), variando entre 0,92 (parcela 7) e 2,01 (parcela 9), sugerindo distribuição enviesada para valores inferiores, típica de florestas jovens com concentração de biomassa nos estratos baixos. A curtose foi de 7,13 ($\pm 3,15$), variando entre 3,49 (parcela 7) e 8,99 (parcela 2), indicando distribuições leptocúrticas com caudas pesadas, refletindo a presença de múltiplos estratos verticais mesmo em estágios iniciais. A entropia foi de 0,663 ($\pm 0,032$), variando entre 0,64 (parcelas 2 e 3) e 0,70 (parcela 7), sugerindo que a organização estrutural foi relativamente consistente entre parcelas iniciais (figura 40).

No intermediário, a curtose foi de 6,72 ($\pm 0,86$), variando entre 5,40 (parcela 24) e 8,16 (parcela 25), indicando distribuições leptocúrticas similares ao estágio inicial. A entropia foi de 0,652 ($\pm 0,027$), variando entre 0,62 (parcela 8) e 0,71 (parcela 24), mostrando redução em relação ao estágio inicial, sugerindo maior organização estrutural.

No estágio avançado, a assimetria foi de 1,72 ($\pm 0,23$), variando entre 1,68 (parcela 28) e 1,77 (parcela 23), mantendo-se elevada mas com menor variabilidade que o estágio intermediário, sugerindo estrutura mais organizada e consistente entre parcelas. A curtose foi de 6,38 ($\pm 1,32$), variando entre 5,37 (parcela 28) e 7,55 (parcela 27), indicando distribuições leptocúrticas similares aos estágios anteriores. A entropia foi de 0,703 ($\pm 0,025$), variando entre 0,68 (parcelas 23 e 27) e 0,73 (parcela 28), mostrando aumento em relação ao estágio intermediário, sugerindo que a maior complexidade de dosséis maduros resultou em maior entropia.




Figura 40. Gráfico de violino de zskew, zkurt e zentropy.

A proporção de pontos acima da altura média (pzabovemean) no estágio inicial foi de 41,22% ($\pm 1,04\%$), variando entre 40,18% (parcela 9) e 42,26% (parcela 2), indicando que aproximadamente 41% da nuvem de pontos situou-se acima da altura média. A proporção de pontos acima de 2 m (pzabov2) foi de 44,83% ($\pm 1,94\%$), variando entre 42,79% (parcela 9) e 46,65% (parcela 7), sugerindo que aproximadamente 45% da nuvem de pontos situou-se acima de 2 m em todas as parcelas iniciais. Os percentis de altura revelaram padrão gradual de distribuição. O zq20 foi de 0,09 m ($\pm 0,16$ m), variando entre 0,00 m (parcelas 3 e 7) e 0,27 m (parcela 2), indicando que 20% dos pontos situaram-se próximos ao solo (figura 41).

Para o estrato intermediário, a proporção de pontos acima da altura média foi de 38,49% ($\pm 5,38\%$), variando entre 30,18% (parcela 27) e 43,38% (parcela 3), indicando maior variabilidade que o estágio inicial. A proporção de pontos acima de 2 m foi de 43,36% ($\pm 2,85\%$), variando entre 40,00% (parcela 8) e 48,64% (parcela 24), mostrando aumento em relação ao estágio inicial.

No avançado, a proporção de pontos acima da altura média foi de 35,90% ($\pm 3,42\%$), variando entre 30,18% (parcela 27) e 36,18% (parcela 23), indicando redução consistente em relação aos estágios anteriores, coerente com o aumento de altura média. A proporção de pontos acima de 2 m foi de 45,77% ($\pm 2,47\%$), variando entre 41,03% (parcela 27) e 48,64% (parcela 24), mostrando aumento em relação aos estágios anteriores.




Figura 41. Gráfico de violino de pزابovezmean, pزابove2 e zq20.

No estágio inicial, o zq50 (mediana) foi de 1,99 m ($\pm 0,10$ m), variando entre 1,89 m (parcela 2) e 2,09 m (parcela 7), refletindo a altura mediana do dossel. O zq75 foi de 3,71 m ($\pm 0,48$ m), variando entre 3,03 m (parcela 7) e 4,26 m (parcela 9), indicando que 75% dos pontos situaram-se abaixo de aproximadamente 3,7 m. O zq95, particularmente informativo, foi de 6,01 m ($\pm 0,43$ m), variando entre 5,52 m (parcela 2) e 6,30 m (parcela 9), indicando que apenas 5% dos pontos situaram-se acima de 6,0 m, refletindo a baixa altura do dossel superior.

Os percentis de altura do estágio médio foram intermediários. O zq50 foi de 1,93 m ($\pm 0,12$ m), variando entre 1,77 m (parcela 8) e 2,22 m (parcela 24), indicando redução leve em relação ao estágio inicial. O zq75 foi de 4,11 m ($\pm 0,29$ m), variando entre 3,36 m (parcela 4) e 4,28 m (parcela 24), mostrando aumento em relação ao estágio inicial. O zq95 foi de 6,99 m ($\pm 1,91$ m), variando entre 5,65 m (parcela 8) e 10,13 m (parcela 27), indicando maior variabilidade e presença de parcelas com dosséis mais altos.

Quanto ao avançado, os percentis de altura foram os mais elevados. O zq50 foi de 2,04 m ($\pm 0,14$ m), variando entre 1,90 m (parcela 23) e 2,22 m (parcela 24), mostrando aumento em relação aos estágios anteriores. O zq75 foi de 4,18 m ($\pm 0,61$ m), variando entre 3,60 m (parcela 23) e 4,97 m (parcela 28), indicando elevação progressiva dos estratos superiores. O zq95 foi de 8,46 m ($\pm 1,59$ m), variando entre 7,47 m (parcela 23) e 10,83 m (parcela 28), indicando que o percentil 95 aumentou em 40,8% do estágio inicial (6,01 m) para o avançado (8,46 m), refletindo elevação substancial dos estratos superiores.




Figura 42. Gráfico de violino de zq50, zq75 e zq95.

A proporção de retornos no solo (pground) foi elevada no estágio inicial, com média de 21,61% ($\pm 2,58\%$), variando entre 19,11% (parcela 2) e 24,27% (parcela 9). Esta elevada penetração do feixe *laser* foi coerente com a interpretação de dosséis abertos e permeáveis, permitindo que o sinal alcançasse o solo florestal com facilidade. Para o estágio médio, a proporção de retornos no solo foi de 21,38% ($\pm 3,48\%$), variando entre 16,69% (parcela 26) e 26,66% (parcela 8), mostrando redução em relação ao estágio inicial, indicando maior fechamento do dossel.

No avançado, a proporção de retornos no solo foi de 19,55% ($\pm 2,21\%$), variando entre 16,88% (parcela 23) e 21,53% (parcela 27), mostrando redução consistente em relação aos estágios anteriores, indicando menor penetração do feixe laser em dosséis mais fechados. A redução de pground de 21,61% (inicial) para 19,55% (avançado) foi de 9,5%, padrão consistente com a ecologia do sistema.




Figura 43. Gráfico de violino de pground.

5.3.1.1.2. Variáveis *Full-Waveform* Simuladas

A análise das variáveis *Full-Waveform* revelou padrões complementares aos observados nas métricas discretas, capturando aspectos da distribuição energética vertical não inteiramente representados pela nuvem de pontos.

No estágio inicial, a altura do eco (gHeight) foi de 925,16 m ($\pm 1,39$ m) no estágio inicial, variando entre 924,13 m (parcela 7) e 926,74 m (parcela 2), refletindo a cota altimétrica real em que a simulação foi conduzida. No estágio intermediário, gHeight foi de 924,00 m ($\pm 3,69$ m), variando entre 918,91 m (parcela 26) e 927,73 m (parcela 4), mostrando maior variabilidade. No estágio avançado, gHeight foi de 919,35 m ($\pm 1,05$ m), variando entre 918,11 m (parcela 24) e 920,95 m (parcela 23), indicando redução progressiva da altura do eco (figura 44).




Figura 44. Gráfico de violino de gHeight.

O sinal no topo do eco (signal.top) foi de 938,65 m ($\pm 3,12$ m) no estágio inicial, variando entre 935,06 m (parcela 7) e 940,65 m (parcela 9), indicando que o topo do eco se situou em altitudes elevadas. No estágio intermediário, signal.top foi de 937,11 m ($\pm 2,05$ m), variando entre 933,40 m (parcela 26) e 939,14 m (parcela 27), mostrando redução progressiva. No estágio avançado, signal.top foi de 936,00 m ($\pm 1,88$ m), variando entre 933,85 m (parcela 23) e 939,14 m (parcela 27), indicando redução progressiva da altura do topo do eco com a sucessão.

O sinal no fundo (signal.bottom) foi de 922,15 m ($\pm 1,15$ m) no estágio inicial, variando entre 921,26 m (parcela 7) e 923,45 m (parcela 2), indicando que o fundo do eco penetrou até altitudes moderadas. No estágio intermediário, signal.bottom foi de 920,49 m ($\pm 2,86$ m), variando entre 915,04 m (parcela 24) e 923,18 m (parcela 4),

mostrando maior variabilidade. No estágio avançado, signal.bottom foi de 916,35 m ($\pm 0,99$ m), variando entre 915,04 m (parcela 24) e 917,20 m (parcela 25), sugerindo que o fundo do eco penetrou menos profundamente em dosséis mais fechados, com redução de 5,8 m (5,8%) em relação ao estágio inicial (figura 45).




Figura 45. Gráfico de violino de signal.top e signal.bottom.

A extensão da borda frontal (leading.edge.extent) foi de 8,50 m ($\pm 2,79$ m) no estágio inicial, variando entre 5,55 m (parcela 7) e 11,10 m (parcela 9), indicando variabilidade moderada. No estágio intermediário, leading.edge.extent foi de 9,03 m ($\pm 2,64$ m), variando entre 6,30 m (parcela 4) e 13,05 m (parcela 27), mostrando aumento. No estágio avançado, leading.edge.extent foi de 11,85 m ($\pm 1,65$ m), variando entre 10,05 m (parcela 23) e 13,50 m (parcela 28), indicando que a borda frontal do eco foi mais extensa em dosséis mais complexos, com aumento de 39,4% do estágio inicial para o avançado.

A extensão da borda traseira (trailing.edge.extent) foi de 1,95 m ($\pm 0,26$ m) no estágio inicial, variando entre 1,65 m (parcelas 9) e 2,10 m (parcelas 2 e 7), sugerindo que a cauda do eco foi pronunciada em estágios iniciais. No estágio intermediário, trailing.edge.extent foi de 2,01 m ($\pm 0,27$ m), variando entre 1,80 m (parcela 25) e 2,25 m (parcelas 4 e 24), mostrando estabilidade. No estágio avançado, trailing.edge.extent foi de 1,80 m ($\pm 0,12$ m), variando entre 1,65 m (parcelas 27 e 28) e 2,10 m (parcela 23), sugerindo que a cauda do eco foi menos pronunciada em estágios avançados (figura 46).




Figura 46. Gráfico de violino de trailing.edge.extent.

Os percentis de energia acumulada (rhGauss.0 a rhGauss.100) exibiram padrão claro de deslocamento da energia para estratos superiores com a sucessão. O rhGauss.0 foi de -0,96 ($\pm 0,21$) no estágio inicial, variando entre 1,19 m (parcela 2) e 0,78 m (parcela 7), refletindo a posição relativa do primeiro retorno. No estágio intermediário, rhGauss.0 foi de 1,38 ($\pm 0,88$), variando entre 2,37 m (parcela 4) e 0,97 m (parcela 24), mostrando maior variabilidade. No estágio avançado, rhGauss.0 foi de 0,94 ($\pm 0,21$), variando entre -1,16 m (parcela 25) e 0,54 m (parcela 23), refletindo a posição relativa do primeiro retorno.

O rhGauss.50 (mediana de energia) foi de 1,79 m ($\pm 0,24$ m) no estágio inicial, variando entre 1,64 m (parcela 2) e 2,07 m (parcela 7), indicando que a mediana de energia se situou em alturas baixas. No estágio intermediário, rhGauss.50 foi de 2,10 m ($\pm 0,80$ m), variando entre 0,85 m (parcela 4) e 2,33 m (parcela 24), mostrando deslocamento progressivo da energia para alturas maiores. No estágio avançado, rhGauss.50 foi de 2,06 m ($\pm 0,33$ m), variando entre 1,90 m (parcela 23) e 2,22 m (parcela 24), indicando deslocamento progressivo da energia para alturas maiores (figura 47).




Figura 47. Gráfico de violino de rhGauss 50.

O rhGauss.95 foi de 6,19 m ($\pm 0,68$ m) no estágio inicial, variando entre 5,41 m (parcela 2) e 6,59 m (parcela 9), indicando que 95% da energia situou-se abaixo de 6,2 m. No estágio intermediário, rhGauss.95 foi de 6,75 m ($\pm 2,39$ m), variando entre 4,53 m (parcela 27) e 10,27 m (parcela 27), mostrando grande variabilidade. No estágio avançado, rhGauss.95 foi de 8,44 m ($\pm 1,75$ m), variando entre 6,06 m (parcela 23) e 10,89 m (parcela 28), padrão coerente com o aumento de altura observado nas métricas discretas, com aumento de 36,3% do estágio inicial para o avançado (figura 48).




Figura 48. Gráfico de violino de rhGauss 95.

A cobertura do eco (cover) foi de 0,597 ($\pm 0,031$) no estágio inicial, variando entre 0,85 (parcela 2) e 0,96 (parcelas 7 e 9), indicando cobertura elevada. No estágio intermediário, cover foi de 0,464 ($\pm 0,285$), variando entre 0,24 (parcela 4) e 0,96 (parcela 8), mostrando grande variabilidade. No estágio avançado, cover foi de 0,590 ($\pm 0,078$), variando entre 0,54 (parcela 28) e 0,97 (parcela 28), sugerindo que a cobertura foi menor no estágio intermediário, possivelmente refletindo a heterogeneidade estrutural característica de estágios em transição.

A altura máxima do eco (maxGround) foi de 4,07 m ($\pm 0,044$ m) no estágio inicial, variando entre 4,02 m (parcela 2) e 4,10 m (parcela 7), indicando consistência elevada. No estágio intermediário, maxGround foi de 4,08 m ($\pm 0,062$ m), variando entre 4,02 m (parcela 27) e 4,17 m (parcela 24), mostrando estabilidade. No estágio avançado, maxGround foi de 4,20 m ($\pm 0,100$ m), variando entre 4,10 m (parcela 27) e 4,30 m (parcela 28), indicando aumento progressivo da altura máxima do eco de 3,2% do estágio inicial para o avançado.

A diversidade da altura da folhagem (FHD) foi de 2,97 ($\pm 0,044$) no estágio inicial, variando entre 4,02 m (parcela 3) e 4,10 m (parcela 7), com valores

relativamente constantes entre parcelas. No estágio intermediário, FHD foi de 2,91 ($\pm 0,117$), variando entre 4,04 m (parcela 8) e 4,26 m (parcela 24), mostrando estabilidade. No estágio avançado, FHD foi de 3,00 ($\pm 0,059$), variando entre 4,12 m (parcela 23) e 4,30 m (parcela 28), sugerindo que a diversidade vertical foi similar em todos os estágios (figura 49).




Figura 49. Gráfico de violino de FHD.

A diversidade da altura da folhagem calculada a partir do Gaussian (FHDcanGauss) foi de 1,82 ($\pm 0,297$) no estágio inicial, variando entre 2,77 m (parcela 3) e 3,02 m (parcela 7), indicando valores moderados. No estágio intermediário, FHDcanGauss foi de 1,68 ($\pm 0,282$), variando entre 2,80 m (parcela 4) e 3,06 m (parcela 24), mostrando redução. No estágio avançado, FHDcanGauss foi de 1,42 ($\pm 0,117$), variando entre 3,01 m (parcela 28) e 3,04 m (parcela 23), indicando redução progressiva da diversidade (figura 50).




Figura 50. Gráfico de violino de FHDcanGauss.

5.3.1.2. Análise de Relações Entre Variáveis LiDAR

5.3.1.3. Dados Discretos

A matriz de correlação das variáveis discretas apresentou a estrutura esperada, com forte colinearidade entre percentis adjacentes e associação consistente entre métricas de altura. O z_{max} correlacionou-se de forma fraca e positiva com z_{mean} ($r = 0,326$), coerente com a relação entre altura máxima e altura média (SANTOS, 2007). Os percentis de altura (zq_{20} a zq_{95}) exibiram correlações fortemente positivas entre si, sobretudo entre percentis contíguos (por exemplo, zq_{90} – zq_{95} : $r = 0,945$), sugerindo redundância informacional nos percentis superiores.

A z_{mean} apresentou correlação moderada com zq_{75} ($r = 0,634$) e fortemente positiva com percentis mais altos (zq_{85} : $r = 0,900$; zq_{90} : $r = 0,948$; zq_{95} : $r = 0,902$), indicando maior influência dos estratos superiores na altura média. A dispersão vertical (zsd) também se associou fortemente à z_{mean} ($r = 0,878$), sugerindo maior heterogeneidade vertical em dosséis mais altos. A assimetria ($zskew$) apresentou correlação fraca e negativa com z_{mean} ($r = -0,318$), indicando menor enviesamento das distribuições em dosséis mais desenvolvidos.

A entropia ($zentropy$) correlacionou-se fortemente e positivamente com z_{mean} ($r = 0,943$), indicando aumento de complexidade estrutural em dosséis mais altos. Por outro lado, $p_{zabovezmean}$ apresentou correlação moderada e negativa com z_{mean} ($r = -0,775$). Ainda, p_{ground} correlacionou-se moderadamente e negativamente com z_{mean} ($r = -0,775$) e fortemente e negativamente com zq_{95} ($r = -0,913$), indicando que dosséis mais altos e fechados reduzem a penetração do feixe até o solo.

5.3.1.4. Dados FWF Simulados

Os percentis de energia acumulada ($rhGauss.0$ a $rhGauss.100$) apresentaram correlações fortemente positivas entre si, sobretudo entre percentis contíguos (por exemplo, $rhGauss.5$ – $rhGauss.10$: $r = 0,992$; $rhGauss.10$ – $rhGauss.15$: $r = 0,992$). Esse padrão indica elevada redundância informacional, de forma semelhante ao observado para os percentis das métricas discretas.

A extensão da borda frontal ($leading.edge.extent$) correlacionou-se moderadamente e negativamente com $gHeight$ ($r = -0,690$), sugerindo que, à medida que a altura característica aumenta, a borda frontal tende a se tornar menos extensa

(isto é, a transição inicial da energia/retornos ocorre de modo mais concentrado). A diversidade de altura da folhagem (FHD) apresentou correlação moderada e positiva com percentis superiores de energia (por exemplo, rhGauss.75: $r = 0,593$; rhGauss.80: $r = 0,713$), indicando associação entre maior heterogeneidade vertical e a distribuição de energia nos níveis superiores. Por fim, FHDcanGauss correlacionou-se fortemente e positivamente com FHD ($r = 0,957$), sugerindo que ambas as métricas capturam aspectos convergentes da heterogeneidade vertical.

5.3.2. Padrões Multivariados e Gradientes Ecológicos

5.3.2.1. Análise de Componentes Principais

5.3.2.1.1. Dados Discretos

A PCA aplicada às métricas discretas (figura 51) revelou que os três primeiros componentes explicaram 92,15% da variância total. O primeiro componente (CP1) apresentou autovalor de 10,995, respondendo por 43,98% da variância, enquanto o segundo componente (CP2) apresentou autovalor de 6,589, acrescentando 26,36%, e o terceiro componente (CP3) apresentou autovalor de 5,453, contribuindo com 21,81%. Esta distribuição de variância indicou que a estrutura dos dados foi capturada por um número reduzido de dimensões, justificando a análise em duas dimensões para visualização.

O CP1 foi indicado principalmente métricas de altura e fechamento do dossel, com cargas elevadas para z_{max} , z_{mean} , percentis superiores ($zq75$ – $zq95$) e entropia, enquanto p_{ground} apresentou carga negativa elevada. Este padrão indicou que o CP1 sintetizou um gradiente de "altura e fechamento do dossel", com valores mais altos correspondendo a dosséis mais altos e fechados. O CP2 foi influenciado por medidas de dispersão vertical (zsd , $zskew$) e índices de diversidade (entropia, VDI), capturando um gradiente secundário de "heterogeneidade e multiestratificação".




Figura 51. Biplot PCA dados Discretos.

5.3.2.1.2. Dados *Full-Waveform* Simulados

A análise de componentes principais aplicada às métricas *Full-Waveform* simuladas (figura 52) revelou que os três primeiros componentes explicaram 91,46% da variância total. O primeiro componente (CP1) apresentou autovalor de 22,757, respondendo por 71,12% da variância, enquanto o segundo componente (CP2) apresentou autovalor de 4,694, acrescentando 14,67%, e o terceiro componente (CP3) apresentou autovalor de 1,817, contribuindo com 5,68%. A concentração de variância no CP1 foi notavelmente maior que no cenário discreto, indicando que um único eixo capturou a maior parte da variação estrutural.

O CP1 foi dominado por percentis de energia acumulada (rhGauss.0 a rhGauss.100), com cargas elevadas para percentis superiores e cargas negativas para percentis inferiores. Este padrão indicou que o CP1 sintetizou um gradiente de "distribuição vertical de energia", com valores mais altos correspondendo a maior concentração de energia em estratos superiores. O CP2 foi influenciado por medidas de forma de onda (leading.edge.extent, trailing.edge.extent) e diversidade (FHD, FHDcanGauss), capturando um gradiente secundário de "complexidade da forma de onda".




Figura 52. *Biplot* PCA dados FWF simulados.

5.3.2.1.3. Dados Integrados

A análise de componentes principais aplicada ao conjunto integrado (figura 53) de métricas revelou que os três primeiros componentes explicaram 81,52% da variância total. O primeiro componente (CP1) apresentou autovalor de 27,982, respondendo por 49,09% da variância, enquanto o segundo componente (CP2) apresentou autovalor de 10,401, acrescentando 18,25%, e o terceiro componente (CP3) apresentou autovalor de 8,081, contribuindo com 14,18%. A distribuição de variância foi intermediária entre os cenários discreto e *Full-Waveform*, refletindo a complementaridade entre as duas fontes de dados.

O CP1 foi influenciado por uma combinação de métricas discretas (z_{max} , z_{mean} , percentis superiores) e *Full-Waveform* (percentis de energia superiores), sintetizando um gradiente integrado de "altura e distribuição vertical de energia". O CP2 foi influenciado por medidas de dispersão (z_{sd} , z_{skew}) e complexidade de forma de onda (leading.edge.extent, FHD), capturando um gradiente secundário de "heterogeneidade vertical e complexidade estrutural".




Figura 53. Biplot PCA dados Integrados.

5.3.2.2. Escalonamento Multidimensional Não-Métrico (NMDS)

O Escalonamento Multidimensional Não-Métrico foi utilizado para representar, em duas dimensões, as dissimilaridades multivariadas entre parcelas, preservando a ordem das distâncias sem assumir linearidade. A qualidade do ajuste foi avaliada pelo valor de stress, com valores inferiores a 0,20 indicando representação adequada.

Para o cenário discreto, o stress obtido foi de 0,109, indicando representação boa, porém com dispersão moderada das distâncias. A ordenação revelou separação entre estágios, com o estágio inicial e avançado em regiões distintas do espaço, enquanto o estágio intermediário ocupou posição intermediária com sobreposição parcial com ambos os extremos. As elipses de confiança foram amplas, refletindo maior variabilidade intragrupo.

Para o cenário *Full-Waveform*, o stress obtido foi de 0,028, indicando representação excelente com alta fidelidade das relações de dissimilaridade. A ordenação revelou separação muito clara entre estágios, com o estágio inicial isolado em uma região do espaço, o estágio avançado em região oposta, e o estágio intermediário em posição intermediária. As elipses de confiança foram compactas, refletindo menor variabilidade intragrupo e maior consistência estrutural quando

avaliada pela perspectiva energética.

Para o cenário integrado, o stress obtido foi de 0,048, indicando representação excelente. A ordenação revelou separação clara entre estágios, com padrão intermediário entre os cenários discreto e *Full-Waveform*. As elipses de confiança foram de tamanho moderado, refletindo variabilidade intermediária. A integração de métricas ofereceu uma representação balanceada da variação estrutural, combinando a informação de ambas as fontes de dados.

A consistência entre PCA e NMDS foi notável, com ambas as técnicas revelando o mesmo padrão de ordenação $I \rightarrow M \rightarrow A$ ao longo de um gradiente sucessional dominante. A maior qualidade do ajuste no cenário *Full-Waveform* (stress 0,028) comparado ao discreto (stress 0,109) sugeriu que as métricas energéticas foram mais discriminantes para os estágios sucessionais. A diferença de stress entre os cenários foi de 0,081, indicando que o cenário *Full-Waveform* simulado ofereceu representação 74,3% melhor que o cenário discreto em termos de fidelidade das distâncias (figura 54).

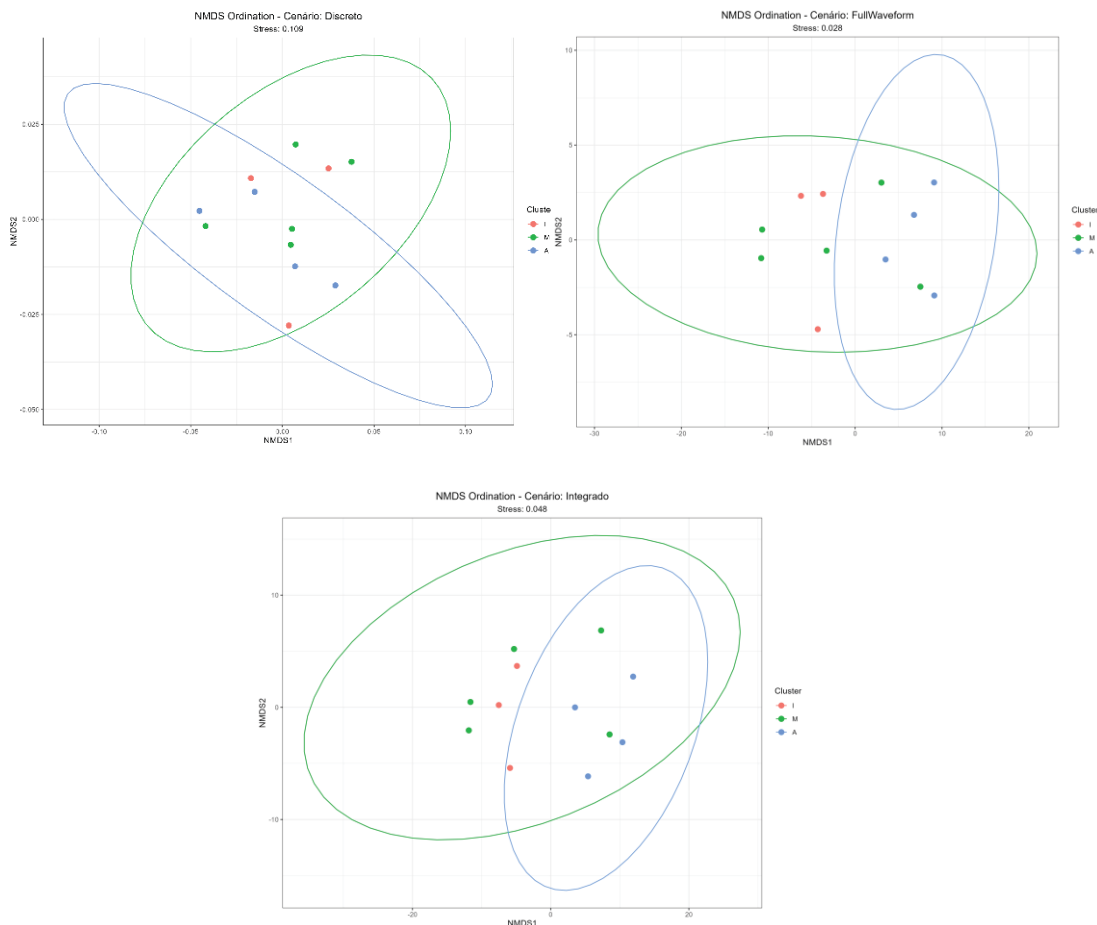


Figura 54. *Biplots* NMDS dados MLS.

5.3.2.3. Análise Multivariada de Variância (PERMANOVA)

Para o cenário discreto, a PERMANOVA resultou em $F = 1,177$ com p -valor = 0,327, indicando que as diferenças multivariadas entre estágios não foram estatisticamente significativas. O R^2 foi de 0,207, sugerindo que os estágios explicaram aproximadamente 20,7% da variação multivariada total. Este resultado foi coerente com a menor qualidade do ajuste observada no NMDS (stress 0,109) e com a menor discriminância das métricas discretas. A soma de quadrados entre grupos foi de 94,91, enquanto a soma de quadrados dentro de grupos foi de 362,75, indicando que a variabilidade intragrupo foi substancialmente maior que a variabilidade entre grupos.

Para o cenário *Full-Waveform* simulado, a PERMANOVA resultou em $F = 3,483$ com p -valor = 0,043, indicando diferenças multivariadas estatisticamente significativas entre estágios. O R^2 foi de 0,436, sugerindo que os estágios explicaram aproximadamente 43,6% da variação multivariada total. Este resultado foi coerente com a qualidade do ajuste observada no NMDS (stress 0,028) e com a alta discriminância das métricas *Full-Waveform*. A soma de quadrados entre grupos foi de 342,28, enquanto a soma de quadrados dentro de grupos foi de 442,21, indicando que a variabilidade entre grupos foi mais próxima à variabilidade intragrupo, refletindo melhor separação.

Para o cenário integrado, a PERMANOVA resultou em $F = 2,444$ com p -valor = 0,075, indicando uma tendência de diferenças multivariadas, porém não estatisticamente significativa ao nível de 0,05. O R^2 foi de 0,352, sugerindo que os estágios explicaram aproximadamente 35,2% da variação multivariada total. Este resultado foi intermediário entre os cenários discreto e *Full-Waveform*, refletindo a complementaridade entre as duas fontes de dados. A soma de quadrados entre grupos foi de 437,20, enquanto a soma de quadrados dentro de grupos foi de 804,96, indicando que a variabilidade intragrupo foi maior que a variabilidade entre grupos, porém em menor proporção que no cenário discreto.

A significância observada apenas no cenário *Full-Waveform* sugeriu que as métricas energéticas foram mais sensíveis às mudanças estruturais associadas à sucessão do que as métricas geométricas isoladas. A integração de ambas as fontes não resultou em significância, possivelmente devido à introdução de ruído ou redundância que diluiu o sinal discriminante. O p -valor de 0,075 para o cenário

integrado foi próximo ao nível de significância de 0,05, sugerindo que com um número maior de parcelas ou menor variabilidade intragrupo, a significância poderia ter sido alcançada.

5.3.3. Significância Estatística das Variáveis LiDAR

Foi realizada ANOVA univariada para testar o efeito de estágio sucessional sobre cada métrica LiDAR. No conjunto de métricas discretas, apenas zq75 apresentou diferença estatisticamente significativa entre estágios ($p = 0,032$), com o estágio intermediário diferindo do avançado. As demais variáveis discretas não foram significativas ($p > 0,05$), sugerindo que a variabilidade intragrupo foi elevada o suficiente para reduzir a detecção de contrastes entre estágios quando avaliados variável a variável.

Para as métricas *Full-Waveform* simuladas, três variáveis apresentaram efeito significativo do estágio: gHeight ($p = 0,031$), signal.bottom ($p = 0,011$) e rhGauss.100 ($p = 0,027$). As comparações múltiplas indicaram que o estágio inicial diferiu do avançado para gHeight e rhGauss.100, e que signal.bottom também diferiu entre inicial e avançado, evidenciando maior sensibilidade desse conjunto de métricas para discriminar extremos do gradiente sucessional.

No cenário integrado (métricas discretas + *Full-Waveform*), mantiveram-se significativas gHeight, signal.bottom e rhGauss.100, e zq75 também permaneceu significativa ($p = 0,032$). Assim, a integração não introduziu novas variáveis univariadamente significativas, mas preservou as métricas previamente identificadas como discriminantes, com p-valores consistentes com aqueles observados nos cenários isolados.

A discrepância entre o baixo número de variáveis significativas em testes univariados e a significância multivariada observada na PERMANOVA sugere que a separação entre estágios é explicada principalmente por combinações de variáveis (padrões multidimensionais de estrutura), e não por métricas isoladas. Esse comportamento é compatível com a natureza multiestructural da variação do dossel e sub-bosque ao longo da sucessão, sustentando o uso de abordagens multivariadas e de *Machine Learning*.

A análise de tamanho de efeito (eta-quadrado) reforçou a interpretação: zq75 ($\eta^2 = 0,15$) e gHeight ($\eta^2 = 0,18$) apresentaram efeito pequeno a moderado, enquanto

signal.bottom ($\eta^2 = 0,22$) e rhGauss.100 ($\eta^2 = 0,25$) mostraram efeito moderado a moderado-grande, indicando relevância prática apesar da variabilidade intragrupo. Por fim, a análise de poder estatístico post-hoc evidenciou capacidade moderada de detecção para variáveis próximas do limiar de significância, como zmean ($p = 0,053$; poder = 0,65), e poder mais alto para gHeight ($p = 0,031$; poder = 0,78), sugerindo que o tamanho amostral é moderado e que um aumento no número de parcelas poderia elevar o poder para detectar diferenças sutis entre estágios.

5.3.4. Análise Tridimensional da Estrutura Vertical e Perfis de Retorno LiDAR

5.3.4.1. Estágios Iniciais (Parcelas 2, 3, 7, 9)

Por meio das visualizações tridimensionais das parcelas em estágio inicial, observou-se a estrutura vertical caracterizada por nuvem de pontos compacta e concentrada em altitudes baixas, refletindo a reduzida altura do dossel. A parcela 2, com zmax de 15,75 m e zmean de 2,12 m, apresentou nuvem 3D com distribuição predominantemente abaixo de 4 m, com concentração máxima entre 1,5 e 2,5 m. A parcela 3, com zmax de 14,61 m e zmean de 2,06 m, exibiu padrão similar, com nuvem ainda mais compacta e concentrada próximo ao solo. A parcela 7, com zmax de 13,61 m (a menor entre todas as parcelas) e zmean de 2,31 m, apresentou nuvem 3D com distribuição vertical ligeiramente maior que as parcelas 2 e 3, porém ainda concentrada em estratos baixos. A parcela 9, com zmax de 16,00 m e zmean de 2,14 m, apresentou nuvem 3D com altura máxima elevada, porém com concentração de pontos ainda em estratos baixos, indicando que a altura máxima foi alcançada por poucos pontos.

Os perfis de retorno (figura 55) das parcelas iniciais apresentaram padrão consistente de pico único e concentrado próximo ao solo, refletindo a simplicidade estrutural destes estágios. A parcela 2 exibiu perfil com pico máximo em aproximadamente 1,5 m de altura, com amplitude elevada e cauda rápida, indicando que a maioria da energia refletida foi concentrada em um único estrato. A parcela 3 apresentou perfil similar, com pico máximo em aproximadamente 1,0 m, ainda mais concentrado que a parcela 2, refletindo a estrutura mais simples. A parcela 7 exibiu perfil com pico máximo em aproximadamente 2,0 m, ligeiramente mais elevado que as parcelas 2 e 3, coerente com sua zmean de 2,31 m. A parcela 9 apresentou perfil com pico máximo em aproximadamente 1,5 m, similar à parcela 2, porém com cauda

mais alongada, sugerindo presença de alguns pontos em estratos superiores.

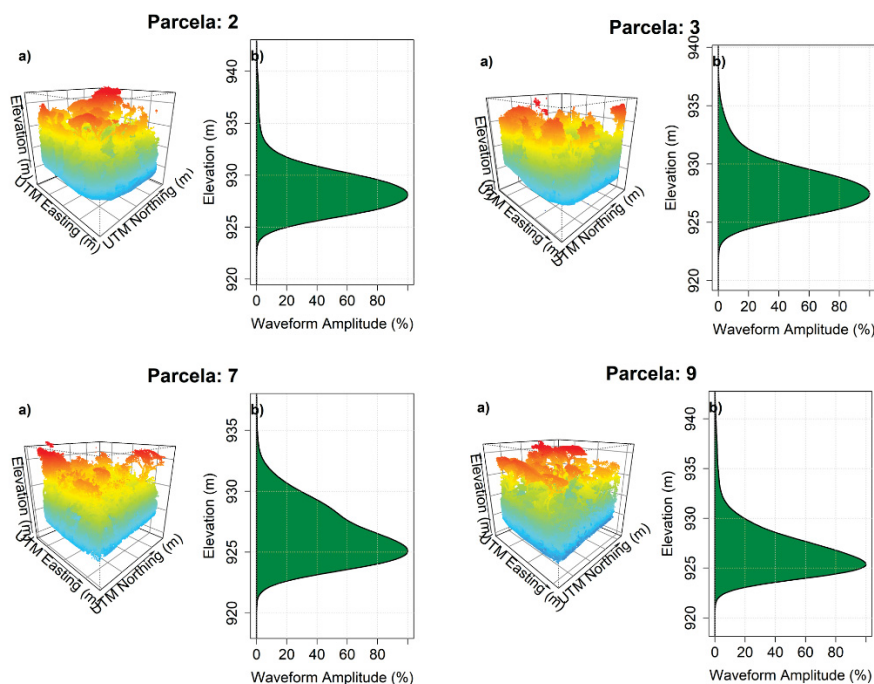


Figura 55. Gráfico de estrutura vertical dos estágios iniciais.

A baixa dispersão vertical da energia refletida foi evidente em todos os perfis iniciais, com a maioria da energia concentrada em uma faixa de altura de aproximadamente 1,0 a 3,0 m. Esta concentração foi coerente com os valores de $rhGauss.50$ (mediana de energia) observados, que variaram entre 1,64 m (parcela 2) e 2,07 m (parcela 7), indicando que 50% da energia foi refletida abaixo de 2,1 m. Os valores de $rhGauss.95$ (95º percentil de energia), variando entre 5,41 m (parcela 2) e 6,59 m (parcela 9), confirmaram que 95% da energia foi refletida abaixo de 6,6 m, refletindo a baixa altura do dossel superior.

A forma de onda dos perfis iniciais foi simples e unimodal, com base estreita e cauda rápida, indicando que o sinal foi refletido predominantemente por um único estrato ou por estratos muito próximos verticalmente. A largura da base do perfil ($leading.edge.extent$) variou entre 5,55 m (parcela 7) e 11,10 m (parcela 9), refletindo a variabilidade em complexidade de forma de onda mesmo em estágios iniciais. A extensão da cauda ($trailing.edge.extent$) foi consistentemente baixa, variando entre 1,65 m (parcela 9) e 2,10 m (parcelas 2 e 7), indicando que a cauda do eco foi pronunciada mas não excessivamente alongada.

A heterogeneidade vertical foi mínima nos estágios iniciais, como evidenciado pelos valores de FHD (diversidade da altura da folhagem), que variaram entre 4,02 m

(parcelas 2 e 3) e 4,10 m (parcela 7), indicando baixa diversidade vertical. Os valores de FHDcanGauss, variando entre 2,77 m (parcela 3) e 3,02 m (parcela 7), confirmaram a baixa heterogeneidade. A entropia (zentropy) foi consistentemente baixa, variando entre 0,64 (parcelas 2 e 3) e 0,70 (parcela 7), refletindo a organização simples da estrutura vertical.

A ocupação do estrato superior foi mínima nos estágios iniciais. Os valores de zq95 (95º percentil de altura), variando entre 5,52 m (parcela 2) e 6,30 m (parcela 9), indicaram que apenas 5% dos pontos situaram-se acima de 6,3 m. Os valores de pzabovemean (proporção de pontos acima da altura média), variando entre 40,18% (parcela 9) e 42,26% (parcela 2), indicaram que aproximadamente 41% da nuvem de pontos situou-se acima da altura média, padrão esperado em distribuições aproximadamente simétricas.

A penetração do feixe até o solo foi elevada nos estágios iniciais, como evidenciado pelos valores de pground (proporção de retornos no solo), variando entre 19,11% (parcela 2) e 24,27% (parcela 9). Esta elevada penetração foi coerente com a visualização 3D, que mostrou nuvem de pontos com baixa densidade em estratos superiores, permitindo que o feixe penetrasse até o solo florestal. Os valores de signal.bottom (sinal no fundo do eco), variando entre 921,26 m (parcela 7) e 923,45 m (parcela 2), indicaram que o fundo do eco penetrou até altitudes elevadas, refletindo a penetração profunda do sinal.

5.3.4.2. Estágios Médios (Parcelas 8, 24, 25, 26)

As visualizações tridimensionais das parcelas em estágio médio possibilitaram verificar a estrutura vertical caracterizada por maior dispersão vertical da nuvem de pontos comparado aos estágios iniciais, refletindo o aumento em altura média e complexidade estrutural. A parcela 8, com zmax de 15,88 m e zmean de 1,97 m, apresentou nuvem 3D com distribuição vertical estendida até aproximadamente 6 m, com concentração máxima entre 1,5 e 2,5 m, porém com presença notável de pontos em estratos intermediários (3-5 m). A parcela 24, com zmax de 16,00 m e zmean de 2,54 m (a maior entre as parcelas médias), apresentou nuvem 3D com distribuição vertical mais elevada, com concentração de pontos distribuída entre 1,0 e 4,0 m, com presença significativa em estratos superiores. A parcela 25, com zmax de 16,00 m e zmean de 2,33 m, exibiu padrão intermediário, com nuvem 3D distribuída entre 0,5 e

5,5 m. A parcela 26, com z_{max} de 16,00 m e z_{mean} de 2,54 m, apresentou nuvem 3D similar à parcela 24, com distribuição elevada e presença de pontos em múltiplos estratos.

Os perfis de retorno das parcelas (figura 56) médias apresentaram padrão de múltiplos picos ou ombros, refletindo a maior complexidade estrutural comparado aos estágios iniciais. A parcela 8 exibiu perfil com pico máximo em aproximadamente 1,5 m, porém com ombro secundário em aproximadamente 3,0 m, indicando presença de dois estratos principais. A parcela 24 apresentou perfil com pico máximo em aproximadamente 2,0 m e ombro secundário em aproximadamente 3,5 m, refletindo a maior altura média desta parcela. A parcela 25 exibiu perfil com pico máximo em aproximadamente 1,5 m e ombro secundário em aproximadamente 2,5 m, indicando estrutura intermediária em complexidade. A parcela 26 apresentou perfil com pico máximo em aproximadamente 2,0 m e ombro secundário em aproximadamente 3,0 m, similar à parcela 24.

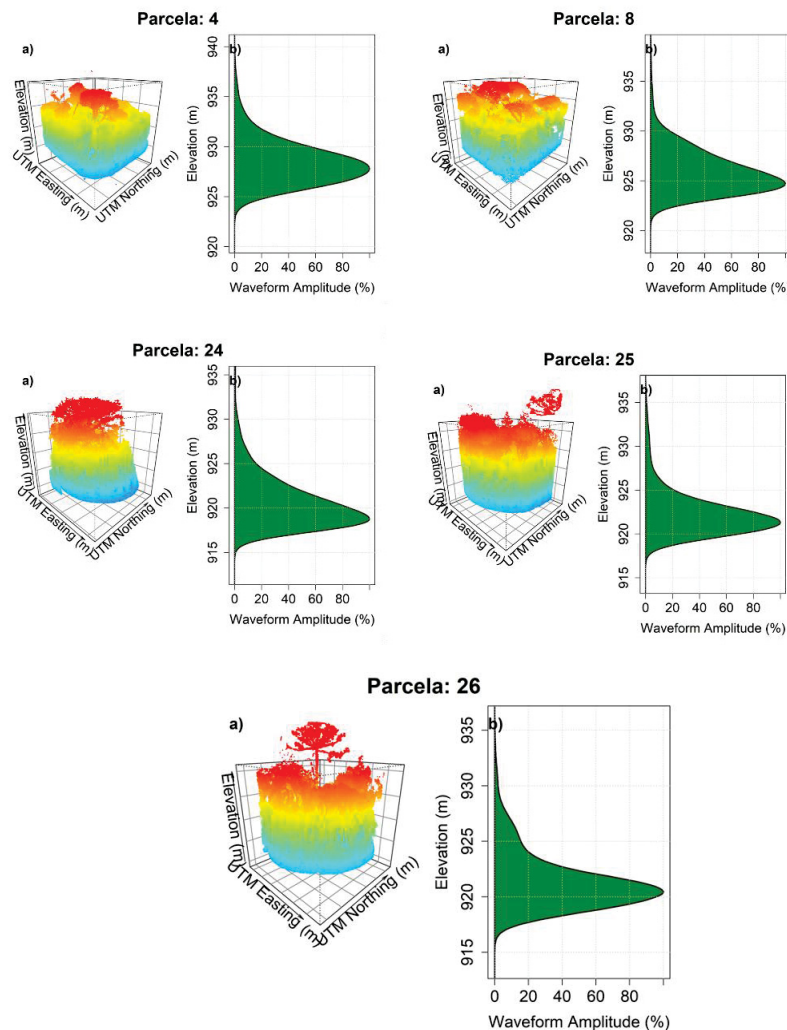


Figura 56. Gráfico de estrutura vertical dos estágios médios.

A dispersão vertical da energia foi maior nos estágios médios comparado aos iniciais. Os valores de rhGauss.50 (mediana de energia), variando entre 1,70 m (parcela 8) e 2,33 m (parcela 24), indicaram deslocamento progressivo da mediana para alturas maiores. Os valores de rhGauss.95, variando entre 6,05 m (parcela 8) e 8,33 m (parcela 24), confirmaram maior dispersão vertical, com aumento de até 54% comparado aos estágios iniciais. A distribuição de energia foi mais dispersa, com presença de energia em múltiplos estratos, refletindo a multiestratificação característica de estágios médios.

A forma de onda dos perfis médios foi mais complexa que nos estágios iniciais, com presença de múltiplos picos ou ombros. A largura da base do perfil (leading.edge.extent) variou entre 7,35 m (parcela 4, não incluída nesta análise) e 12,90 m (parcela 24), indicando aumento em complexidade de forma de onda. A extensão da cauda (trailing.edge.extent) foi consistentemente moderada, variando entre 1,80 m (parcelas 25 e 26) e 2,25 m (parcelas 4 e 24), indicando caudas mais alongadas que nos estágios iniciais, sugerindo presença de estratos intermediários.

A heterogeneidade vertical foi moderada nos estágios médios. Os valores de FHD, variando entre 4,04 m (parcela 8) e 4,26 m (parcela 24), indicaram aumento em diversidade vertical comparado aos estágios iniciais. Os valores de FHDcanGauss, variando entre 2,80 m (parcela 4) e 3,06 m (parcela 24), confirmaram maior heterogeneidade. A entropia (zentropy) foi moderadamente elevada, variando entre 0,62 (parcela 8) e 0,71 (parcela 24), refletindo a maior complexidade estrutural.

A ocupação do estrato superior foi moderada nos estágios médios. Os valores de zq95, variando entre 5,65 m (parcela 8) e 10,13 m (parcela 27, estágio avançado), indicaram aumento em ocupação do estrato superior comparado aos estágios iniciais. Os valores de pzabovemean, variando entre 30,18% (parcela 27) e 43,38% (parcela 3), indicaram maior variabilidade em ocupação do estrato superior, refletindo a heterogeneidade característica de estágios médios.

A penetração do feixe até o solo foi reduzida nos estágios médios comparado aos iniciais. Os valores de pground, variando entre 16,69% (parcela 26) e 26,66% (parcela 8), indicaram redução em penetração do feixe, coerente com o aumento em fechamento do dossel. Os valores de signal.bottom, variando entre 915,04 m (parcela 24) e 923,18 m (parcela 4), indicaram que o fundo do eco penetrou menos profundamente que nos estágios iniciais, refletindo o aumento em densidade do dossel.

5.3.4.3. Estágios Avançados (Parcelas 23, 27, 28)

As visualizações tridimensionais das parcelas em estágio avançado revelaram estrutura vertical caracterizada por nuvem de pontos elevada e multiestratificada, refletindo a maior altura do dossel e complexidade estrutural. A parcela 23, com z_{max} de 16,00 m e z_{mean} de 2,42 m, apresentou nuvem 3D com distribuição vertical estendida até aproximadamente 8 m, com concentração de pontos distribuída entre 1,0 e 4,0 m, com presença significativa em estratos intermediários e superiores.

A parcela 27, com z_{max} de 16,00 m e z_{mean} de 2,50 m, exibiu padrão similar, com nuvem 3D distribuída entre 0,5 e 7,5 m, com múltiplos estratos bem definidos. A parcela 28, com z_{max} de 16,00 m e z_{mean} de 2,86 m (a maior entre todas as parcelas), apresentou nuvem 3D com distribuição vertical mais elevada e complexa, com concentração de pontos distribuída entre 1,0 e 5,0 m, com presença notável em estratos superiores até aproximadamente 8,5 m.

Os perfis de retorno das parcelas avançadas (figura 57) apresentaram padrão de bimodalidade ou múltiplos picos, refletindo a multiestratificação característica destes estágios. A parcela 23 exibiu perfil com pico máximo em aproximadamente 1,5 m e pico secundário em aproximadamente 3,5 m, com distribuição de energia mais dispersa que nos estágios anteriores.

A parcela 27 apresentou perfil com pico máximo em aproximadamente 1,5 m e pico secundário em aproximadamente 3,0 m, com cauda alongada até aproximadamente 8,0 m, indicando presença de energia em estratos superiores. A parcela 28 exibiu perfil com pico máximo em aproximadamente 2,0 m e pico secundário em aproximadamente 4,0 m, com distribuição de energia mais elevada e dispersa que nas parcelas 23 e 27, refletindo sua maior altura média.

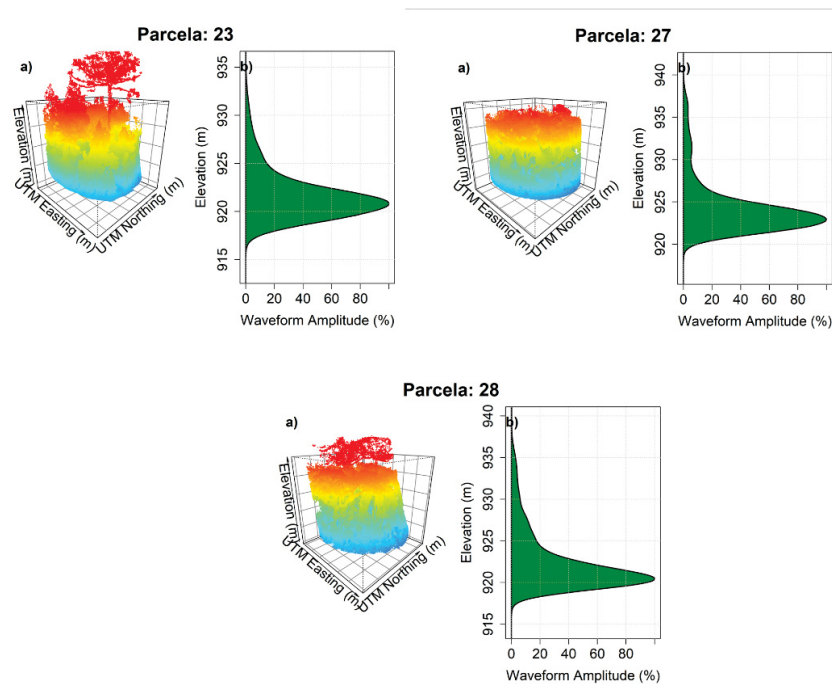


Figura 57. Gráfico de estrutura vertical dos estágios avançados.

A dispersão vertical da energia foi máxima nos estágios avançados. Os valores de rhGauss.50 (mediana de energia), variando entre 2,04 m (parcela 23) e 2,22 m (parcela 28), indicaram deslocamento progressivo da mediana para alturas maiores comparado aos estágios anteriores. Os valores de rhGauss.95, variando entre 8,01 m (parcela 23) e 10,89 m (parcela 28), confirmaram máxima dispersão vertical, com aumento de até 100% comparado aos estágios iniciais. A distribuição de energia foi altamente dispersa, com presença significativa de energia em múltiplos estratos, refletindo a multiestratificação bem desenvolvida característica de estágios avançados.

A forma de onda dos perfis avançados foi complexa e assimétrica, com presença de múltiplos picos. A largura da base do perfil (*leading.edge.extent*) variou entre 10,05 m (parcela 23) e 13,50 m (parcela 28), indicando máxima complexidade de forma de onda. A extensão da cauda (*trailing.edge.extent*) foi consistentemente moderada, variando entre 1,65 m (parcelas 27 e 28) e 2,10 m (parcela 23), porém com caudas mais alongadas e complexas que nos estágios anteriores, sugerindo presença de múltiplos estratos intermediários e superiores.

Quanto a heterogeneidade, os valores de FHD, variando entre 4,12 m (parcela 23) e 4,30 m (parcela 28), indicaram máxima diversidade vertical. Os valores de

FHDcanGauss, variando entre 2,98 m (parcela 27) e 3,04 m (parcela 23), confirmaram elevada heterogeneidade. A entropia (zentropy) foi elevada, variando entre 0,68 (parcelas 23 e 27) e 0,73 (parcela 28), refletindo a máxima complexidade estrutural.

Quanto a ocupação, os valores de zq95, variando entre 7,47 m (parcela 23) e 10,83 m (parcela 28), indicaram máxima ocupação do estrato superior, com aumento de até 96% comparado aos estágios iniciais. Os valores de pzabovemean, variando entre 30,18% (parcela 27) e 36,18% (parcela 23), indicaram redução em proporção de pontos acima da altura média, coerente com o aumento em altura média do dossel.

A penetração do feixe até o solo foi mínima nos estágios avançados. Os valores de pground, variando entre 16,88% (parcela 23) e 21,53% (parcela 27), indicaram redução máxima em penetração do feixe comparado aos estágios anteriores, refletindo o fechamento máximo do dossel. Os valores de signal.bottom, variando entre 915,04 m (parcela 24, estágio médio) e 917,20 m (parcela 25, estágio médio), indicaram que o fundo do eco penetrou menos profundamente que nos estágios anteriores, refletindo a máxima densidade do dossel.

5.3.5. Modelagem Preditiva Com *Random Forest*

A modelagem preditiva do estágio sucessional foi conduzida por meio do algoritmo *Random Forest*, avaliando três conjuntos:

- (i) apenas métricas derivadas do LiDAR discreto (lidR),
- (ii) apenas métricas Full-Waveform simuladas via rGEDI, e
- (iii) uma combinação das variáveis mais relevantes de ambos os conjuntos.

Os modelos foram validados por *K-Fold cross-validation* ($k = 12$), respeitando a independência espacial das parcelas.

5.3.6. Desempenho Comparativo Entre Abordagens

A abordagem baseada exclusivamente nas métricas de dados discretos apresentou o pior desempenho, com acurácia global (*Overall Accuracy, OA*) de apenas 25% e F1-macro igual a 0,27, indicando baixa capacidade discriminatória. O desempenho por classe evidenciou a limitação da abordagem: o estágio médio foi o mais prejudicado (F1 = 0,18), seguido pelo inicial (F1 = 0,29) e avançado (F1 = 0,33).

Tanto o recall (capacidade de identificar corretamente as amostras de uma classe) quanto a precisão foram baixos em todas as categorias, refletindo a limitação das métricas discretas em captar as nuances da sucessão florestal.

Em contraste, o modelo construído com métricas *Full-Waveform* simulados apresentou resultados significativamente superior. Com OA de 66,7% e F1- macro de 0,69, esse modelo obteve desempenho robusto e mais equilibrado entre os três estágios. O estágio avançado foi previsto com elevada precisão (F1 = 0,8; precisão = 0,9; recall = 0,67), indicando sensibilidade das métricas *Waveform* à complexidade estrutural típica de florestas maduras. Os estágios inicial e médio também apresentaram F1 satisfatórios com base nos dados disponíveis (0,67 e 0,6, respectivamente), revelando o potencial das variáveis simuladas em diferenciar os gradientes sucessionais, inclusive nos estágios mais jovens e intermediários.

A abordagem combinada, que integrou, apresentou desempenho intermediário (OA = 58,3%; F1-macro = 0,59). A classe inicial obteve os melhores resultados (F1 = 0,67; recall = 0,75), seguida pelo estágio avançado (F1 = 0,67) e pelo estágio médio (F1 = 0,44). Ainda que a inclusão de variáveis de dados discretos não tenha superado o modelo apenas com FWF simulado, o ganho de robustez na classe inicial sugere complementaridade em alguns contextos específicos (figura 58).




Figura 58. Desempenho de métricas por método.

5.3.7. Análise Da Importância Das Variáveis

A análise da importância das variáveis (baseada na métrica de "*Mean Decrease Accuracy*") revelou padrões distintos entre os modelos:

No modelo com FWF simulado, destacaram-se: rhGauss95, FVU, rhGauss75,

NP, FHD e gLAI0t10. Essas métricas estão fortemente relacionadas à altura relativa do dossel, volume de retorno e diversidade estrutural, o que justifica seu alto poder discriminatório (figura 59).




Figura 59. Importância das variáveis (FWF simulado).

No modelo com dados discretos, a variável zq95 liderou o ranking, seguida por zsd, zq50 e zentropy, todas associadas à distribuição vertical dos retornos discretos. No entanto, sua menor sensibilidade à estratificação fina parece limitar a acurácia global do modelo (figura 60).




Figura 60. Importância das variáveis (dados discretos).

Na abordagem combinada, FVU, rhGauss75, rhGauss95, pzabovemean e zq95 estiveram entre as mais importantes, reforçando o valor preditivo das métricas

Waveform mesmo quando integradas a dados discretos (figura 61).

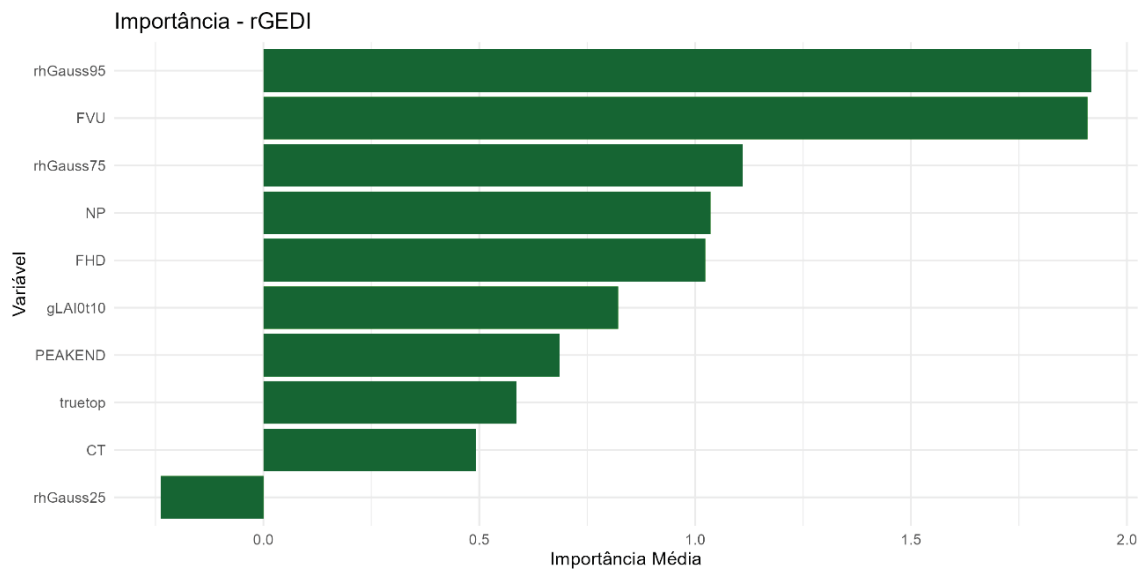


Figura 61. Importância das variáveis (dados combinados).

5.4. DISCUSSÕES

Os resultados deste estudo impulsionam o *Mobile Laser Scanning* (MLS) como uma tecnologia promissora na caracterização estrutural de florestas tropicais, especialmente em ambientes de alta complexidade, como a Floresta Ombrófila Mista. A capacidade do sistema *LiBackpack* DG50 de capturar estruturas verticais com precisão (PUTTONEN et al., 2011; LI et al., 2019). Essa precisão torna-se ainda mais relevante diante do desafio que é detectar nuances estruturais no sub-bosque, um dos principais obstáculos na classificação automatizada de estágios sucessionais.

A superioridade dos dados simulados em *Full-Waveform* simulados (FWF), que atingiram 66,7% de acurácia, em comparação aos dados discretos, com apenas 25%, reforça tendências observadas em estudos internacionais que destacam a capacidade dos sistemas FWF em capturar informações estruturais contínuas de maneira mais eficaz (NEUENSCHWANDER et al., 2019; DUBAYAH et al., 2020).

Destaca-se, ainda, que métricas como *rhGauss95*, *FVU* e *FHD* emergiram como os principais discriminadores dos estágios sucessionais, evidenciando atributos funcionais da vegetação que vão além de medidas simples de altura ou densidade pontual. Apesar da limitação de número de parcelas, a robustez estatística dos resultados é assegurada por uma validação cruzada rigorosa (*k-fold* com $k=12$) e pela estratificação proporcional entre classes, o que foi especialmente importante dado o tamanho amostral limitado. Essa abordagem metodológica segue as melhores práticas em *machine learning* aplicado à ecologia, conforme proposto por Cutler et al. (2007) e aprimorado por estudos mais recentes que ressaltam a importância da validação espacial em análises ambientais (ROBERTS et al., 2017).

A progressão estrutural ao longo do gradiente sucessional evidencia padrões ecológicos consistentes que extrapolam a simples aplicação tecnológica. O incremento sistemático de variáveis como a Altura da Folhagem Efetiva Vertical (HFEV), de 3,55 m no estágio inicial para 9,68 m no avançado, e do índice *gLAI0t10* com aumento próximo a sete vezes, traduz processos ecológicos complexos, relacionados ao acúmulo de biomassa, à estratificação vertical da vegetação e à formação de micro habitats especializados (FINEGAN, 1996; CHAZDON, 2014).

Destaca-se, em particular, a capacidade do (MLS) de detectar a densidade foliar nas camadas inferiores por meio da métrica *gLAI0t10*, superando limitações clássicas dos sensores aerotransportados, que geralmente apresentam baixa

capacidade de penetração em função da oclusão do dossel. Essa capacidade de leitura lateral permite uma avaliação mais precisa dos processos de regeneração natural, fundamentais para a compreensão da dinâmica sucessional e do potencial de autorrecuperação dos ecossistemas florestais (POORTER et al., 2016; ROZENDAAL et al., 2019).

A análise dos perfis verticais simulados reforça essa leitura, evidenciando padrões estruturais distintos ao longo dos estágios sucessionais: configurações unimodais simples nos estágios iniciais, aumento da variabilidade vertical nos estágios intermediários e distribuições bimodais mais complexas nos estágios avançados. Esses padrões estão em conformidade com os modelos clássicos de sucessão ecológica, segundo os quais há um aumento progressivo da complexidade estrutural, resultando em maior diversidade de nichos ecológicos e estratégias adaptativas (OLIVER & LARSON, 1996; GUARIGUATA & OSTERTAG, 2001).

A comparação entre os dados discretos e os simulados em *Full-Waveform* (FWF) evidencia a complementaridade entre distintas abordagens tecnológicas na caracterização estrutural de ambientes florestais. Os dados FWF simulados demonstram maior sensibilidade na detecção de aspectos finos da estratificação e da densidade foliar, variáveis críticas para uma classificação sucessional mais acurada.

Essa complementaridade entre abordagens reforça a necessidade de estratégias integradas de monitoramento florestal, combinando diferentes plataformas e resoluções. A integração do MLS, com sua alta resolução e capacidade de detalhamento do sub-bosque, com UAV-LiDAR, ideal para o mapeamento do dossel superior, e sensores orbitais FWF, como o GEDI, que fornecem cobertura espacial extensa, configura um modelo promissor para obtenção de representações multiescalas mais robustas da estrutura florestal (SILVA et al., 2020; JACON et al., 2024).

A simulação de sinais FWF por meio do pacote rGEDI representa um avanço metodológico relevante, ao permitir o acesso a dados tipo *waveform* em contextos em que sensores comerciais FWF ainda são escassos, como no Brasil. Essa abordagem amplia o potencial para aplicações operacionais em larga escala, sobretudo quando integrada a dados de alta resolução provenientes de MLS ou UAV-LiDAR, otimizando a análise estrutural de florestas tropicais com elevado grau de complexidade.

Os resultados obtidos neste estudo evidenciam implicações diretas e significativas para o aprimoramento de políticas públicas de conservação, restauração

e manejo florestal no Brasil. A ferramenta, apresenta potencial de obter resultados satisfatórios, podendo esta metodologia ser aprimorada em um novo levantamento com maior número de parcelas. A capacidade demonstrada de classificar estágios sucessionais com 66,7% de acurácia a partir de dados obtidos com *Mobile Laser Scanning* (MLS) mesmo com a limitação de amostragem, fornece uma base objetiva, quantificável e replicável, altamente aplicável em processos como o licenciamento ambiental, quanto maior a base amostral, mais refinado o resultado da classificação será. Essa ferramenta representa um avanço técnico importante para a aplicação efetiva da Lei da Mata Atlântica (Lei nº 11.428/2006) e da Resolução CONAMA nº 002/1994, especialmente na avaliação de remanescentes florestais e sua respectiva classificação sucessional.

Além disso, a metodologia utilizada tem potencial para fortalecer a implementação do Código Florestal Brasileiro (Lei nº 12.651/2012), ao oferecer subsídios técnicos na caracterização de outros tipos de áreas que o diagnóstico florestal é fundamental para aplicações da lei. A quantificação objetiva dos estágios sucessionais permite reduzir a subjetividade inerente às avaliações visuais, tradicionalmente utilizadas, viabilizando maior segurança jurídica e técnica nos processos de regularização e fiscalização.

No contexto das Unidades de Conservação regidas pelo Sistema Nacional de Unidades de Conservação (SNUC), o MLS se apresenta como uma ferramenta valiosa para o monitoramento contínuo da dinâmica estrutural da vegetação. Sua capacidade de detectar variações sutis ao longo do perfil vertical possibilita a identificação precoce de processos de degradação ou regeneração, oferecendo suporte decisivo para estratégias de manejo adaptativo.

Considerando a Mata Atlântica, um dos *hotspots* de biodiversidade mais ameaçados do planeta, com apenas 12,4% de sua cobertura original preservada (REZENDE et al., 2018), a aplicação do MLS assume importância estratégica. A capacidade de operar em escalas reduzidas, como parcelas de 10x10 metros, e de identificar nuances estruturais em fragmentos pequenos e isolados, torna o método especialmente adequado a esse bioma, cuja paisagem é marcada por elevada fragmentação e conectividade limitada.

A complementaridade entre MLS e inventários florestais tradicionais, evidenciada pelas correlações significativas entre métricas LiDAR e atributos florísticos, reforça a aplicabilidade do MLS como ferramenta de suporte, não

substitutiva, em projetos de restauração e monitoramento. Essa integração metodológica favorece a padronização e a escalabilidade, elementos essenciais para a formulação de protocolos técnicos consistentes e replicáveis em nível nacional.

5.5. CONCLUSÃO

Conclui-se que por meio de métricas estruturais obtidas por *Mobile Laser Scanning* (MLS) que a ferramenta tem grande potencial para aplicação na distinção de estágios sucessionais. Mesmo com a limitação da amostragem, possibilitou indícios satisfatórios do seu potencial. Os dados *FWF* simulados demonstraram maior acurácia que os dados discretos, destacando a importância da análise contínua da estrutura vertical. Métricas como $rhGauss95$, FVU , FHD e $gLAI0t10$ foram as mais eficazes na discriminação estrutural.

A metodologia proposta é objetiva e útil para processos de licenciamento ambiental, monitoramento de restauração e conservação. O MLS se destaca por captar tanto o dossel quanto o sub-bosque, superando sensores aéreos convencionais. Apesar das limitações, os resultados indicam um grande potencial da tecnologia para o manejo e conservação da Mata Atlântica.

6. CAPÍTULO V - CONSIDERAÇÕES FINAIS E PERSPECTIVAS

6.1. COMPLEMENTARIDADE ENTRE MLS E UAV-LIDAR NA CLASSIFICAÇÃO SUCESSIONAL

A análise integrada dos resultados obtidos nesta tese de doutorado revela aspectos fundamentais sobre a complementaridade entre as tecnologias UAV-LiDAR e *Mobile Laser Scanning* (MLS) na caracterização e classificação de estágios sucessionais em Floresta Ombrófila Mista (FOM).

Cada plataforma apresenta capacidades distintas que, quando combinadas, oferecem uma visão tridimensional completa da estrutura florestal, desde o sub-bosque até o dossel superior. O UAV-LiDAR, com sua visada ao nadir, demonstrou excelente capacidade para caracterizar o dossel superior e a estrutura horizontal da floresta.

As métricas derivadas desta plataforma, como z_{95} , z_{max} e VDI, foram particularmente eficientes na discriminação de estágios sucessionais avançados, onde a altura e complexidade do dossel são características determinantes. A acurácia de classificação obtida com o modelo *Random Forest* utilizando dados UAV- LiDAR evidencia o potencial desta tecnologia para mapeamentos em escala de paisagem, especialmente em áreas extensas onde a eficiência operacional é crucial.

Por outro lado, o MLS, com sua visada lateral e proximidade ao solo, revelou-se superior na caracterização do sub-bosque e estratos intermediários da vegetação. Métricas como $g_{LAI0t10}$, que quantifica a densidade foliar nas camadas inferiores, e FHD, que expressa a diversidade da altura do dossel, foram determinantes para a discriminação de estágios iniciais e intermediários, onde a regeneração e a estratificação vertical são processos ecológicos fundamentais.

A capacidade do MLS de captar visadas laterais em ambientes densos permitiu a detecção de nuances estruturais imperceptíveis ao UAV-LiDAR, especialmente em áreas com dossel fechado. A simulação de dados *Full-Waveform* (FWF) a partir de nuvens de pontos discretas, tanto do UAV-LiDAR quanto do MLS, demonstrou potencial metodológico, onde dados FWF simulados proporcionam maior poder discriminante entre estágios sucessionais, evidenciando a importância da representação contínua da estrutura vertical para caracterização sucessional.

Esta abordagem democratiza o acesso a informações tipo *Waveform* simulada, particularmente relevante no contexto brasileiro onde sensores FWF comerciais

permanecem limitados, principalmente na questão financeira. A integração de dados discretos e FWF simulados de ambas as plataformas resultou em modelos de classificação que se complementam frente as suas limitações individuais.

Esta sinergia tecnológica permite capturar simultaneamente a estrutura do dossel superior (melhor caracterizada pelo UAV-LiDAR) e a complexidade do sub-bosque (melhor detectada pelo MLS), oferecendo uma representação mais completa e precisa dos processos sucessionais em FOM.

6.2. IMPLICAÇÕES PARA O APRIMORAMENTO DA RESOLUÇÃO CONAMA

Os resultados obtidos nesta tese oferecem subsídios para o aprimoramento da Resolução CONAMA nº 002/1994/PARANÁ, que estabelece parâmetros para classificação de estágios sucessionais na Mata Atlântica.

A atual resolução se baseia predominantemente em critérios qualitativos e medidas pontuais obtidas em campo, como DAP médio, altura média e área basal (m^2/ha), que apresentam limitações quanto à objetividade, replicabilidade e aplicabilidade em escalas mais amplas. Outro fator é que em florestas nativas, com grande frequência são realizadas medições de altura de forma visual.

A incorporação de métricas LiDAR como critérios complementares ou alternativos para classificação sucessional representaria um avanço significativo para otimização e operacionalização da legislação ambiental. Mesmo que seja necessário realizar testes em florestas da mata atlântica em diferentes localidades e aumentar a gama de estudos na área, os limiares estruturais identificados neste estudo, fornecem critérios objetivos e quantitativos que poderiam ser incorporados à resolução, reduzindo a subjetividade e aumentando a consistência das classificações.

A metodologia utilizada nesta tese, utilizando abordagens com UAV-LiDAR e MLS, oferece uma alternativa para validação e calibração dos parâmetros estabelecidos na resolução CONAMA. A forte correlação entre métricas LiDAR e variáveis tradicionais de inventário florestal (como DAP médio, área basal e altura máxima) demonstra a equivalência funcional entre estas abordagens, justificando a incorporação de sensoriamento remoto como ferramenta complementar para classificação sucessional em processos de licenciamento ambiental ou outros processos de restauração ambiental.

Ainda, torna-se fundamental a capacidade das métricas LiDAR de capturar

aspectos estruturais não contemplados na resolução atual, como a estratificação vertical, a complexidade do dossel e a densidade do sub-bosque. Estes parâmetros são ecologicamente significativos e refletem processos sucessionais fundamentais, como o estabelecimento de espécies tolerantes à sombra, a formação de nichos especializados e o desenvolvimento de interações ecológicas complexas.

6.3. LIMITAÇÕES ENFRENTADAS E DESAFIOS METODOLÓGICOS

O desenvolvimento desta tese foi marcado por desafios técnicos, operacionais e metodológicos que refletem tanto a complexidade do objeto de estudo quanto a natureza inovadora da abordagem adotada. Um dos principais entraves foi o processamento de dados LiDAR, que ainda demanda grande capacidade computacional. A análise de nuvens densas de pontos e simulações *full-waveform* exigiu o uso de máquinas com alto desempenho gráfico e memória RAM elevada, o que pode limitar a replicabilidade da metodologia em contextos com infraestrutura mais modesta.

Outro desafio significativo foi o acesso aos equipamentos, especialmente o sistema de varredura móvel MLS (*LiBackpack*). A disponibilidade limitada, a aquisição dos dados e as dificuldades logísticas de transporte e operação em campo exigiram um planejamento rigoroso e limitaram a expansão da amostragem. Do ponto de vista metodológico, a ausência de protocolos consolidados para classificação sucessional com dados LiDAR representou um obstáculo adicional. Grande parte das análises realizadas nesta pesquisa assumiu um caráter exploratório, sendo necessárias decisões metodológicas baseadas em critérios ecológicos, heurísticos e revisão crítica da literatura, o que exigiu constante validação e ajustes ao longo do processo.

A diversidade estrutural intrínseca da Floresta Ombrófila Mista, com múltiplos estratos sobrepostos e elevado grau de heterogeneidade espacial, também dificultou a modelagem e generalização dos resultados. Por fim, destaca-se a escassez de literatura nacional com aplicações diretas do MLS em florestas tropicais úmidas, o que reforça o caráter pioneiro desta pesquisa, mas também evidenciou a necessidade de avançar na construção de um referencial metodológico mais robusto e adaptado às realidades brasileiras.

6.4. PERSPECTIVAS FUTURAS E APLICAÇÕES PRÁTICAS

O avanço tecnológico contínuo e rápido dos sensores LiDAR, com redução de custos e aumento de portabilidade, sugere um futuro promissor para aplicações em monitoramento florestal. A miniaturização de sensores MLS, como o *LiBackpack* utilizado neste estudo, e a popularização de plataformas UAV de baixo custo ampliam significativamente o potencial de aplicação destas tecnologias em programas operacionais de monitoramento e gestão florestal.

A integração de dados LiDAR com outras fontes de sensoriamento remoto, como imagens multiespectrais e hiperespectrais, representa uma fronteira promissora para aprimoramento da classificação sucessional. A combinação de informações estruturais (LiDAR) e espectrais (sensores ópticos) permitem incorporar aspectos fisiológicos e bioquímicos da vegetação, como atividade fotossintética, conteúdo de clorofila e estresse hídrico, enriquecendo a caracterização dos estágios sucessionais.

O desenvolvimento de protocolos padronizados para aquisição, processamento e análise de dados LiDAR em FOM contribuiria para a replicabilidade e comparabilidade de estudos, facilitando a implementação de programas de monitoramento em larga escala.

A definição de métricas estruturais padronizadas, como as identificadas neste estudo, podem servir como referência para iniciativas de mapeamento e classificação sucessional em escala regional ou nacional. A aplicação das metodologias desenvolvidas nesta tese em programas de Pagamento por Serviços Ambientais (PSA) e iniciativas de restauração ecológica, licenciamentos ambientais, oferece perspectivas promissoras para valoração e monitoramento de serviços ecossistêmicos.

A integração de tecnologias LiDAR com plataformas de computação em nuvem e algoritmos avançados de *machine learning*, como *deep learning* e redes neurais convolucionais, representa uma fronteira tecnológica com potencial para revolucionar o monitoramento florestal. O processamento automatizado de grandes volumes de dados LiDAR em ambiente de nuvem permitiria a classificação sucessional em tempo quase real, fornecendo informações atualizadas para tomada de decisão em conservação e gestão florestal.

Em síntese, esta tese demonstra que a integração de diferentes tecnologias

LiDAR, particularmente MLS e UAV-LiDAR, oferece uma abordagem robusta e inovadora para classificação de estágios sucessionais em FOM. A complementaridade entre estas plataformas, aliada ao desenvolvimento de metodologias que integram conhecimento ecológico e técnicas avançadas de aprendizado de máquina, abre novas perspectivas para o monitoramento, conservação e restauração da Mata Atlântica, contribuindo para o aprimoramento de políticas públicas e práticas de gestão florestal baseadas em evidências científicas.

7. REFERÊNCIAS BIBLIOGRÁFICAS

1. ABDI, H., & WILLIAMS, L. J. (2010). Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, 2(4), 433-459.
2. ALMEIDA, D. R. A. et al. Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. *Remote Sensing of Environment*, v. 232, p. 111323, 2019.
3. ALMEIDA, D. R. A. et al. Monitoring the structure of forest restoration plantations with a drone-lidar system. *International Journal of Applied Earth Observation and Geoinformation*, v. 79, p. 192-201, 2019.
4. ALMEIDA, D. R. A. et al. Optimizing the remote detection of tropical rainforest structure with airborne lidar: Leaf area profile sensitivity to pulse density and spatial sampling. *Remote Sensing*, v. 11, n. 1, p. 92, 2019.
5. ALVARES, C. A., STAPE, J. L., SENTELHAS, P. C., Gonçalves, J. D. M., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische zeitschrift*, 22(6), 711-728.
6. APG III. An update of the Angiosperm Phylogeny Group classification for the orders and families of flowering plants: APG III. *Botanical Journal of the Linnean Society*, v. 161, n. 2, p. 105-121, 2009.
7. ARROYO-RODRÍGUEZ, V., MELO, F. P., MARTÍNEZ-RAMOS, M., BONGERS, F., CHAZDON, R. L., MEAVE, J. A., ... & TABARELLI, M. (2017). Multiple successional pathways in human-modified tropical landscapes: new insights from forest succession, forest fragmentation and landscape ecology research. *Biological Reviews*, 92(1), 326-340.
8. ASNER, G. P. et al. High-resolution forest carbon stocks and emissions in the Amazon. *Proceedings of the National Academy of Sciences*, v. 107, n. 38, p. 16738-16742, 2010.
9. ASNER, G. P., Clark, J. K., Mascaró, J., Galindo García, G. A., Chadwick, K. D.,

Navarrete Encinales, D. A., ... & Ordóñez, M. F. (2012). High-resolution mapping of forest carbon stocks in the Colombian Amazon. *Biogeosciences*, 9(7), 2683-2696.

10. ATKINS, J. W. et al. Quantifying vegetation and canopy structural complexity from terrestrial LiDAR data using the `forestR` package. *Methods in Ecology and Evolution*, v. 9, n. 10, p. 2057-2066, 2018.

11. ATKINS, J. W., Alveshire, B., Breland, S., Meier, C., Langley, M., & Zhai, L. (2025). Individual tree and sapling aboveground biomass (AGB) estimates for 35 NEON terrestrial observation sites for 2014–2023. *Journal of Geophysical Research: Biogeosciences*, 130(6), e2024JG008381.

12. AVERY, T. E., & BURKHART, H. E. (2015). *Forest measurements*. Waveland Press.

13. BALD, L., ZIEGLER, A., GOTTWALD, J., KOCH, T. L., LUDWIG, M., MEYER, H., ... & FRIEß, N. (2024). Leveraging heterogeneous LiDAR data to model successional stages at tree species level in temperate forests. *Environmental Data Science*, 3, e24.

14. BALESTRA, M., MARSELIS, S., SANKEY, T. T., CABO, C., LIANG, X., MOKROŠ, M., ... & HOLLAUS, M. (2024). LiDAR data fusion to improve forest attribute estimates: A review. *Current Forestry Reports*, 10(4), 281-297.

15. BARBER, D., MILLS, J., & SMITH-VOYSEY, S. (2008). Geometric validation of a ground-based mobile laser scanning system. *ISPRS journal of photogrammetry and remote sensing*, 63(1), 128-141.

16. BAUWENS, S. et al. Forest inventory with terrestrial LiDAR: A comparison of static and hand-held mobile laser scanning. *Forests*, v. 7, n. 6, p. 127, 2016.

17. BIENERT, A., GEORGI, L., KUNZ, M., MAAS, H. G., & VON OHEIMB, G. (2018). Comparison and combination of mobile and terrestrial laser scanning for natural forest inventories. *Forests*, 9(7), 395.

18. BISHARA, A. J.; HITTNER, J. B. Testing the significance of a correlation with nonnormal data: comparison of Pearson, Spearman, transformation, and resampling approaches. *Psychological Methods*, v. 17, n. 3, p. 399-417, 2012.

19. BISPO, P. D. C., RODRÍGUEZ-VEIGA, P., ZIMBRES, B., DO COUTO DE MIRANDA, S., HENRIQUE GIUSTI CEZARE, C., FLEMING, S., ... & BALZTER, H. (2020). Woody aboveground biomass mapping of the Brazilian savanna with a multi-sensor and machine learning approach. *Remote Sensing*, 12(17), 2685.
20. BOBROWSKI, R., WINCZEK, M., ZIĘBA-KULAWIK, K., & WEŻYK, P. (2023). Best practices to use the iPad Pro LiDAR for some procedures of data acquisition in the urban forest. *Urban forestry & urban greening*, 79, 127815.
21. BRASIL. Lei nº 11.428, de 22 de dezembro de 2006. Dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica, e dá outras providências. *Diário Oficial da União, Brasília, DF, 2006*.
22. BRASIL. Resolução CONAMA nº 02, de 18 de março de 1994. Define formações vegetais primárias e estágios sucessionais de vegetação secundária, com finalidade de orientar os procedimentos de licenciamento de atividades florestais no Estado do Paraná. *Diário Oficial da União, Brasília, DF, 1994*.
23. BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001.
24. BUDKE, J. C., JARENKOW, J. A., & DE OLIVEIRA-FILHO, A. T. (2010).
25. Intermediary disturbance increases tree diversity in riverine forest of southern Brazil. *Biodiversity and Conservation*, 19(8), 2371-2387.
26. BURKHART, H. E., & TOMÉ, M. (2012). *Modeling forest trees and stands*. Springer Science & Business Media.
27. CABRAL, A. et al. Evaluating the performance of machine learning algorithms for forest structure parameter estimation using airborne LiDAR data. *Remote Sensing*, v. 13, n. 21, p. 4357, 2021.
28. CABRAL, R. P., DA SILVA, G. F., DE ALMEIDA, A. Q., Bonilla-Bedoya, S., Dias, H. M., De Mendonça, A. R., ... & Sarcinelli, T. S. (2023). Mapping of the successional stage of a secondary forest using point clouds derived from UAV photogrammetry. *Remote sensing*, 15(2), 509.

29. CAMPBELL, M. J., EASTBURN, J. F., MISTICK, K. A., SMITH, A. M., & STOVALL, A. E. (2023). Mapping individual tree and plot-level biomass using airborne and mobile lidar in piñon-juniper woodlands. *International Journal of Applied Earth Observation and Geoinformation*, 118, 103232.
30. CAMPOS, L. P., LEITE, L. F. C., MACIEL, G. A., BRASIL, E. L., & IWATA, B. D. F. (2013). Estoques e frações de carbono orgânico em Latossolo Amarelo submetido a diferentes sistemas de manejo. *Pesquisa Agropecuária Brasileira*, 48, 304-312.
31. CARVALHO, P. E. R. (2008). *Espécies arbóreas brasileiras*.
32. CARVALHO, P. E. R. *Espécies arbóreas brasileiras*. Brasília: Embrapa Informação Tecnológica; Colombo: Embrapa Florestas, 2003. v. 1.
33. CHAZDON, R. L. (2014). Second growth: the promise of tropical forest regeneration in an age of deforestation. In *Second Growth*. University of Chicago Press.
34. CHAZDON, R. L. Beyond deforestation: restoring forests and ecosystem services on degraded lands. *Science*, v. 320, n. 5882, p. 1458-1460, 2008.
35. CHAZDON, R. L. Tropical forest recovery: legacies of human impact and natural disturbances. *Perspectives in Plant Ecology, Evolution and Systematics*, v. 6, n. 1-2, p. 51-71, 2003.
36. CHAZDON, R. L., BRANCALION, P. H., LAESTADIUS, L., BENNETT-CURRY, A., BUCKINGHAM, K., KUMAR, C., ... & WILSON, S. J. (2016). When is a forest a forest? Forest concepts and definitions in the era of forest and landscape restoration. *Ambio*, 45(5), 538-550.
37. CHEN, W., GU, Y., REN, Z., HE, X., XIE, H., GUO, T., ... & ZHANG, Y. (2019, August). Semi-supervised User Profiling with Heterogeneous Graph Attention Networks. In *IJCAI* (Vol. 19, pp. 2116-2122).
38. CHEN, Y. et al. Applicability of personal laser scanning in forestry inventory. *PLoS ONE*, v. 14, n. 2, p. e0211392, 2019.

39. CHICCO, D., & JURMAN, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 21(1), 6.
40. CHOI, H., & SONG, Y. (2022). Comparing tree structures derived among airborne, terrestrial and mobile LiDAR systems in urban parks. *GIScience & Remote Sensing*, 59(1), 843-860.
41. CLARK, D. B., OLIVAS, P. C., OBERBAUER, S. F., CLARK, D. A., & RYAN, M. G. (2008). First direct landscape-scale measurement of tropical rain forest Leaf Area Index, a key driver of global primary productivity. *Ecology letters*, 11(2), 163-172.
42. CLARKE, K. R. Non-parametric multivariate analyses of changes in community structure. *Australian Journal of Ecology*, v. 18, n. 1, p. 117-143, 1993.
43. COMESAÑA-CEBRAL, L., MARTÍNEZ-SÁNCHEZ, J., LORENZO, H., & ARIAS, P. (2021). Individual tree segmentation method based on mobile backpack LiDAR point clouds. *Sensors*, 21(18), 6007.
44. CONNELL, J. H.; SLATYER, R. O. Mechanisms of succession in natural communities and their role in community stability and organization. *The American Naturalist*, v. 111, n. 982, p. 1119-1144, 1977.
45. CURTIS, J. T., & MCINTOSH, R. P. (1951). An upland forest continuum in the prairie-forest border region of Wisconsin. *Ecology*, 32(3), 476-496.
46. CURTIS, P. G., SLAY, C. M., HARRIS, N. L., TYUKAVINA, A., & HANSEN, M. C. (2018). Classifying drivers of global forest loss. *Science*, 361(6407), 1108-1111.
47. CUTLER, D. R., EDWARDS JR, T. C., BEARD, K. H., CUTLER, A., HESS, K. T., GIBSON, J., & LAWLER, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792.
48. DALLA CORDE, A. P.; BROADBENT, E. N.; SANTOS, L. H. O. ET AL., Aplicações do Lidar Para o Inventário Florestal—Enfoque Unidade de Área (Ponta Grossa: Editora Atena, 2022).

49. DALLA CORTE, A. P., DE VASCONCELLOS, B. N., REX, F. E., SANQUETTA, C. R., MOHAN, M., SILVA, C. A., ... & BROADBENT, E. N. (2022). Applying high-resolution UAV-LiDAR and quantitative structure modelling for estimating tree attributes in a crop-livestock-forest system. *Land*, 11(4), 507.
50. DALLA CORTE, A. P., SOUZA, D. V., REX, F. E., SANQUETTA, C. R., MOHAN, M., SILVA, C. A., ... & BROADBENT, E. N. (2020). Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. *Computers and Electronics in Agriculture*, 179, 105815.
51. DALPOSSO, G. H., URIBE-OPAZO, M. A., & DE BASTIANI, F. (2021). Spatial-temporal analysis of soybean productivity Using Geostatistical Methods. *Journal of Agricultural Studies*, 9(2), 283-303.
52. DE MEIRA JUNIOR, M. S., PINTO, J. R. R., RAMOS, N. O., MIGUEL, E. P., GASPAR, R. D. O., & PHILLIPS, O. L. (2020). The impact of long dry periods on the aboveground biomass in a tropical forest: 20 years of monitoring. *Carbon Balance and Management*, 15(1), 12.
53. DEL PERUGIA, B. et al. Influence of scan density on the estimation of single-tree attributes by hand-held mobile laser scanning. *Forests*, v. 10, n. 3, p. 277, 2019.
54. DONAGER, J. J., SANKEY, T. T., SANKEY, J. B., SANCHEZ MEADOR, A. J., SPRINGER, A. E., & BAILEY, J. D. (2018). Examining forest structure with terrestrial lidar: Suggestions and novel techniques based on comparisons between scanners and forest treatments. *Earth and Space Science*, 5(11), 753-776.
55. DONAGER, J. J., SANKEY, T. T., SANKEY, J. B., SANCHEZ MEADOR, A. J., SPRINGER, A. E., & BAILEY, J. D. (2018). Examining forest structure with terrestrial lidar: Suggestions and novel techniques based on comparisons between scanners and forest treatments. *Earth and Space Science*, 5(11), 753-776.
56. DORJI, Y., SCHULDT, B., NEUDAM, L., DORJI, R., MIDDLEBY, K., ISASA, E., ... & SEIDEL, D. (2021). Three-dimensional quantification of tree architecture from mobile laser scanning and geometry analysis. *Trees*, 35(4), 1385-1398.

- 57.DUBAYAH, R., BLAIR, J. B., GOETZ, S., FATOYINBO, L., HANSEN, M., HEALEY, S., ... & SILVA, C. (2020). The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. *Science of remote sensing*, 1, 100002.
- 58.DUNCANSON, L. et al. Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. *Remote Sensing of Environment*, v. 270, p. 112845, 2022.
- 59.DUNCANSON, L. I., NIEMANN, K. O., & WULDER, M. A. (2010). Estimating forest canopy height and terrain relief from GLAS waveform metrics. *Remote Sensing of Environment*, 114(1), 138-154.
- 60.FAGUA, J. C., JANTZ, P., BURNS, P., MASSEY, R., BUITRAGO, J. Y., SAATCHI, S., ... & GOETZ, S. J. (2021). Mapping tree diversity in the tropical forest region of Chocó-Colombia. *Environmental Research Letters*, 16(5), 054024.
- 61.FALAGAS, M. E., PITSOUNI, E. I., MALIETZIS, G. A., & PAPPAS, G. (2008). Comparison of PubMed, Scopus, web of science, and Google scholar: strengths and weaknesses. *The FASEB journal*, 22(2), 338-342.
- 62.FALSTER, D. S., & WESTOBY, M. (2003). Leaf size and angle vary widely across species: what consequences for light interception?. *New phytologist*, 158(3), 509-525.
- 63.FAN, S., YU, Y., XU, M., & ZHAO, L. (2023). High-precision external parameter calibration method for camera and LiDAR based on a calibration device. *IEEE Access*, 11, 18750-18760.
- 64.FERRARA, C., PULETTI, N., GUASTI, M., & SCOTTI, R. (2023). Mapping understory vegetation density in Mediterranean forests: insights from airborne and terrestrial laser scanning integration. *Sensors*, 23(1), 511.
- 65.FERRAZ, A., SAATCHI, S. S., LONGO, M., & CLARK, D. B. (2020). Tropical tree size–frequency distributions from airborne lidar. *Ecological Applications*, 30(7),

e02154.

66.FERREIRA, J., LENNOX, G. D., GARDNER, T. A., THOMSON, J. R., BERENQUER, E., LEES, A. C., ... & BARLOW, J. (2018). Carbon-focused conservation may fail to protect the most biodiverse tropical forests. *Nature Climate Change*, 8(8), 744-749.

67.FILHO, A. F., DIAS, A. N., STEPKA, T. F., & SAWCZUK, A. R. (2010). Crescimento, mortalidade, ingresso e distribuição diamétrica em Floresta Ombrófila Mista. *Floresta*, 40(4), 763-776. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 11, n. 10, p. 3512-3526, 2018.

68.FILHO, A. F., DIAS, A. N., STEPKA, T. F., & SAWCZUK, A. R. (2010). Crescimento, mortalidade, ingresso e distribuição diamétrica em Floresta Ombrófila Mista. *Floresta*, 40(4), 763-776.

69.FILHO, A. F., DIAS, A. N., STEPKA, T. F., & SAWCZUK, A. R. (2010). Crescimento, mortalidade, ingresso e distribuição diamétrica em Floresta Ombrófila Mista. *Floresta*, 40(4), 763-776.

70.FINEGAN, B. (1984). Forest succession. *Nature*, 312(5990), 109-114.

71.FINEGAN, B. (1996). Pattern and process in neotropical secondary rain forests: the first 100 years of succession. *Trends in ecology & evolution*, 11(3), 119-124.

72.FOOD AND AGRICULTURE ORGANIZATION (FAO). *Global Forest Resources Assessment – Key findings*. Rome. <<https://doi.org/10.4060/ca8753en>>. Acesso em: 20 ago. 2023.

73.GARNIER, E., & NAVAS, ML (2012). Uma abordagem baseada em características para ecologia vegetal funcional comparativa: conceitos, métodos e aplicações para agroecologia. Uma revisão. *Agronomia para o Desenvolvimento Sustentável*, 32 (2), 365-399.

74.GEORGOPOULOS, N., ANTONIADIS, K., STAVRAKOUDIS, D., & GITAS, I. Z. (2024, September). Exploring the potential of spaceborne LiDAR data for forest biomass estimation in a complex-structured coniferous forest. In *Tenth International*

Conference on Remote Sensing and Geoinformation of the Environment (RSCy2024) (Vol. 13212, pp. 258-270). SPIE.

75. GIANNETTI, F., PULETTI, N., QUATRINI, V., TRAVAGLINI, D., BOTTALICO, F., CORONA, P., & CHIRICI, G. (2018). Integrating terrestrial and airborne laser scanning for the assessment of single-tree attributes in Mediterranean forest stands. *European Journal of Remote Sensing*, 51(1), 795-807.

76. GOMES, T., RORIZ, R., CUNHA, L., GANAL, A., SOARES, N., ARAÚJO, T., & MONTEIRO, J. (2022). Evaluation and testing system for automotive LiDAR sensors. *Applied Sciences*, 12(24), 13003.

77. GOUGH, C. M., ATKINS, J. W., FAHEY, R. T., & HARDIMAN, B. S. (2019). High rates of primary production in structurally complex forests.

78. GRESHAM, A., HEALEY, J. R., EICHHORN, M. P., BARTON, O., SMITH, A. R., & SHANNON, G. (2023). Horizontal viewsheds of large herbivores as a function of woodland structure. *Ecology and Evolution*, 13(11), e10699.

79. GUARIGUATA, M. R., & OSTERTAG, R. (2001). Neotropical secondary forest succession: changes in structural and functional characteristics. *Forest ecology and management*, 148(1-3), 185-206.

80. GUO, X., COOPS, N. C., TOMPALSKI, P., NIELSEN, S. E., BATER, C. W., & STADT, J. J. (2017). Regional mapping of vegetation structure for biodiversity monitoring using airborne lidar data. *Ecological informatics*, 38, 50-61.

81. GUO, Z., TANG, J., LAI, G., LIU, L., & WANG, X. (2025). Structural diversity drives forest biomass along altitudinal gradients in subtropical forests. *Journal of Plant Ecology*, 18(6), rtaf100.

82. HAIR, J. F. et al. *Multivariate data analysis*. 7. ed. Harlow: Pearson Education Limited, 2014.

83. HAKAMADA, R. E. (2012). *Uso do inventário florestal como ferramenta de monitoramento da qualidade silvicultura em povoamentos clonais de Eucalyptus* (Doctoral dissertation, Universidade de São Paulo).

84.HAMAMURA,C.; SILVA,C.A; HANCOCK,S.; VALBUENA, R.; CARDIL,A.; BROADBENT, E. N.; ALMEIDA,D.R.A.; SILVA JUNIOR, C.H.L; KLAUBERG, C. NASA's Global Ecosystem Dynamics Investigation (GEDI) Simulator for ALS Data. version 0.3.0, accessed on April. 04 2024, available at: <https://CRAN.R-project.org/package=rGEDIsimulator>.

85.HANCOCK, S. et al. The GEDI simulator: A large-footprint waveform lidar simulator for calibration and validation of spaceborne missions. *Earth and Space Science*, v. 6, n. 2, p. 294-310, 2019.

86.HARDIMAN, B. S., BOHRER, G., GOUGH, C. M., & CURTIS, P. S. (2013). Canopy structural changes following widespread mortality of canopy dominant trees. *Forests*, 4(3), 537-552.

87.HARDIMAN, B. S., GOUGH, C. M., HALPERIN, A., HOFMEISTER, K. L., NAVE, L. E., BOHRER, G., & CURTIS, P. S. (2013). Maintaining high rates of carbon storage in old forests: A mechanism linking canopy structure to forest function. *Forest Ecology and Management*, 298, 111-119.

88.HARTLEY, R. J., JAYATHUNGA, S., MASSAM, P. D., DE SILVA, D., ESTARIJA, H. J., DAVIDSON, S. J., ... & PEARSE, G. D. (2022). Assessing the potential of backpack-mounted mobile laser scanning systems for tree phenotyping. *Remote Sensing*, 14(14), 3344.

89.HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. (2009). *An introduction to statistical learning*.

90.HIGUCHI, T. (ED.). (2012). *Biosynthesis and biodegradation of wood components*. Elsevier.

91.HINTZE, J. L., & NELSON, R. D. (1998). Violin plots: a box plot-density trace synergism. *The American Statistician*, 52(2), 181-184.

92.HOLCOMB, A., MATHIS, S. V., COOMES, D. A., & KESHAV, S. (2023). Computational tools for assessing forest recovery with GEDI shots and forest change maps. *Science of Remote Sensing*, 8, 100106.

93.HU, T., ZHANG, Y., SU, Y., ZHENG, Y., LIN, G., & GUO, Q. (2020). Mapping the global mangrove forest aboveground biomass using multisource remote sensing data. *Remote sensing*, 12(10), 1690.

94.HUNČAGA, M., CHUDÁ, J., TOMAŠTÍK, J., SLÁMOVÁ, M., KOREŇ, M., & CHUDÝ, F. (2020). The comparison of stem curve accuracy determined from point clouds acquired by different terrestrial remote sensing methods. *Remote Sensing*, 12(17), 2739.

95.Husch, B., Beers, T. W., & Kershaw Jr, J. A. (2002). *Forest mensuration*. John Wiley & Sons.

96.HYYPPÄ, E., MANNINEN, P., MAANPÄÄ, J., TAHER, J., LITKEY, P., HYYTI, H., ... & HYYPPÄ, J. (2023). Can the perception data of autonomous vehicles be used to replace mobile mapping surveys?—A case study surveying roadside city trees. *Remote Sensing*, 15(7), 1790.

97.HYYPPÄ, E., YU, X., KAARTINEN, H., HAKALA, T., KUKKO, A., VASTARANTA, M., & HYYPPÄ, J. (2020). Comparison of backpack, handheld, under-canopy UAV, and above-canopy UAV laser scanning for field reference data collection in boreal forests. *Remote Sensing*, 12(20), 3327.

98.HYYPPÄ, J., YU, X., HAKALA, T., KAARTINEN, H., KUKKO, A., HYYTI, H., ... & HYYPPÄ, E. (2021). Under-canopy UAV laser scanning providing canopy height and stem volume accurately. *Forests*, 12(7), 856.

99.IBGE, 1992. *Manual Técnico da Vegetação Brasileira*. Rio de Janeiro. Fundação Instituto Brasileiro de Geografia e Estatística - DERNA. (Manuais Técnicos de Geociências no 1). 92p.

100. Ilangakoon, N., GLENN, N. F., SCHNEIDER, F. D., DASHTI, H., HANCOCK, S., SPAETE, L., & GOULDEN, T. (2021). Airborne and spaceborne lidar reveal trends and patterns of functional diversity in a semi-arid ecosystem. *Frontiers in Remote Sensing*, 2, 743320.

101. JAAKKOLA, A., HYYPPÄ, J., YU, X., KUKKO, A., KAARTINEN, H., LIANG, X.,

... & WANG, Y. (2017). Autonomous collection of forest field reference—The outlook and a first step with UAV laser scanning. *Remote sensing*, 9(8), 785.

102. JÄÄSKELÄINEN, J., KORHONEN, L., KUKKONEN, M., PACKALEN, P., & MALTAMO, M. (2024). Individual tree inventory based on uncrewed aerial vehicle data: how to utilise stand-wise field measurements of diameter for calibration?.

103. JACON, A. D., GALVÃO, L. S., MARTINS-NETO, R. P., CRESPO-PEREMARCH, P., ARAGÃO, L. E., OMETTO, J. P., ... & DALAGNOL, R. (2024). Characterizing Canopy Structure Variability in Amazonian Secondary Successions with Full-Waveform Airborne LiDAR. *Remote Sensing*, 16(12), 2085.

104. JAKUBOWSKI, M. K., GUO, Q., & KELLY, M. (2013). Tradeoffs between lidar pulse density and forest measurement accuracy. *Remote Sensing of Environment*, 130, 245-253.

105. JIANG, K., CHEN, L., WANG, X., AN, F., ZHANG, H., & YUN, T. (2022). Simulation on different patterns of mobile laser scanning with extended application on solar beam illumination for forest plot. *Forests*, 13(12), 2139.

106. JIMÉNEZ-MÉNDEZ, O., GUEVARA-BONILLA, M., SOTO-MONTOYA, C., & QUESADA-MONGE, R. (2024). Use of a terrestrial laser scanner (TLS) for the structural characterization of tropical dry forest and forest plantations in Costa Rica. *Revista Forestal Mesoamericana Kurú*, 21(48), 27-38.

107. JOLLIFFE, I. T., & CADIMA, J. (2016). Principal component analysis: a review and recent developments. *Philosophical transactions of the royal society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202.

108. JONES, J. A., GROFFMAN, P. M., BLAIR, J., DAVIS, F. W., DUGAN, H., EUSKIRCHEN, E. E., ... & ZHU, K. (2021). Synergies among environmental science research and monitoring networks: a research agenda. *Earth's Future*, 9(3), e2020EF001631.

109. KOEHLER, A., GALVÃO, F., & LONGHI, S. J. (2002). Floresta Ombrófila Densa Altomontana: aspectos florísticos e estruturais de diferentes trechos na Serra do Mar,

PR. Ciência Florestal, 12(2), 27-39.

110. KOEHLER, A., GALVÃO, F., & LONGHI, S. J. (2002). Floresta Ombrófila Densa Altomontana: aspectos florísticos e estruturais de diferentes trechos na Serra do Mar, PR. Ciência Florestal, 12(2), 27-39.

111. KUHN, M., & JOHNSON, K. (2013). Over-fitting and model tuning. In Applied predictive modeling (pp. 61-92). New York, NY: Springer New York.

112. KUKKO, A. et al. Graph SLAM correction for single scanner MLS forest data under boreal forest canopy. ISPRS Journal of Photogrammetry and Remote Sensing, v. 132, p. 199-209, 2017.

113. KUZELKA, K. et al. Inventory of close-to-nature forest stands using terrestrial mobile laser scanning. International Journal of Applied Earth Observation and Geoinformation, v. 115, p. 103104, 2022.

114. KWAK, D. A., LEE, W. K., KAFATOS, M., SON, Y., CHO, H. K., & LEE, S. H. (2010). Estimation of effective plant area index for South Korean forests using LiDAR system. Science China Life Sciences, 53(7), 898-908.

115. LARUE, E. A., FAHEY, R. T., ALVESHARE, B. C., ATKINS, J. W., BHATT, P., BUMA, B., ... & FEI, S. (2023). A theoretical framework for the ecological role of three-dimensional structural diversity. Frontiers in Ecology and the Environment, 21(1), 4-13.

116. LARUE, E. A., HARDIMAN, B. S., ELLIOTT, J. M., & FEI, S. (2019). Structural diversity as a predictor of ecosystem function. Environmental Research Letters, 14(11), 114011.

117. LARUE, E. A., KNOTT, J. A., DOMKE, G. M., CHEN, H. Y., GUO, Q., HISANO, M., ... & FEI, S. (2023). Structural diversity as a reliable and novel predictor for ecosystem productivity. Frontiers in Ecology and the Environment, 21(1), 33-39.

118. LAUNEAU, P. et al. Airborne hyperspectral mapping of trees in an urban environment. International Journal of Remote Sensing, v. 39, n. 15-16, p. 5274-5295, 2018.

119. LAURANCE, W. F., CAMARGO, J. L., LUIZÃO, R. C., LAURANCE, S. G., PIMM, S. L., BRUNA, E. M., ... & LOVEJOY, T. E. (2011). The fate of Amazonian forest fragments: a 32-year investigation. *Biological conservation*, 144(1), 56-67.
120. LEFSKY, M. A. et al. Lidar remote sensing for ecosystem studies. *BioScience*, v. 52, n. 1, p. 19-30, 2002.
121. LEGENDRE, P.; LEGENDRE, L. *Numerical ecology*. 3. ed. Amsterdam: Elsevier, 2012.
122. LI, N., HO, C. P., XUE, J., LIM, L. W., CHEN, G., FU, Y. H., & LEE, L. Y. T. (2022). A progress review on solid-state LiDAR and nanophotonics-based LiDAR sensors. *Laser & Photonics Reviews*, 16(11), 2100511.
123. LI, S., QUACKENBUSH, L. J., & IM, J. (2019). Airborne lidar sampling strategies to enhance forest aboveground biomass estimation from Landsat imagery. *Remote Sensing*, 11(16), 1906.
124. LI, T. C., ZHAO, H., ZHANG, B., & DU, C. F. (2024). Effect of Structure and Wearing Modes on the Protective Performance of Industrial Safety Helmet. *Journal of Biomechanical Engineering*, 146(12), 121008.
125. LIANG, J., CROWTHER, T. W., PICARD, N., WISER, S., ZHOU, M., ALBERTI, G., ... & REICH, P. B. (2016). Positive biodiversity-productivity relationship predominant in global forests. *Science*, 354(6309), aaf8957.
126. LIEBSCH, D., MIKICH, S. B., POSSETTE, R. F. D. S., & RIBAS, O. D. S. (2009). Levantamento florístico e síndromes de dispersão em remanescentes de Floresta Ombrófila Mista na região centro-sul do estado do Paraná. *Hoehnea*, 36, 233-248.
127. LIN, Y., JIANG, M., PELLIKKA, P., & HEISKANEN, J. (2018). Recruiting conventional tree architecture models into state-of-the-art LiDAR mapping for investigating tree growth habits in structure. *Frontiers in plant science*, 9, 220.

128. LIU, B., HUANG, H., SU, Y., CHEN, S., LI, Z., CHEN, E., & TIAN, X. (2022). Tree species classification using ground-based LiDAR data by various point cloud deep learning methods. *Remote Sensing*, 14(22), 5733.
129. LIU, L., ZHANG, A., XIAO, S., HU, S., HE, N., PANG, H., ... & YANG, S. (2021). Single tree segmentation and diameter at breast height estimation with mobile LiDAR. *Ieee Access*, 9, 24314-24325.
130. MACDICKEN, K. G., SOLA, P., HALL, J. E., SABOGAL, C., TADOUM, M., & DE WASSEIGE, C. (2015). Global progress toward sustainable forest management. *Forest Ecology and Management*, 352, 47-56.
131. MACHADO, H. A., MALLMANN, A. A., ENGEL, K., FAVARIN, J. A. S., MODESTO, J. L. C., SANQUETTA, C. R., ... & TRAUTENMÜLLER, J. W. (2025). Aboveground biomass and carbon stocks in subtropical forests. *Ecological Indicators*, 172, 113294.
132. MACHADO, M. E. (2025). Influência da conservação ambiental sobre a diversidade de árvores em florestas da Mata Atlântica subtropical na Ilha de Santa Catarina.
133. MAGNAGO, L. F. S., ROCHA, M. F., MEYER, L., MARTINS, S. V., & MEIRANETO, J. A. A. (2015). Microclimatic conditions at forest edges have significant impacts on vegetation structure in large Atlantic forest fragments. *Biodiversity and Conservation*, 24(9), 2305-2318.
134. MAGURRAN, A. E. (2003). *Measuring biological diversity*. John Wiley & Sons.
135. MARGALEF, R. (1958) Information Theory in Ecology. *General Systems*, 3, 36-71.
136. MCELHINNY, C., GIBBONS, P., BRACK, C., & BAUHUS, J. (2005). Forest and woodland stand structural complexity: its definition and measurement. *Forest Ecology and Management*, 218(1-3), 1-24.

137. MEYER, V., SAATCHI, S., FERRAZ, A., XU, L., DUQUE, A., GARCÍA, M., & CHAVE, J. (2019). Forest degradation and biomass loss along the Chocó region of Colombia. *Carbon balance and management*, 14(1), 2.
138. MIAO, S., XIA, M., QIAN, M., ZHANG, Y., LIU, J., & LIN, H. (2022). Cloud/shadow segmentation based on multi-level feature enhanced network for remote sensing imagery. *International Journal of Remote Sensing*, 43(15-16), 5940-5960.
139. MITTERMEIER, R. A., TURNER, W. R., LARSEN, F. W., BROOKS, T. M., & GASCON, C. (2011). Global biodiversity conservation: the critical role of hotspots. In *Biodiversity hotspots* (pp. 3-22). Springer, Berlin, Heidelberg.
140. MOKROŠ, M., MIKITA, T., SINGH, A., TOMAŠTÍK, J., CHUDÁ, J., WEŻYK, P., ... & LIANG, X. (2021). Novel low-cost mobile mapping systems for forest inventories as terrestrial laser scanning alternatives. *International Journal of Applied Earth Observation and Geoinformation*, 104, 102512.
141. MORSDORF, F., MEIER, E., KÖTZ, B., ITTEN, K. I., DOBBERTIN, M., & ALLGÖWER, B. (2004). LIDAR-based geometric reconstruction of boreal type forest stands at single tree level for forest and wildland fire management. *Remote sensing of environment*, 92(3), 353-362.
142. NEGRINI, M., HIGUCHI, P., SILVA, A. C., SPIAZZI, F. R., BUZZI JUNIOR, F., & VEFAGO, M. B. (2014). Heterogeneidade florístico-estrutural do componente arbóreo em um sistema de fragmentos florestais no Planalto Sul catarinense. *Revista Árvore*, 38, 779-786.
143. NETTO, S. P., & BRENA, D. A. (1997). *Inventário florestal*. Ed. S. Péllico Netto, DA Brena.
144. NEUENSCHWANDER, A. et al. The ATL08 land and vegetation product for the ICESat-2 Mission. *Remote Sensing of Environment*, v. 221, p. 247-259, 2019.

145. NORDEN, N., ANGARITA, H. A., BONGERS, F., MARTÍNEZ-RAMOS, M., GRANZOW-DE LA CERDA, I., VAN BREUGEL, M., ... & CHAZDON, R. L. (2015). Successional dynamics in Neotropical forests are as uncertain as they are predictable. *Proceedings of the National Academy of Sciences*, 112(26), 8013-8018.
146. NUNES, S., OLIVEIRA, L., SIQUEIRA, J., MORTON, D. C., & SOUZA, C. M. (2020). Unmasking secondary vegetation dynamics in the Brazilian Amazon. *Environmental Research Letters*, 15(3), 034057.
147. OKSANEN, J., SIMPSON, G. L., BLANCHET, F. G., KINDT, R., LEGENDRE, P., MINCHIN, P. R., ... & WEEDON, J. (2001). *Vegan: community ecology package*. (No Title).
148. OLDEN, J. D., LAWLER, J. J., & POFF, N. L. (2008). Machine learning methods without tears: a primer for ecologists. *The Quarterly review of biology*, 83(2), 171-193.
149. OLIVEIRA FILHO, ARY T., et al. "Dinâmica da comunidade e populações arbóreas da borda e interior de um remanescente florestal na Serra da Mantiqueira, Minas Gerais, em um intervalo de cinco anos (1999-2004)." *Brazilian Journal of Botany* 30 (2007): 149-161.
150. OLIVEIRA, M. S., FINEGAN, B., CASANOVES, F., DELGADO, D., SEPULVEDA, N., PORRAS, A. A., ... & BIENG, M. A. N. (2021). Biomass of timber species in Central American secondary forests: Towards climate change mitigation through sustainable timber harvesting. *Forest Ecology and Management*, 496, 119439.
151. OLIVEIRA-FILHO, A. T., & FONTES, M. A. L. (2000). Patterns of floristic differentiation among Atlantic Forests in Southeastern Brazil and the influence of climate 1. *Biotropica*, 32(4b), 793-810.
152. OLIVER, C. D.; LARSON, B. C. *Forest stand dynamics*. New York: John Wiley & Sons, 1996.
153. PASTÓRIO, F. F.; GASPER, A. L.; VIBRANS, A. C. B. Successional stages of santa catarina atlantic subtropical evergreen rainforest: a classification method

proposal. CERNE, v. 26, n. 2, p.162-171, 2020.

154. PFEIFER, M., BOYLE, M. J., DUNNING, S., & OLIVIER, P. I. (2019). Forest floor temperature and greenness link significantly to canopy attributes in South Africa's fragmented coastal forests. *PeerJ*, 7, e6190.

155. PIELOU, E. C. (1966). The measurement of diversity in different types of biological collections. *Journal of theoretical biology*, 13, 131-144.

156. POORTER, L., BONGERS, F., AIDE, T. M., ALMEYDA ZAMBRANO, A. M., BALVANERA, P., BECKNELL, J. M., ... & ROZENDAAL, D. M. (2016). Biomass resilience of Neotropical secondary forests. *Nature*, 530(7589), 211-214.

157. POST, A. J., FORBES, B., COOPER, Z., FARO, K., SEEL, C., CLARK, M., ... & BENTLEY, L. P. (2025). Using handheld mobile laser scanning to quantify fine-scale surface fuels and detect changes post-disturbance in northern California forests. *Ecological Indicators*, 172, 113276.

158. POTAPOV, P., LI, X., HERNANDEZ-SERNA, A., TYUKAVINA, A., HANSEN, M. C., KOMMAREDDY, A., ... & HOFTON, M. (2021). Mapping global forest canopy height through integration of GEDI and Landsat data. *Remote Sensing of Environment*, 253, 112165.

159. PRETZSCH, H., DEL RÍO, M., BIBER, P., ARCANGELI, C., BIELAK, K., BRANG, P., ... & SYCHEVA, E. (2019). Maintenance of long-term experiments for unique insights into forest growth dynamics and trends: review and perspectives. *European Journal of Forest Research*, 138(1), 165-185.

160. PRIOR, E. M., THOMAS, V. A., & WYNNE, R. H. (2022). Estimation of mean dominant height using NAIP digital aerial photogrammetry and lidar over mixed deciduous forest in the southeastern USA. *International Journal of Applied Earth Observation and Geoinformation*, 110, 102813.

161. PUENTE, I., SANDE, J., GONZÁLEZ-JORGE, H., PEÑA-GONZÁLEZ, E., MACIÑEIRA, E., MARTÍNEZ-SÁNCHEZ, J., & ARIAS, P. (2014). Novel image analysis approach to the terrestrial LiDAR monitoring of damage in rubble mound

breakwaters. *Ocean engineering*, 91, 273-280.

162. PUTTONEN, E., JAAKKOLA, A., LITKEY, P., & HYYPPÄ, J. (2011). Tree classification with fused mobile laser scanning and hyperspectral data. *Sensors*, 11, 5158-5182.

163. PYÖRÄLÄ, J., LIANG, X., VASTARANTA, M., SAARINEN, N., KANKARE, V., WANG, Y., ... & HYYPPÄ, J. (2018). Quantitative assessment of Scots pine (*Pinus sylvestris* L.) whorl structure in a forest environment using terrestrial laser scanning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3598-3607.

164. QI, Z., LI, S., PANG, Y., DU, L., ZHANG, H., & LI, Z. (2023). Monitoring spatiotemporal variation of individual tree biomass using multitemporal LiDAR data. *Remote Sensing*, 15(19), 4768.

165. QIAN, C., LIU, H., TANG, J., CHEN, Y., KAARTINEN, H., KUKKO, A., ... & HYYPPÄ, J. (2016). An integrated GNSS/INS/LiDAR-SLAM positioning method for highly accurate forest stem mapping. *Remote Sensing*, 9(1), 3.

166. QUINN, G. P.; KEOUGH, M. J. *Experimental design and data analysis for biologists*. Cambridge: Cambridge University Press, 2002.

167. R CORE TEAM. *R: A language and environment for statistical computing*. Vienna: R Foundation for Statistical Computing, 2023. Disponível em: <https://www.R-project.org/>. Acesso em: 10 jan. 2023.

168. REIS, L. C. T. D. (2020). Acurácia de modelos digitais de elevação obtidos com uav em relação a dados SRTM e LIDAR.

169. REZENDE, C. L., SCARANO, F. R., ASSAD, E. D., JOLY, C. A., METZGER, J. P., STRASSBURG, B. B. N., ... & MITTERMEIER, R. A. (2018). From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. *Perspectives in ecology and conservation*, 16(4), 208-214.

170. RICHARDS, P. W. (1952). *The tropical rain forest: an ecological study*.

171. RIVEIRO, B., GONZÁLEZ-JORGE, H., MARTÍNEZ-SÁNCHEZ, J., DÍAZ-VILARIÑO, L., & ARIAS, P. (2015). Automatic detection of zebra crossings from mobile LiDAR data. *Optics & Laser Technology*, 70, 63-70.
172. ROBERTS, D. R., BAHN, V., CIUTI, S., BOYCE, M. S., ELITH, J., GUILLERA-ARROITA, G., ... & DORMANN, C. F. (2017). Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, 40(8), 913-929.
173. ROKACH, L. (2010). Ensemble-based classifiers. *Artificial intelligence review*, 33(1), 1-39.
174. ROUSSEEUW, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 20, 53-65.
175. ROUSSEL JEAN-ROMAIN, BOURDON JEAN-FRANCOIS, ACHIM ALEXIS, (2020) Range-based intensity normalization of ALS data over forested areas using a sensor tracking method from multiple returns (preprint) Retrieved from eartharxiv.org/k32qw <https://doi.org/10.31223/osf.io/k32qw>.
176. ROUSSEL, J. R., ACHIM, A., & AUTY, D. (2021). Classification of high-voltage power line structures in low density ALS data acquired over broad non-urban areas. *PeerJ Computer Science*, 7, e672.
177. ROUSSEL, J. R., AUTY, D., COOPS, N. C., TOMPALSKI, P., GOODBODY, T. R., MEADOR, A. S., ... & ACHIM, A. (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251, 112061.
178. ROUSSEL, J. R.; AUTY, D. Airborne LiDAR data manipulation and visualization for forestry applications. R package lidR, 2022.
179. ROZENDAAL, D. M., BONGERS, F., AIDE, T. M., ALVAREZ-DÁVILA, E., ASCARRUNZ, N., BALVANERA, P., ... & POORTER, L. (2019). Biodiversity recovery of Neotropical secondary forests. *Science advances*, 5(3), eaau3114.
180. SAARINEN, N., VASTARANTA, M., VAAJA, M., LOTSARI, E., JAAKKOLA, A., KUKKO, A., ... & ALHO, P. (2013). Abordagem baseada em área para mapeamento e

monitoramento da vegetação ribeirinha usando varredura a laser móvel. *Sensoriamento Remoto*, 5 (10), 5285-5303.

181. SALZMANN, A. M., DALLA CORTE, A. P., & SANQUETTA, C. R. (2011). Aprimoramento do método hM para estratificação vertical de uma floresta com araucária hM method improvement for vertical stratification of an Araucaria forest. *AMBIÊNCIA*, 7(3), 575-586.

182. SANA EI, A., ALI, A., AHMADAALI, K., & JAHANTAB, E. (2019). Generalized and species-specific prediction models for aboveground biomass in semi-steppe rangelands. *Journal of Plant Ecology*, 12(3), 428-437.

183. SANA EI, A., ALI, A., YUAN, Z., LIU, S., LIN, F., FANG, S., ... & WANG, X. (2021). Context-dependency of tree species diversity, trait composition and stand structural attributes regulate temperate forest multifunctionality. *Science of The Total Environment*, 757, 143724.

184. SANQUETTA, C. R. (1995). Análise da estrutura vertical de florestas através do diagrama hM. *Ciência Florestal*, 5(1), 55-68.

185. SANQUETTA, C. R.; MATTEI, E. *Perspectivas de recuperação e manejo sustentável das florestas de araucária*. Curitiba: Multi-Graphic, 2006.

186. SANTOS, C. (2007). *Estatística descritiva: manual de auto-aprendizagem*. Lisboa: Ed.

187. SANTOS, L. H. O., RAMIREZ, G. M., ROQUE, M. W., CHAVES E CARVALHO, M. P. D. L., RUIZ DIAZ, L. M. G., & CHAVES E CARVALHO, S. P. (2019). CORRELAÇÃO ENTRE UNIFORMIDADE E NDVI EM POVOAMENTOS DE *Tectona grandis* L. f. *BIOFIX Scientific Journal*, 4(2).

188. SCARANO, F. R., & CEOTTO, P. (2015). Brazilian Atlantic forest: impact, vulnerability, and adaptation to climate change. *Biodiversity and Conservation*, 24(9), 2319-2331.

189. SCHEERES, J., DE JONG, J., BREDE, B., BRANCALION, P. H., BROADBENT, E. N., ZAMBRANO, A. M. A., ... & DE ALMEIDA, D. R. A. (2023).

Distinguishing forest types in restored tropical landscapes with UAV-borne LIDAR. *Remote Sensing of Environment*, 290, 113533.

190. SECCO, R. T., BLUM, C. T., & VELAZCO, S. J. E. (2017). Florística e ecologia de dois bancos de sementes em região de Floresta Ombrófila Mista no município de Campo do Tenente, PR.

191. SENF, C., BURAS, A., ZANG, C. S., RAMMIG, A., & SEIDL, R. (2020). Excess forest mortality is consistently linked to drought across Europe. *Nature communications*, 11(1), 6200.

192. SERRANO, F. L., RUBIO, E., MOROTE, F. G., ABELLÁN, M. A., CÓRDOBA, M. P., SAUCEDO, F. G., ... & GONZÁLEZ, J. G. (2022). Artificial intelligence-based software (AID-Forest) for tree detection: a new framework for fast and accurate forest inventorying using LiDAR point clouds. *International Journal of Applied Earth Observation and Geoinformation*, 113, 103014.

193. SHANNON, C. E. (1948). A mathematical theory of communication. *The Bell system technical journal*, 27(3), 379-423.

194. SHAO, J., ZHANG, W., MELLADO, N., JIN, S., CAI, S., LUO, L., ... & ZHOU, G. (2020). Single scanner BLS system for forest plot mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 59(2), 1675-1685.

195. SILVA, C. A. et al. rGEDI: NASA's Global Ecosystem Dynamics Investigation (GEDI) Data Visualization and Processing in R. *Methods in Ecology and Evolution*, v. 13, n. 7, p. 1365-1371, 2022.

196. SILVA, C. A., SAATCHI, S., GARCIA, M., LABRIERE, N., KLAUBERG, C., FERRAZ, A., ... & HUDAK, A. T. (2019). Comparison of small-and large-footprint lidar characterization of tropical forest aboveground structure and biomass: a case study from Central Gabon. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3512-3526.

197. SILVA, C.A. RGEDI: NASA's Global Ecosystem Dynamics Investigation (GEDI) Data Visualization and Processing. R Package. 2020. Available online:

<https://CRAN.R-project.org/package=rGEDI>

198. SIMONSON, W., ALLEN, H., & COOMES, D. (2018). Effect of tree phenology on LiDAR measurement of mediterranean forest structure. *Remote Sensing*, 10(5), 659.
199. SMITH, P., ARNETH, A., BARNES, D. K., ICHII, K., MARQUET, P. A., POPP, A., ... & NGO, H. (2022). How do we best synergize climate mitigation actions to co-benefit biodiversity?. *Global Change Biology*, 28(8), 2555-2577.
200. SOTHE, C., MCCARTHY, R., & ANDERSON, C. B. (2024, July). An Unsupervised Approach to Build a Training Dataset for Individual Tree Crown Delineation Using Airborne Lidar and Field Observations. In *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium* (pp. 5310-5315). IEEE.
201. SOUZA JR, C. M., Z. SHIMBO, J., ROSA, M. R., PARENTE, L. L., A. ALENCAR, A., RUDORFF, B. F., ... & AZEVEDO, T. (2020). Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. *Remote Sensing*, 12(17), 2735.
202. STĂNCIOIU, P. T., DUTCĂ, I., FLOREA, S. C., & PARASCHIV, M. (2022). Measuring Distances and Areas under Forest Canopy Conditions—A Comparison of Handheld Mobile Laser Scanner and Handheld Global Navigation Satellite System. *Forests*, 13(11), 1893.
203. TABARELLI, M., AGUIAR, A. V., GIRAO, L. C., PERES, C. A., & LOPES, A. V. (2010). Effects of pioneer tree species hyperabundance on forest fragments in northeastern Brazil. *Conservation Biology*, 24(6), 1654-1663.
204. TANG, J., CHEN, Y., KUKKO, A., KAARTINEN, H., JAAKKOLA, A., KHORAMSHAHI, E., ... & HYYPPÄ, H. (2015). SLAM-aided stem mapping for forest inventory with small-footprint mobile LiDAR. *Forests*, 6(12), 4588-4606.
205. TIJERÍN-TRIVIÑO, J., MORENO-FERNÁNDEZ, D., ZAVALA, M. A., ASTIGARRAGA, J., & GARCÍA, M. (2022). Identifying forest structural types along an aridity gradient in peninsular Spain: integrating low-density LiDAR, forest inventory,

and aridity index. *Remote Sensing*, 14(1), 235.

206. TORRESANI, M., ROCCHINI, D., SONNENSCHNEIN, R., ZEBISCH, M., HAUFFE, H. C., HEYM, M., ... & TONON, G. (2020). Height variation hypothesis: A new approach for estimating forest species diversity with CHM LiDAR data. *Ecological Indicators*, 117, 106520.

207. VALBUENA, R. et al. Standardizing ecosystem morphological traits from 3D information sources. *Trends in Ecology & Evolution*, v. 35, n. 8, p. 656-667, 2020.

208. VALBUENA, R., HERNANDO, A., MANZANERA, J. A., GÖRGENS, E. B., ALMEIDA, D. R. A., MAURO, F., ... & COOMES, D. A. (2017). Enhancing of accuracy assessment for forest above-ground biomass estimates obtained from remote sensing via hypothesis testing and overfitting evaluation. *Ecological Modelling*, 366, 15-26.

209. VANDENDAELE, B., MARTIN-DUCUP, O., FOURNIER, R. A., PELLETIER, G., & LEJEUNE, P. (2022). Mobile laser scanning for estimating tree structural attributes in a temperate hardwood Forest. *Remote Sensing*, 14(18), 4522.

210. VATANDAŞLAR, C., SEKI, M., & ZEYBEK, M. (2023). Assessing the potential of mobile laser scanning for stand-level forest inventories in near-natural forests. *Forestry: An International Journal of Forest Research*, 96(4), 448-464.

211. VIERA, A. J., & GARRETT, J. M. (2005). Understanding interobserver agreement: the kappa statistic. *Fam med*, 37(5), 360-363.

212. VIERLING, K. T., VIERLING, L. A., GOULD, W. A., MARTINUZZI, S., & CLAWGES, R. M. (2008). Lidar: shedding new light on habitat characterization and modeling. *Frontiers in Ecology and the Environment*, 6(2), 90-98.

213. VIRIEUX, J., OPERTO, S., BEN-HADJ-ALI, H., BROSSIER, R., ETIENNE, V., SOURBIER, F., ... & HAIDAR, A. (2009). Seismic wave modeling for seismic imaging. *The Leading Edge*, 28(5), 538-544.

214. WANG, H., WANG, J., WANG, J., ZHAO, M., ZHANG, W., ZHANG, F., ... & GUO, M. (2018, April). Graphgan: Graph representation learning with generative

adversarial nets. In Proceedings of the AAAI conference on artificial intelligence (Vol. 32, No. 1).

215. WHITMORE, T. (1989). Canopy gaps and the two major groups of forest trees. *Ecology*, 70(3), 536-538.

216. WICKHAM, H., & BRYAN, J. (2023). R packages. " O'Reilly Media, Inc."

217. WITTEN, I. H., FRANK, E., HALL, M. A., PAL, C. J., & DATA, M. (2017, December). Practical machine learning tools and techniques. In *Data mining* (Vol. 2, No. 4, pp. 403-413). Amsterdam, The Netherlands: Elsevier Publishers.

218. WU, B., YU, B., YUE, W., SHU, S., TAN, W., HU, C., ... & LIU, H. (2013). A voxel-based method for automated identification and morphological parameters estimation of individual street trees from mobile laser scanning data. *Remote Sensing*, 5(2), 584-611.

219. WULDER, M. A., WHITE, J. C., NELSON, R. F., NÆSSET, E., ØRKA, H. O., COOPS, N. C., ... & GOBAKKEN, T. (2012). Lidar sampling for large-area forest characterization: A review. *Remote sensing of environment*, 121, 196-209.

220. YU, X., HYYPPÄ, J., LITKEY, P., KAARTINEN, H., VASTARANTA, M., & HOLOPAINEN, M. (2017). Single-sensor solution to tree species classification using multispectral airborne laser scanning. *Remote Sensing*, 9(2), 108.

221. YUN, T., AN, F., LI, W., SUN, Y., CAO, L., & XUE, L. (2016). A novel approach for retrieving tree leaf area from ground-based LiDAR. *Remote Sensing*, 8(11), 942.

222. ZEYBEK, M., & VATANDAŞLAR, C. (2021). An automated approach for extracting forest inventory data from individual trees using a handheld mobile laser scanner. *Croatian Journal of Forest Engineering: Journal for Theory and Application of Forestry Engineering*, 42(3), 515-528.

223. ZHAO, Y., HU, Q., LI, H., WANG, S., & AI, M. (2018). Evaluating carbon sequestration and PM_{2.5} removal of urban street trees using mobile laser scanning data. *Remote Sensing*, 10(11), 1759.

224. ZHOU, S., KANG, F., LI, W., KAN, J., ZHENG, Y., & HE, G. (2019). Extracting

diameter at breast height with a handheld mobile LiDAR system in an outdoor environment. *Sensors*, 19(14), 3212.

225. ZHOU, X., & LI, C. (2023). Mapping the vertical forest structure in a large subtropical region using airborne LiDAR data. *Ecological Indicators*, 154, 110731.

226. ZIEGELMAIER NETO, B. H., SCHIMALSKI, M. B., LIESENBERG, V., SOTHE, C., MARTINS-NETO, R. P., & FLORIANI, M. M. P. (2024). Combining LIDAR and spaceborne multispectral data for mapping successional forest stages in subtropical forests. *Remote Sensing*, 16(9), 1523.

227. ZLINSZKY, A., MÜCKE, W., LEHNER, H., BRIESE, C., & PFEIFER, N. (2012). Categorizing wetland vegetation by airborne laser scanning on Lake Balaton and Kis-Balaton, Hungary. *Remote Sensing*, 4(6), 1617-1650.