

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA SUSTENTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

Fernando Santos Boggiani

Detecção de árvores individuais e cubagem de *Pinus elliottii* utilizando LiDAR UAV e MLS

Sorocaba

2026

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA SUSTENTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

Fernando Santos Boggiani

Dissertação ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis para obtenção do título de Mestre em Planejamento e Uso de Recursos Renováveis da Universidade Federal de São Carlos.

Orientação: Profº Drº Cláudio Roberto Thiersch
Coorientação: Profº Drº Cristiano Rodrigues Reis

Financiamento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Sorocaba

2026

Boggiani, Fernando Santos

Detecção de árvores individuais e cubagem de *Pinus elliottii* utilizando LiDAR UAV e MLS / Fernando Santos Boggiani -- 2026.
73f.

Dissertação (Mestrado) - Universidade Federal de São Carlos, campus Sorocaba, Sorocaba
Orientador (a): Cláudio Roberto Thiersch
Banca Examinadora: Ximena Mendes de Oliveira, Carla Américo
Bibliografia

1. Biometria. 2. Lidar. I. Boggiani, Fernando Santos. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano - CRB/8
6979



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências e Tecnologias Para a Sustentabilidade
Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis

Folha de Aprovação

Folha de Aprovação Defesa de Dissertação de Mestrado do candidato Fernando Santos Boggiani, realizada em 15/05/2026.

Comissão Julgadora:

Prof. Dr. Cláudio Roberto Thiersch (UFSCar)

Profa. Dra. Ximena Mendes de Oliveira (UFSCar)

Profa. Dra. Carla Américo (Unesp)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis.

AGRADECIMENTO

Ao Prof. Dr. Cláudio Roberto Thiersch, por ter despertado meu interesse pelo inventário florestal, e por toda a orientação, apoio, confiança e amizade nestes últimos anos de pesquisas e projetos.

A todos os membros do grupo de pesquisa Sample, pelas contribuições neste trabalho, em especial à Maria Inês, que me apresentou o LiDAR, guiou-me e ajudou-me em muitas decisões durante os dois anos de mestrado. Ao Evandro, Murilo e Vinícius, pela ajuda essencial na última coleta de campo.

Aos professores Pedro e Karina, que proporcionaram muito conhecimento com o projeto da FLONA de Capão Bonito, onde tive ótimos momentos em campo e defini as linhas desta pesquisa.

Aos colegas da equipe de inventário florestal com os quais convivi durante minha passagem pela Bracell e com quem aprendi muito sobre toda a rotina do inventário em uma empresa florestal, tanto no campo quanto no escritório: ao coordenador Gustavo Martins; ao especialista Pedro; aos supervisores Atny e Elivelton; aos colegas de escritório Gustavo Henrique, Iana, Arthur, Bárbara e Kálita; e ao grande time de campo Jean, Wellington Darc, Wellington, Adriano, Carlos, Ronaldo e Lucas.

Ao meu pai, Luiz Roberto, por me ensinar que a honestidade é o maior princípio de um homem, e por me inspirar a ter uma vida com muitas histórias para contar.

À minha avó Esmeralda, por me mostrar que a vida é luta, trabalho e alegria!

A toda a minha família, que de todas as formas proporcionou minha permanência na jornada acadêmica, em especial ao meu tio Paulo, à minha mãe Ana Maria, à minha irmã Rafaela, à minha pequena sobrinha Olívia, às tias Cláudia e Ana Lúcia, e às minhas primas Camila e Helena.

Aos meus amigos de Sorocaba, que sempre me apoiaram a seguir em frente e a chegar onde estou: Pedro, Gregory, Matheus e Carolina.

À minha namorada, Ana, que está comigo em todos os momentos.

Aos amigos da graduação que me acompanham até hoje, em especial ao Marcos, Lucas, Gabriel, Pablo e Alex.

Ao CNPq, pela oportunidade de realizar um mestrado com bolsa.

À FLONA de Capão Bonito, pela concessão da área de coleta de dados neste estudo.

RESUMO

BOGGIANI, Fernando Santos. **Detecção de árvores individuais e cubagem de *Pinus elliottii* utilizando LiDAR UAV e MLS**. 2026. Dissertação (Mestrado em Planejamento e Uso de Recursos Renováveis) – Universidade Federal de São Carlos, Sorocaba, 2026.

Este trabalho teve como objetivo avaliar, aprimorar e validar abordagens metodológicas computacionais baseadas em nuvens de pontos LiDAR (*Light Detection and Ranging*) embarcado em dispositivos móveis e aéreos para estimativa de parâmetros dendrométricos em povoamentos de *Pinus elliottii*. A dissertação está dividida em dois capítulos. O primeiro avaliou o desempenho de algoritmos para a Detecção de Árvores Individuais (ITD) a partir de dados LiDAR UAV (Veículos Aéreos Não Tripulados), contrapondo uma metodologia fundamentada no Seccionamento Transversal da nuvem de pontos (STAD) com agrupamento via algoritmo DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) em comparação aos métodos tradicionais de contagem pelo dossel. O método STAD obteve o menor RMSE (8,43% em parcelas circulares e 11,11% em retangulares) ao focar na seção dos fustes abaixo das copas. O segundo capítulo abordou a cubagem não destrutiva utilizando um LiDAR MLS (Escaneamento a Laser móvel). O método tradicional de cubagem destrutiva com suta foi comparado com dois métodos de coleta de diâmetros na nuvem de pontos LiDAR: o primeiro, baseado no Seccionamento Transversal e Contornos por Classes Angulares (STAC) em linguagem R, avaliando diferentes métricas e classes angulares; e o segundo, processado no software CloudCompare com o plugin 3Dfin. A parametrização do método STAC (72 classes angulares e métrica de ponto mínimo) obteve a maior acurácia (RMSE de 5,94% e BIAS de 2,5%). Conclui-se que o método STAD supera as limitações dos algoritmos clássicos centrados no dossel, enquanto a rotina STAC comprova viabilidade operacional e maior aderência ao contorno de cada seção dos fustes em relação ao método tradicional e algoritmos consolidados na literatura.

Palavras-chave: Biometria florestal; DBSCAN; Nuvem de pontos.

ABSTRACT

BOGGIANI, Fernando Santos. **Individual tree detection and stem profiling in *Pinus elliottii* using UAV and MLS LiDAR**. 2026. Dissertation (Master's in Planning and Use of Renewable Resources) – Federal University of São Carlos, Sorocaba, 2026.

This study aimed to evaluate, improve, and validate computational methodological approaches based on LiDAR (Light Detection and Ranging) point clouds embedded in mobile and aerial devices to estimate dendrometric parameters in *Pinus elliottii* stands. The dissertation is divided into two chapters. The first evaluated the performance of Individual Tree Detection (ITD) algorithms using UAV (Unmanned Aerial Vehicle) LiDAR data, contrasting a methodology based on point cloud Cross-Sectioning (STAD) with clustering via the DBSCAN (Density-Based Spatial Clustering of Applications with Noise) algorithm against traditional canopy-based counting methods. The STAD method achieved the lowest RMSE (8.43% in circular plots and 11.11% in rectangular plots) by focusing on the stem section below the crowns. The second chapter addressed non-destructive stem profiling using MLS (Mobile Laser Scanning) LiDAR. The traditional destructive stem profiling method using a caliper was compared with two methods of diameter collection from the LiDAR point cloud: the first, based on Cross-Sectioning and Contours by Angular Classes (STAC) in the R language, evaluating different metrics and angular classes; and the second, processed in the CloudCompare software using the 3Dfin plugin. The STAC method parameterization (72 angular classes and minimum point metric) obtained the highest accuracy (RMSE of 5.94% and BIAS of 2.5%). It is concluded that the STAD method overcomes the limitations of classic canopy-centered algorithms, while the STAC routine proves operational viability and greater adherence to the contour of each stem section compared to the traditional method and algorithms consolidated in the literature.

Keywords: Forest Biometrics; DBSCAN; Point Cloud.

LISTA DE ABREVIATURAS E SIGLAS

BIAS – Viés
CC – *CloudCompare*
CSF – *Cloth Simulation Filter*
CV – Coeficiente de Variação
DAP – Diâmetro à Altura do Peito
DBSCAN – *Density-Based Spatial Clustering of Applications with Noise*
FLONA – Floresta Nacional
GNSS – *Global Navigation Satellite System* (Sistema Global de Navegação por Satélite)
HDBSCAN – *Hierarchical Density-Based Spatial Clustering of Applications with Noise*
IBÁ – Indústria Brasileira de Árvores
IDW – *Inverse Distance Weighting* (Ponderação pelo Inverso da Distância)
IMU – Unidade de Medição Inercial (*Inertial Measurement Unit*)
ITD – Detecção de Árvores Individuais (*Individual Tree Detection*)
KNN – *k-Nearest Neighbors*
LiDAR – *Light Detection and Ranging*
LMF – Filtro de Máximos Locais
MDSN – Modelo Digital de Superfície Normalizado
MDT – Modelo Digital de Terreno
MLS – *Mobile Laser Scanning* (Varredura a laser móvel)
PIB – Produto Interno Bruto
RANSAC – *Random Sample Consensus*
RGB – *Red, Green, Blue* (Vermelho, Verde, Azul)
RMSE – Raiz do Erro Quadrático Médio (*Root Mean Square Error*)
RTK – *Real-Time Kinematic*
SIRGAS – Sistema de Referência Geocêntrico para as Américas
SLAM – *Simultaneous Localization and Mapping*
SOR – *Statistical Outlier Removal*
STAC – Seccionamento Transversal e Contornos por Classes Angulares
STAD – Seccionamento Transversal do Fuste e Agrupamento com Algoritmo DBSCAN
TLS – *Terrestrial Laser Scanning*
UTM – *Universal Transverse Mercator*

SUMÁRIO

1 INTRODUÇÃO	10
2 CAPÍTULO 1	13
2.1 INTRODUÇÃO	14
2.2 MATERIAL E MÉTODOS	15
2.2.1 Área de estudo.....	16
2.2.2 Coleta de dados e processamento da nuvem de pontos.....	16
2.2.3 Dimensionamento dos pontos amostrais	17
2.2.4 Contagem de indivíduos nas unidades amostrais	18
2.2.5 Métodos de contagem avaliados	21
2.2.5.1 Filtro de máximos locais (LMF)	21
2.2.5.2 Algoritmo Li 2012 (LI).....	22
2.2.5.3 Seccionamento Transversal do Fuste e Agrupamento com Algoritmo DBSCAN (STAD)	23
2.2.5.4 Síntese dos cenários avaliados	25
2.2.6 Análise estatística e eficiência computacional.....	26
2.3 RESULTADOS E DISCUSSÃO	27
2.4 CONCLUSÃO	35
3 CAPÍTULO 2	41
3.1 INTRODUÇÃO	42
3.2 MATERIAL E MÉTODOS	43
3.2.1 Área de estudo.....	43
3.2.2 Coleta MLS e pré-processamento da nuvem de pontos.....	44
3.2.3 Métodos de obtenção e estimativa diamétrica avaliados	47
3.2.3.1 Algoritmo 3Dfin	47
3.2.3.2 Seccionamento Transversal e Contornos por Classes Angulares (STAC) ...	49
3.2.3.2.1 Individualização dos fustes.....	49
3.2.3.2.2 Seccionamento transversal e definição de contornos.....	51
3.2.3.3 Cubagem Rigorosa tradicional com suta	55
3.2.3.4 Síntese dos cenários avaliados	57
3.2.4 Análise estatística e eficiência computacional.....	57
3.3 RESULTADOS E DISCUSSÃO	59
3.4 CONCLUSÃO	68
4 CONCLUSÕES GERAIS	73

1 INTRODUÇÃO

O setor de base florestal brasileiro é um dos mais competitivos e produtivos do mundo, ancorado no manejo intensivo e na alta tecnologia aplicada aos plantios comerciais, com um crescimento de 10,4% no Produto Interno Bruto (PIB) em 2024. Nesse cenário, o país possui cerca de 10,5 milhões de hectares de florestas plantadas, sendo os gêneros *Eucalyptus* e *Pinus* os grandes protagonistas no fornecimento de matéria-prima para os mais diversos fins industriais, desde a produção de celulose e papel até madeira serrada, painéis e resina (IBÁ, 2025).

Para quantificar esse estoque, a biometria florestal e o inventário contínuo tradicionalmente apoiam-se na amostragem estatística, na qual parcelas representativas são medidas em campo e os resultados extrapolados para o restante do talhão. Contudo, os métodos convencionais de mensuração apresentam gargalos operacionais substanciais. A dependência de instrumentos analógicos, como sutas e fitas métricas, além do uso de métodos destrutivos para a cubagem rigorosa e o ajuste de equações de volume, tornam o processo oneroso, lento e suscetível a erros não amostrais (SOARES et al., 2011; WHITE et al., 2016).

Em resposta a essas limitações, novas tecnologias têm impulsionado o sensoriamento remoto para aprimorar a estimativa de atributos florestais. Entre essas inovações, a tecnologia LiDAR (*Light Detection and Ranging*) consolidou-se como uma ferramenta disruptiva. Ao utilizar o LiDAR aéreo, por exemplo, a emissão de pulsos laser é capaz de penetrar as falhas do dossel, permitindo a reconstrução estrutural da floresta em nuvens de pontos 3D de alta densidade. Essa capacidade tecnológica pode viabilizar a transição do inventário baseado em amostragem para a perspectiva do censo florestal, no qual os indivíduos de um plantio podem ser localizados e mensurados de forma individualizada (HOLOPAINEN et al., 2014; KANGAS et al., 2018).

Atualmente, o rápido avanço na miniaturização dos sensores permitiu a integração do LiDAR em múltiplas plataformas, abrindo novas fronteiras para a caracterização florestal a partir de diferentes perspectivas geométricas. Sensores embarcados em plataformas aéreas, como os Veículos Aéreos Não Tripulados (UAVs ou Drones), oferecem uma visão *top-down* (de cima para baixo), ideal para a varredura rápida de grandes áreas. No entanto, em povoamentos maduros e densos como os de *Pinus elliottii*, o intenso fechamento do dossel e a complexidade das copas frequentemente causam oclusões, desafiando o desempenho de algoritmos clássicos de Detecção de Árvores Individuais (ITD – do inglês *Individual Tree Detection*) e exigindo abordagens de processamento mais robustas e menos dependentes dos ápices (MOHAN et al., 2021).

Por outro lado, os sistemas móveis de varredura a laser (HMLS - *Handheld Mobile Laser Scanning*), que operam no sub-bosque sustentados por algoritmos de localização e mapeamento simultâneos (SLAM – do inglês *Simultaneous Localization and Mapping*), oferecem uma perspectiva *bottom-up* (de baixo para cima). Essa abordagem terrestre contorna as oclusões do dossel e fornece uma nuvem de pontos com maior densidade nos fustes. Este detalhamento permite a extração de perfis transversais, para a obtenção de diâmetros ao longo do tronco e a realização de cubagem de forma totalmente não destrutiva (LIANG et al., 2018; DALLA CORTE et al., 2020). O grande desafio tecnológico atual, no entanto, está na capacidade de processar computacionalmente essa massiva quantidade de dados de forma eficiente, contornando ruídos e irregularidades morfológicas próprias da árvore.

Nesse contexto de modernização do inventário e necessidade de soluções computacionais aplicadas, a presente dissertação propõe avaliar, aprimorar e validar abordagens metodológicas baseadas em nuvens de pontos LiDAR para a estimativa de parâmetros dendrométricos em *Pinus elliottii*.

REFERÊNCIAS

- DALLA CORTE, A. P.; SOUZA, D. V.; REX, F. E.; SANQUETTA, C. R.; et al. Forest inventory with high-density UAV-LiDAR: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, p. 105815, 2020.
- HOLOPAINEN, M.; VASTARANTA, M.; HYYPPÄ, J. Outlook to forest inventories of future. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 18-26, 2014.
- IBÁ – INDÚSTRIA BRASILEIRA DE ÁRVORES. Relatório Anual 2025. Brasília: IBÁ, 2025. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/relatorio-iba-2025.pdf>.
- KANGAS, A.; et al. Remote sensing and forest inventories in Nordic countries – roadmap for the future. **Scandinavian Journal of Forest Research**, v. 33, n. 4, p. 397-412, 2018.
- LIANG, X.; HYYPPÄ, J.; KAARTINEN, H.; LEHTOMÄKI, M.; PYÖRÄLÄ, J.; PFEIFER, N.; HOLLAUS, M. International benchmarking of terrestrial laser scanning approaches for forest inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 144, p. 137-179, 2018.
- MOHAN, M.; et al. Individual tree detection using UAV-lidar and UAV-SfM data: a tutorial for beginners. **Open Geosciences**, v. 13, p. 1028-1039, 2021. Disponível em: <https://doi.org/10.1515/geo-2020-0290>.
- SOARES, C. P. B.; PAULA NETO, F. DE; SOUZA, A. L. DE. Dendrometria e inventário florestal. 2. ed. Viçosa, MG: Editora UFV, 2011.
- WHITE, J. C.; COOPS, N. C.; WULDER, M. A.; VASTARANTA, M.; HILKER, T.; TOMPALSKI, P. Remote sensing technologies for enhancing forest inventories: A review. **Canadian Journal of Forest Research**, Ottawa, v. 46, n. 5, p. 619-646, 2016.

2 CAPÍTULO 1

DETECÇÃO DE ÁRVORES INDIVIDUAIS EM NUVEM DE PONTOS LiDAR UAV

RESUMO

BOGGIANI, Fernando Santos. Título: **DETECÇÃO DE ÁRVORES INDIVIDUAIS EM NUVEM DE PONTOS LiDAR UAV**. Sorocaba: UFSCar, 2026. Cap 1. P. 12. Dissertação (Mestrado em Planejamento e Uso de Recursos Renováveis) – Universidade Federal de São Carlos, Sorocaba, 2026.

A necessidade de estimativas de estoque cada vez mais acuradas tem impulsionado a transição do modelo de inventário florestal amostral para o censo florestal completo, cenário no qual a tecnologia LiDAR embarcada em Veículos Aéreos Não Tripulados (UAV) apresenta grande destaque. Contudo, a Detecção de Árvores Individuais (ITD) em povoamentos antigos enfrenta desafios estruturais devido ao intenso fechamento do dossel. Este capítulo teve como objetivo avaliar e comparar o desempenho de diferentes metodologias de ITD aplicadas a uma nuvem de pontos LiDAR UAV de alta densidade (500 pontos.m⁻²) em um talhão de *Pinus elliottii* com 41 anos de idade. Foram comparados algoritmos clássicos focados no dossel superior, como o filtro de máximos locais e o crescimento de região na nuvem de pontos, com uma abordagem metodológica fundamentada no seccionamento transversal da nuvem de pontos e agrupamento por meio do algoritmo DBSCAN (STAD). A validação ocorreu em 60 unidades amostrais (circulares e retangulares) a partir de contagem manual. Os resultados indicaram a superioridade da detecção pelo seccionamento transversal, onde a melhor parametrização (STAD de 3,0 m e raio de vizinhança de 1,5 m) obteve o menor RMSE (Raiz do Erro Quadrático Médio) em parcelas circulares (8,43%) e retangulares (11,11%), e um BIAS da estimativa de 0,43% e 1,11% respectivamente. Conclui-se que a análise direta na porção desobstruída dos fustes reduz erros de omissão e comissão oriundos de copas irregulares, além de se mostrar robusta contra o efeito de borda, superando os métodos limitados à estrutura do dossel.

Palavras-chave: CENSO; DBSCAN; *Pinus elliotti*.

2.1 INTRODUÇÃO

O inventário florestal fundamenta-se na teoria de amostragem para determinar ou estimar características quantitativas e qualitativas da floresta (Scolforo, 2025). A quantificação do número de árvores por hectare constitui uma métrica de considerável importância neste âmbito, a qual, tradicionalmente, é realizada por meio da contagem de indivíduos nas unidades amostrais, acompanhada das medições de diâmetro e altura, com posterior inferência estatística para o restante da população (Scolforo, 2025).

No entanto, a alta variabilidade espacial dos talhões e a necessidade de estimativas de estoque cada vez mais acuradas têm impulsionado a busca por tecnologias que permitam a transição do modelo amostral para o censo florestal completo. Nesse cenário, a tecnologia LiDAR (*Light Detection and Ranging*) consolidou-se como uma ferramenta de sensoriamento remoto mais promissora para a extração de atributos em inventários florestais (White *et al.*, 2016; Xu *et al.*, 2021; Corte *et al.*, 2022).

Os sensores LiDAR emitem pulsos de laser que, com base nos retornos, estabelecem a distância entre o sensor e a superfície, registrando o dossel da floresta e toda a sua estrutura vertical, incluindo o sub-bosque, em uma nuvem de pontos tridimensional (3D) (Bigdeli *et al.*, 2018). Quando o sensor é embarcado em Veículos Aéreos Não Tripulados (UAVs), a obtenção de densidades acima de 50 pontos.m⁻² viabiliza a Detecção de Árvores Individuais (ITD) e a estimativa de suas alturas com elevada precisão (Wallace *et al.*, 2014; Yu *et al.*, 2021).

As metodologias de detecção de árvores podem ser classificadas, essencialmente, em algoritmos que operam diretamente na nuvem de pontos ou em modelos digitais (*rasters*), como o Modelo Digital de Superfície Normalizado (MDSN) (Hui *et al.*, 2022).

Entre as abordagens baseadas no MDSN, destaca-se o uso do Filtro de Máximos Locais (LMF), método de simples aplicação, mas com perda efetiva em florestas com copas muito próximas (Mohan *et al.*, 2021). Já métodos que operam na nuvem de pontos focados nas copas, como o proposto por Li *et al.* (2012), embora apresentem melhorias substanciais ao isolar as copas geometricamente em 3D, demandam elevado custo computacional e calibração complexa de parâmetros espaciais.

Em contrapartida, a disponibilidade de nuvens de alta densidade (acima de 1.400 pontos.m⁻²) permite a aplicação de algoritmos originalmente desenvolvidos para o escaneamento a laser terrestre (TLS – *Terrestrial Laser Scanning*) em dados aéreos, com maior densidade de pontos na base do fuste, viabilizando a extração do Diâmetro à Altura do Peito (DAP) de cada árvore individual por meio de métodos como RANSAC (*Random Sample*

Consensus) e Transformada de *Hough* (Olofsson *et al.*, 2014; Couto *et al.*, 2017; Corte *et al.*, 2020).

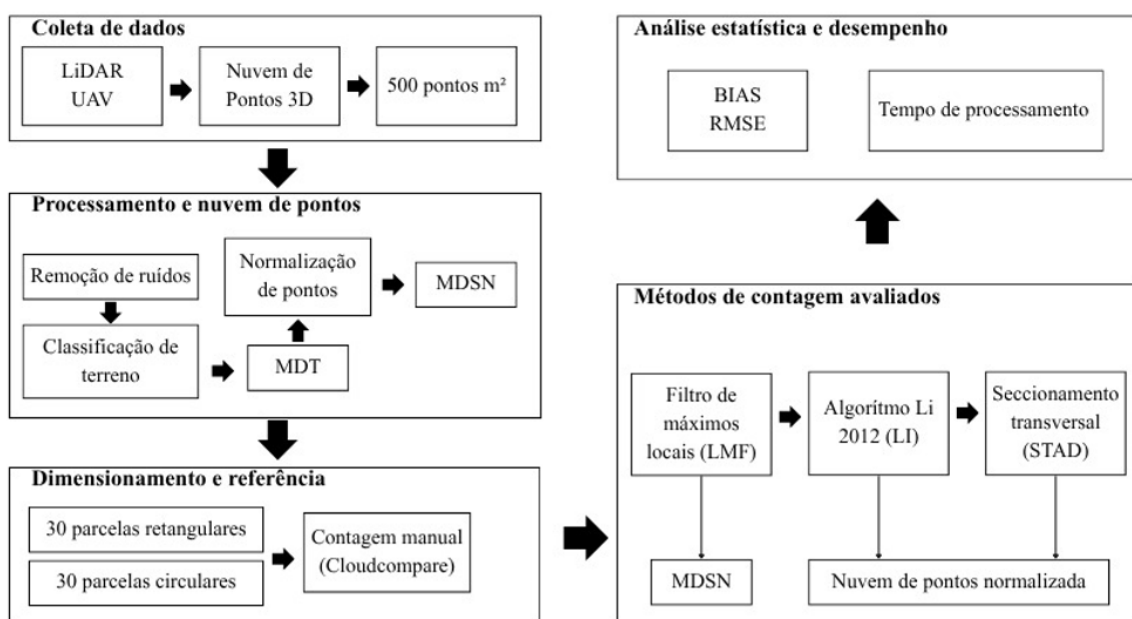
Seguindo essa premissa, diversos estudos têm segmentado as árvores diretamente pelo fuste utilizando algoritmos de agrupamento como o *k-means* (Puliti *et al.*, 2020; Ibrahim *et al.*, 2025), o DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) (Wang *et al.*, 2020; Hyyppä *et al.*, 2020; Gollob *et al.*, 2020) e o HDBSCAN (*Hierarchical Density-Based Spatial Clustering of Applications with Noise*) (Neuville *et al.*, 2021).

Neste contexto, este capítulo tem como objetivo avaliar o desempenho de diferentes metodologias de ITD aplicadas a uma nuvem de pontos LiDAR UAV em um povoamento de *Pinus elliottii*. Especificamente, o estudo compara a acurácia de algoritmos consagrados na literatura, baseados em MDSN e nuvem 3D, com uma abordagem metodológica fundamentada no seccionamento transversal da nuvem de pontos e agrupamento por meio do algoritmo DBSCAN, visando maximizar a assertividade na contagem de árvores individuais.

2.2 MATERIAL E MÉTODOS

O desenvolvimento deste estudo foi estruturado em cinco etapas operacionais sequenciais: aquisição dos dados remotos, pré-processamento da nuvem de pontos, definição das unidades amostrais e referência de campo, aplicação dos algoritmos de detecção de árvores individuais (ITD) e, por fim, a avaliação de desempenho dos métodos (Figura 1).


Figura 1 – Fluxograma das etapas da metodologia descrita.



2.2.1 Área de estudo

O estudo foi conduzido em um talhão de *Pinus elliottii* (Figura 2), com área de 55 hectares e idade aproximada de 41 anos, localizado na Floresta Nacional (FLONA) de Capão Bonito, localizada no município de Capão Bonito – SP.

Figura 2 – Localização de pontos amostrais lançados na área de estudo, localizada na Floresta Nacional de Capão Bonito, Capão Bonito, São Paulo.



Fonte: Elaborado pelo autor

2.2.2 Coleta de dados e processamento da nuvem de pontos

O levantamento dos dados foi realizado utilizando um Veículo Aéreo Não Tripulado (UAV) multirrotor modelo DJI Matrice 350 RTK. A utilização do sistema RTK (*Real-Time Kinematic*) embarcado garantiu o georreferenciamento com precisão centimétrica das rotas de voo.

O UAV foi equipado com o sensor Zenmuse L2, o qual integra um sensor LiDAR e uma câmera RGB, operando com uma taxa de emissão de 240.000 pulsos por segundo (240 kHz) e capacidade de registrar até cinco retornos por pulso emitido. O sensor possui alcance de até 250 metros com 10% de refletividade, com precisão de 5 cm na horizontal e 4 cm na vertical a 150 metros de distância (DJI, 2023).

Os voos foram executados a uma altura de 100 metros acima do nível do solo, operando com uma velocidade de deslocamento de 8 m s^{-1} e sobreposição lateral entre as faixas de voo de 60%. Essa parametrização de voo resultou em uma nuvem de pontos 3D com densidade média de 500 pontos m^{-2} .

O processamento da nuvem de pontos da área de estudo foi realizado em linguagem de programação R (R Core Team, 2024), com uso do pacote *lidR* (Roussel et al., 2020), o qual fornece funções para manipulação de dados LiDAR. O fluxo de processamento abrangeu as etapas de filtragem de ruídos, classificação dos pontos (terreno e vegetação), normalização das alturas e geração dos Modelos Digitais de Terreno (MDT) e MDSN.

A eliminação de ruídos da nuvem de pontos foi executada com a função *classify_noise* aplicando o algoritmo *Statistical Outlier Removal* (SOR). O filtro atua removendo pontos discrepantes com base na distância média de cada retorno em relação aos seus k vizinhos mais próximos, excluindo aqueles que ultrapassam um limiar estipulado pelo desvio padrão da vizinhança, conforme descrito por Rusu et al. (2008).

Em seguida, a identificação dos pontos correspondentes ao solo foi realizada com a função *classify_ground*, aplicando o algoritmo *Cloth Simulation Filter* (CSF). Este método atua invertendo matematicamente a nuvem de pontos 3D, a partir da simulação da queda de um tecido virtual cobrindo a superfície, classificando como terreno os retornos que interceptam essa malha simulada, conforme descrito por Zhang et al. (2016). Os demais pontos que permaneceram acima desse modelo de solo foram classificados como vegetação.

A função *rasterize_terrain* foi utilizada para o processamento do MDT com resolução de 0,5 m, utilizando a interpolação espacial com Ponderação pelo Inverso da Distância (*Inverse Distance Weighting* - IDW), com a seleção de pontos baseada no algoritmo dos vizinhos mais próximos (*k-Nearest Neighbors* - KNN) (Bater et al., 2009).

A normalização da nuvem de pontos foi realizada com a função *normalize_height*, que subtrai a cota do MDT da elevação absoluta de cada ponto, equalizando o nível do solo para $Z = 0$. Por fim, o MDSN foi gerado com resolução de 0,5m a partir da função *rasterize_canopy* empregando o algoritmo *pit-free*. Este método atua modelando uma superfície contínua das copas ao preencher falsas depressões triangulando pontos de primeiros retornos em diferentes níveis de altura, conforme descrito por Khosravipour et al. (2014).

2.2.3 Dimensionamento dos pontos amostrais

Para a definição das parcelas e posterior recorte na nuvem de pontos e MDSN, foram lançados aleatoriamente 30 pontos amostrais na área de estudo (Figura 2), e, para avaliar o

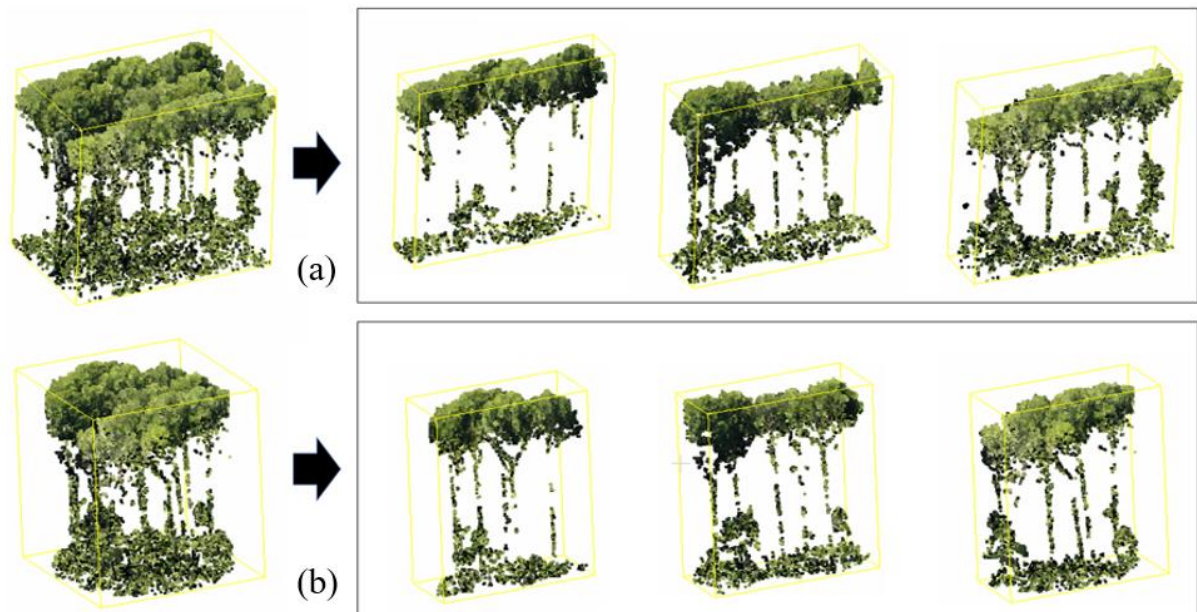
desempenho dos métodos de ITD, em cada ponto amostral, foram estabelecidas parcelas circulares com raio de 12,62 m (500 m²) e parcelas retangulares com dimensão de 20 x 30 m (600 m²), totalizando 60 parcelas, sendo 30 de cada formato com mesmo ponto central.

A escolha por avaliar algoritmos de contagem em dois formatos de parcela se justifica pelos potenciais vieses que cada formato apresenta. No inventário tradicional, parcelas circulares são de fácil instalação e possuem baixa vulnerabilidade a erros de área em comparação às parcelas retangulares, as quais podem sofrer com a tendência de inclusão indevida de árvores de grande porte pelas equipes de campo ao deslocar os limites da parcela (Paul *et al.*, 2019). Essa influência geométrica também se reflete no sensoriamento remoto, como constatado por Packalen *et al.* (2023), em um estudo avaliativo utilizando dados LiDAR aerotransportado, observaram o RMSE superior nas parcelas de formato quadrado em relação às circulares, devidamente atribuído à maior proporção de árvores de borda em formatos com cantos retos.

2.2.4 Contagem de indivíduos nas unidades amostrais

A validação dos algoritmos baseou-se na contagem manual das árvores a partir da visualização da estrutura 3D da nuvem de pontos normalizada, em cada amostra, no *software CloudCompare* (Cloudcompare, 2024). Para otimizar a visualização de fustes, o procedimento foi executado isolando cada linha de plantio de forma sucessiva, nas parcelas circulares (Figura 3a) e retangulares (Figura 4a). Em cada linha, os fustes foram contabilizados, e o somatório total estabeleceu o número real de árvores por parcela.

Figura 3 – Recorte e ilustração da contagem das parcelas retangulares (a) e circulares (b).



Fonte: Elaborado pelo autor.

A Tabela 1 sintetiza a caracterização estrutural e a estatística descritiva do povoamento para ambos os formatos de parcela, como premissa inicial para definição dos parâmetros dos algoritmos a partir do raio e diâmetro de copa médio.

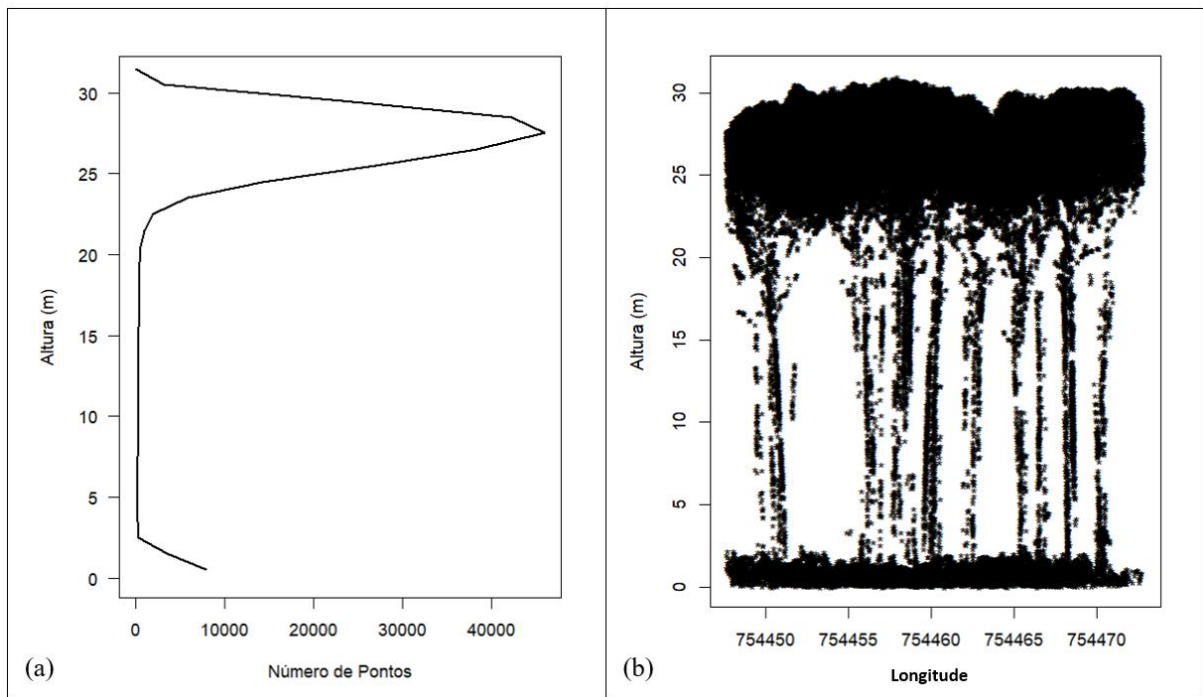
Tabela 1 – Estatística descritiva da contagem manual de indivíduos de *Pinus elliottii* e parâmetros estruturais para os diferentes formatos de unidades amostrais.

Formato da parcela	Circular	Retangular
Nº de parcelas	30	30
Área da parcela (m ²)	500	600
Nº de árvores total	487	610
Média (árvore parcela ⁻¹)	16,2	20,3
Média (árvore ha ⁻¹)	324	338
Desvio padrão	2,10	2,54
Coefficiente de variação (%)	12,91	12,48
Densidade (m ² árvore ⁻¹)	30,9	29,6
Raio de copa média (m ²)	3,1	3,1
Diâmetro de copa médio (m ²)	6,2	6,2

Apesar da diferença de tamanho e formato, ambas as geometrias refletiram uma densidade populacional consistente para o talhão, estimada em aproximadamente 324 a 338 árvores por hectare.

A distribuição de pontos em relação a altura (Figura 4a), destaca a maior concentração de retornos LiDAR entre 23 e 30 metros, evidenciando copas achatadas e arredondadas, característica que compromete o desempenho de algoritmos baseados no formato de copa, os quais são voltados para identificação de árvores pelo formato cônico da copa (DALPONTE et al., 2016; MOHAN et al., 2021).

Figura 4 – (a) Perfil de distribuição vertical do número de pontos LiDAR em relação à altura. (b) Disposição lateral dos pontos nos eixos X e Z.



Fonte: Elaborado pelo autor.

Por outro lado, a visualização da nuvem de pontos lateralmente (Figura 4b) revela uma zona de baixa densidade de retornos na porção intermediária dos fustes, compreendida entre 5 e 20 metros de altura. É exatamente essa desobstrução estrutural que fundamenta a aplicação da metodologias de agrupamento pelo fuste, viabilizando a segmentação (WANG et al., 2020).

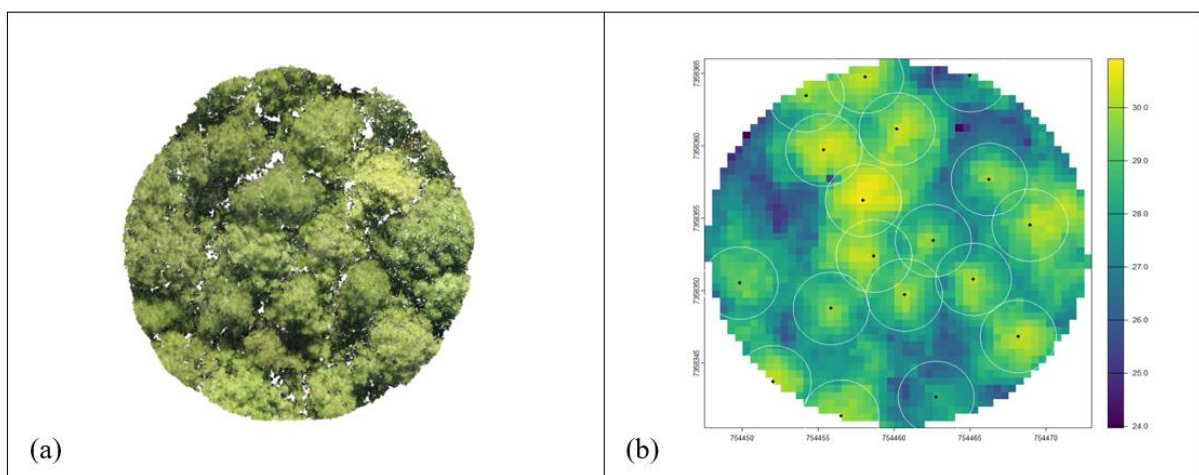
2.2.5 Métodos de contagem avaliados

Foram avaliados três diferentes métodos computacionais: o Filtro de Máximos Locais (LMF), o Algoritmo Li 2012 (LI) e o Seccionamento Transversal do Fuste e Agrupamento com Algoritmo DBSCAN (STAD). O LMF atua sobre o MDSN, enquanto os métodos LI e STAD operam diretamente na nuvem de pontos LiDAR.

2.2.5.1 Filtro de máximos locais (LMF)

Aplicado sobre o MDSN por meio da função *locate_trees* parametrizada com o algoritmo *lmf* (Popescu *et al.*, 2004) do pacote *lidR*, o método identifica o pixel de maior valor altimétrico dentro de uma janela de busca móvel (argumento *ws*) (Figura 5), assumindo-o como o ápice de uma árvore. A principal limitação deste método é a sua sensibilidade ao tamanho da janela: dimensões muito pequenas tendem a gerar erros de comissão (falsos positivos em galhos laterais), enquanto janelas muito amplas causam erros de omissão (exclusão de árvores dominadas). Para avaliar a influência da variação do tamanho das copas e mitigar esses erros, o algoritmo foi testado atribuindo ao parâmetro *ws* dimensões circulares com diâmetros de 4,5, 5,0 e 6,0 metros. Esses valores foram balizados pelo diâmetro de copa médio estimado no inventário manual do talhão (6,2 m), buscando encontrar a parametrização que melhor represente a dimensão real das copas de *Pinus elliottii* em cada parcela.

Figura 5 – Visualização superior da parcela florestal. (a) Projeção ortogonal da nuvem de pontos bruta. (b) MDSN com a aplicação do algoritmo de LMF em janela móvel de 5 metros, evidenciando os ápices detectados (pontos pretos) e a área de busca (círculos brancos).




Fonte: Elaborado pelo autor.

2.2.5.2 Algoritmo Li 2012 (LI)

O algoritmo descrito por Li et al. (2012) (LI), executado através da função *segment_trees* parametrizada com o método *li2012* do pacote *lidR*, atua como um algoritmo de crescimento de região diretamente na nuvem de pontos 3D. O algoritmo identifica o ponto mais alto da nuvem como a primeiro ponto da copa e, iterativamente, incorpora os pontos vizinhos baseando-se em limiares de distância horizontal, isolando as árvores individualmente ao avançar do topo para a base do dossel. Assim, em contraste com o método LMF, que se restringe à identificação de picos altimétricos, o algoritmo LI promove a segmentação integral das copas e fustes. Embora a modelagem volumétrica das copas não seja o escopo desta análise, tal individualização otimiza a contagem das árvores (Figura 6).

A análise de sensibilidade do método consistiu no pareamento do raio de busca inicial máximo (R) com o limiar de distância da base da copa ($dt2$), estruturados em três cenários derivados do raio médio de copa observado. O primeiro cenário atribuiu R de 3,00 m e $dt2$ de 2,50 m; o segundo avaliou R de 2,75 m e $dt2$ de 2,25 m; e o terceiro restringiu R a 2,50 m e $dt2$ a 2,00 m. Os demais parâmetros estruturais requeridos pela função como o limiar de distância horizontal superior ($dt1$), a cota de separação altimétrica (Zu) e a altura mínima de classificação ($hmin$) foram mantidos em seus valores padrão (*default*) estabelecidos pelo pacote *lidR*.

Figura 6 – Visualização da segmentação de árvores individuais na nuvem de pontos através do algoritmo de Li2012 em uma parcela circular: vista superior (a), vista lateral (b) e vista das copas (c).



Fonte: Elaborado pelo autor.

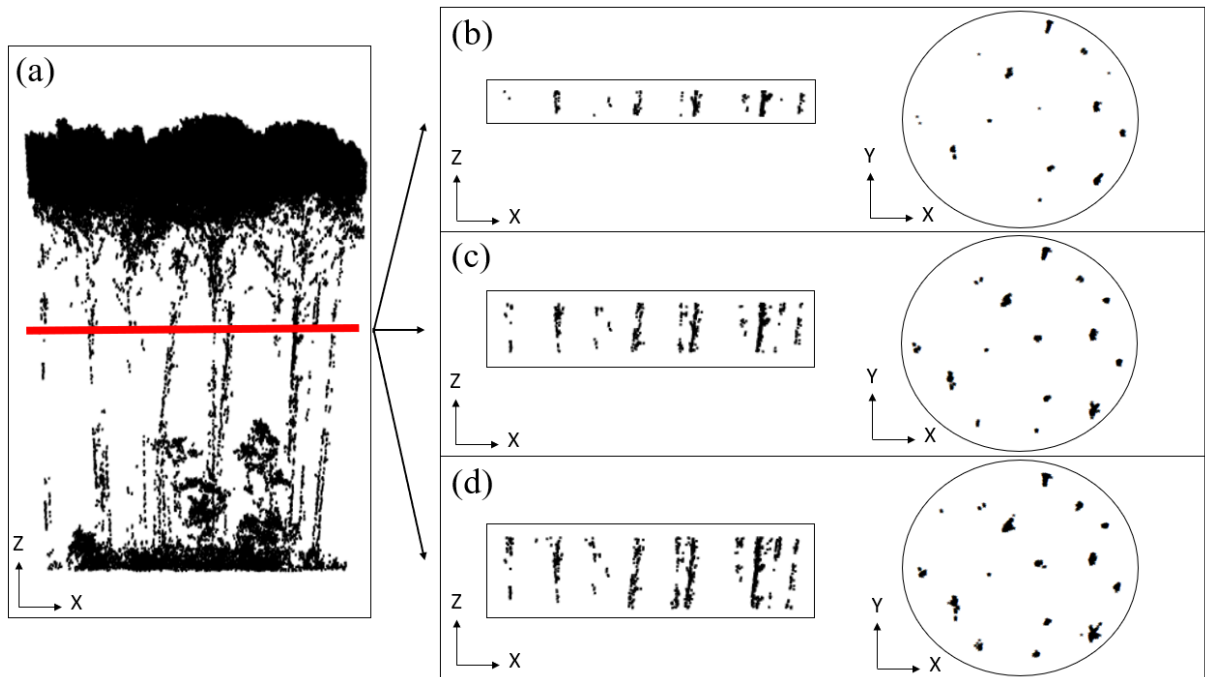
2.2.5.3 Seccionamento Transversal do Fuste e Agrupamento com Algoritmo DBSCAN (STAD)

Para a contagem e localização dos indivíduos a partir das nuvens de pontos LiDAR, foi aplicada uma metodologia baseada no seccionamento transversal da nuvem de pontos adaptada de Gollob (2020). A abordagem fundamenta-se na premissa da existência de uma zona de menor densidade de pontos ao longo do perfil vertical do povoamento, caracterizado pela região dos fustes sem a interferência excessiva do dossel e do sub-bosque. O processamento foi executado em linguagem de programação R, utilizando os pacotes *lidR* para a manipulação da nuvem de pontos (Roussel *et al.*, 2020) e *dbscan* para o agrupamento espacial bidimensional desenvolvido por Hahsler *et al.* (2019).

O algoritmo DBSCAN, proposto originalmente por Ester *et al.* (1996), opera através de uma lógica de densidade, identificando agrupamentos com base na proximidade espacial dos pontos. O funcionamento baseia-se em dois parâmetros fundamentais: o *epsilon* (*eps*), que define o raio de busca em torno de cada ponto, e o *minPts*, que estabelece o número mínimo de vizinhos necessários dentro desse raio para que um ponto seja considerado parte de um grupo.

A definição da altura de cada secção baseou-se na identificação automática do estrato vertical com a menor densidade de pontos, característica de fustes desobstruídos. Para isso, a distribuição vertical (eixo Z) da nuvem foi discretizada em um histograma com classes de 1 metro de altura. A busca pela camada ideal foi delimitada entre a metade da altura total do dossel e o topo da floresta, estratégia adotada para isolar o fuste e reduzir interferências de pontos do sub-bosque. Por fim, o valor central da classe que apresentou a menor frequência de retornos dentro deste intervalo foi selecionado como o nível de referência para os recortes subsequentes (Figura 7a).

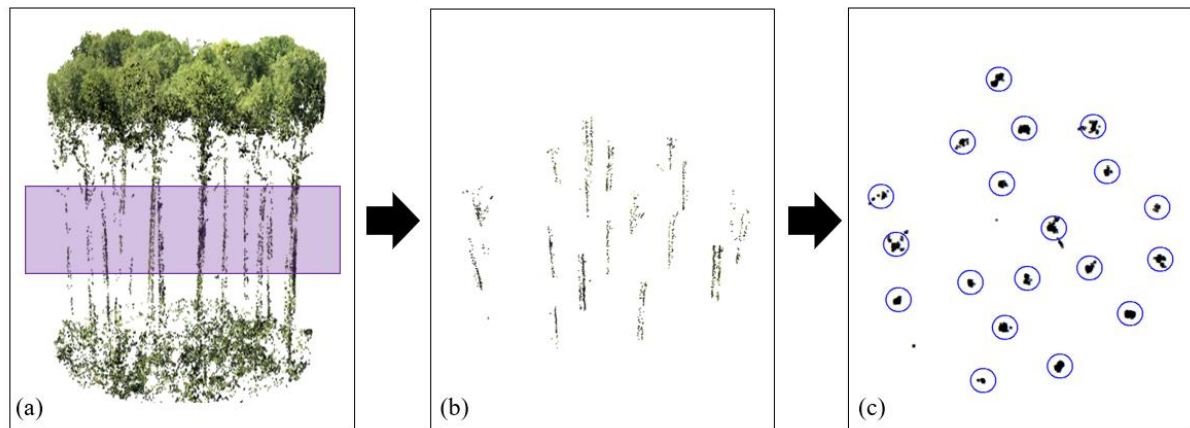
Figura 7 – Ilustração das etapas do método de STAD em 2D. (a) Perfil vertical da parcela com a demarcação do valor central da classe com menor número de pontos. (b), (c) e (d) demonstram as três configurações de recorte testadas: seccionamentos transversais com espessuras de 2 m (b), 4 m (c) e 6 m (d), exibindo o perfil vertical (X,Z) e a respectiva projeção no plano (X,Y).



Fonte: Elaborado pelo autor.

A partir da altura central da classe central de menor número de pontos, a nuvem de pontos foi recortada e processada em três configurações distintas para avaliar a sensibilidade do método (Figura 7b), pareando a espessura da fatia vertical com o raio de vizinhança espacial do algoritmo DBSCAN. Na primeira configuração, utilizou-se um intervalo de 1 metro em relação ao valor central da classe com menor número de pontos para a espessura (Z), associado a um *eps* de 0,5 m; na segunda, o intervalo foi expandido para 2 metros com *eps* de 1,0 m; e, na terceira, adotou-se 3 metros de espessura vertical com *eps* de 1,5 m. Em todas as execuções, o número mínimo de pontos (*minPts*) foi fixado em 5. A partir de cada recorte, a nuvem foi projetada bidimensionalmente (x,y), o algoritmo DBSCAN foi aplicado e cada agrupamento foi considerado uma seção do fuste (Figuras 7c e 8).

Figura 8 – Ilustração das etapas do método de STAD diretamente na nuvem de pontos para o agrupamento em 2D. (a) Vista lateral da nuvem de pontos destacando a faixa de seccionamento no fuste de 6m. (b) Recorte da secção. (c) Projeção bidimensional e identificação dos indivíduos com o algoritmo DBSCAN com eps de 1,5.



Fonte: Elaborado pelo autor.

2.2.5.4 Síntese dos cenários avaliados

A Tabela 2 sintetiza todas as configurações parametrizadas para os três algoritmos de detecção de árvores individuais (LMF, LI e STAD) testados neste estudo.

Tabela 2 - Síntese das parametrizações avaliadas para os algoritmos de detecção de árvores individuais (LMF, LI e STAD).

Método	Configuração	Parâmetros avaliados	Parâmetros fixos
LMF	LMF (4.5)	$ws = 4,5$ m	-
	LMF (5.0)	$ws = 5,0$ m	
	LMF (6.0)	$ws = 6,0$ m	
LI	LI (3.00)	$R = 3,00$ m; $dt2 = 2,50$ m	$dt1 =$ Padrão $Zu =$ Padrão
	LI (2.75)	$R = 2,75$ m; $dt2 = 2,25$ m	
	LI (2.50)	$R = 2,50$ m; $dt2 = 2,00$ m	
STAD	STAD (2m)	Espessura = 2 m; $eps = 0,5$ m	$minPts = 5$
	STAD (4m)	Espessura = 4 m; $eps = 1,0$ m	
	STAD (6m)	Espessura = 6 m; $eps = 1,5$ m	

2.2.6 Análise estatística e eficiência computacional

Para quantificar a acurácia de cada método ITD em relação à contagem manual, as contagens estimadas foram comparadas com as contagens observadas por meio do Raiz do Erro Quadrático Médio (*Root Mean Square Error* - RMSE) e Viés (*Bias* - BIAS), calculados pelas respectivas equações:

$$BIAS = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (1)$$

$$BIAS (\%) = \left(\frac{BIAS}{\bar{y}} \right) \times 100 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$RMSE (\%) = \left(\frac{RMSE}{\bar{y}} \right) \times 100 \quad (4)$$

Em que:

\hat{y}_i é o número de árvores estimado pelo algoritmo na parcela i ;

y_i é o número de árvores contado manualmente na parcela i ;

\bar{y} é o número médio de árvores observadas; e n é o número total de parcelas.

A eficiência computacional foi calculada pelo tempo médio de processamento por parcela para cada método de ITD (Equação 5). A extração dos tempos foi realizada de forma automatizada no R utilizando a função *Sys.time()* desde o carregamento da nuvem de pontos até a contagem final. Todos os processamentos foram executados em um computador equipado com processador Intel Core i5 9ª geração, 24 GB de memória RAM e sistema operacional Windows 11.

$$\bar{T}_p = \frac{T_f - T_i}{n} \quad (5)$$

Em que:

\bar{T}_p é o tempo médio de processamento por parcela (em segundos);

T_f corresponde ao tempo registrado no término do processamento do conjunto de parcelas;

T_i é o tempo inicial registrado antes da execução do algoritmo;

n o número de parcelas avaliadas.

2.3 RESULTADOS E DISCUSSÃO

Os resultados de contagem para cada algoritmo, sob suas respectivas parametrizações espaciais, estão sintetizados na Tabela 3. Observou-se que o BIAS da estimativa apresentou uma expressiva amplitude, variando de -5,53 a 2,50 nas parcelas retangulares e de -3,70 a 2,07 nas parcelas circulares. Os maiores valores RMSE e os BIAS concentraram-se nas configurações extremas dos algoritmos, especificamente em STAD (2.0), LMF (6.0) e LI (2.5).

Tabela 3 – Número total de árvores detectadas, Média, RMSE e BIAS da contagem de indivíduos estimada pelos diferentes algoritmos e parametrizações, em parcelas circulares e retangulares.

Parcela	Método	Total	Média	BIAS	BIAS (%)	RMSE	RMSE (%)
Circular	Observado	487	16,2	-	-	-	-
	STAD (6.0)	488	16,3	0,07	0,41	1,37	8,43
	STAD (4.0)	456	15,2	-1,00	-6,17	1,95	12,03
	LI (3.0)	459	15,3	-0,90	-5,56	2,54	15,66
	LMF (5.0)	462	15,4	-0,80	-4,94	2,65	16,33
	LI (2.75)	511	17,0	0,83	5,14	2,73	16,83
	LMF (4.5)	518	17,3	1,07	6,58	2,85	17,6
	LI (2.5)	548	18,3	2,07	12,76	3,26	20,10
	STAD (2.0)	375	12,5	-3,70	-22,84	4,15	25,63
	LMF (6.0)	388	12,9	-3,27	-20,16	4,33	26,72
Retangular	Observado	610	20,3	-	-	-	-
	STAD (6.0)	601	20,0	-0,30	-1,48	2,26	11,11
	STAD (4.0)	546	18,2	-2,13	-10,49	2,89	14,20
	LMF (4.5)	641	21,4	1,03	5,08	3,11	15,32
	LI (2.75)	634	21,1	0,80	3,93	3,24	15,91
	LMF (5.0)	570	19,0	-1,33	-6,56	3,35	16,46
	LI (3.0)	568	18,9	-1,4	-6,89	3,4	16,70
	LI (2.5)	685	22,8	2,50	12,30	4,11	20,22
	LMF (6.0)	488	16,3	-4,07	-20,00	4,89	24,06
	STAD (2.0)	444	14,8	-5,53	-27,21	5,92	29,10

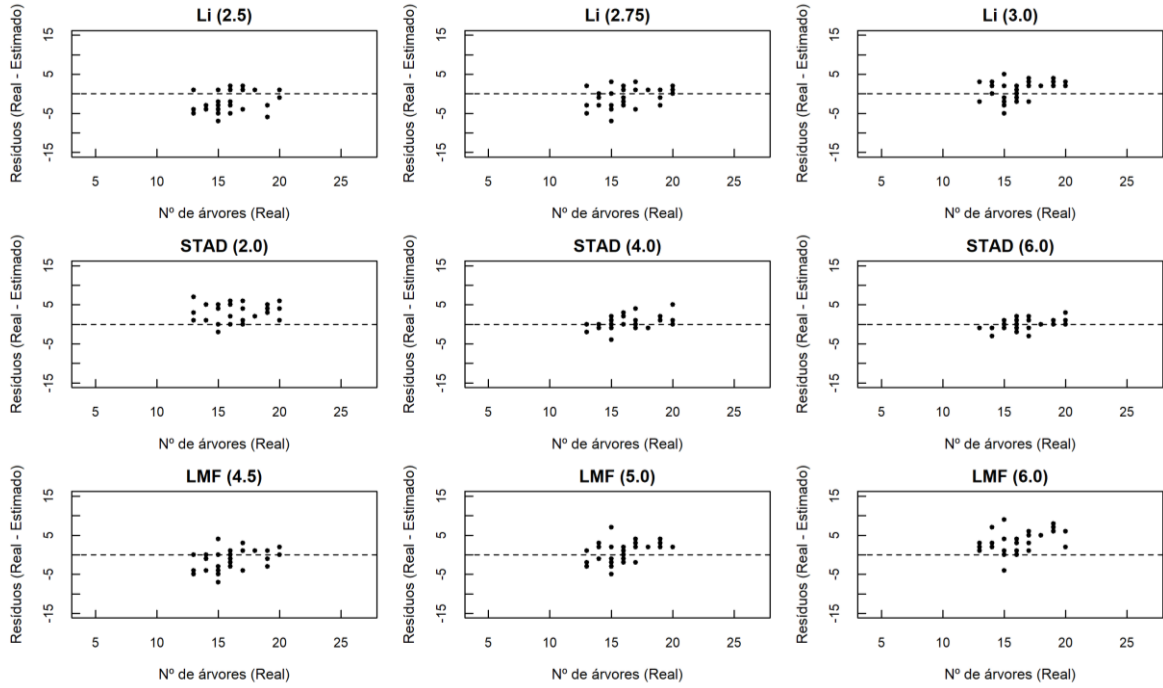
O método de STAD (6,0) com espessura de 6 metros e *eps* de 1,5 m, obteve os melhores resultados nas duas geometrias de parcelas, tanto nas circulares (RMSE de 8,43% e BIAS de 0,41%), quanto nas retangulares (RMSE de 11,11% e BIAS de -1,48%).

A análise evidenciou que configurações de seccionamento muito estreitas comprometem a detecção. O uso do STAD (2.0), que avalia uma faixa do fuste de apenas 1 metro de espessura, resultou na detecção de um número significativamente menor de indivíduos, com subestimativas (BIAS) de -22,84% e -27,21% para parcelas circulares e retangulares, respectivamente. Isso indica que, para a densidade média da nuvem de pontos avaliada (500 pontos m⁻²), uma secção de baixa espessura não fornece retornos suficientes para satisfazer o parâmetro de adensamento mínimo (*minPts* = 5) definidos com o algoritmo DBSCAN, culminando em erros de omissão.

Em relação aos métodos baseados na estrutura do dossel, o melhor desempenho nas parcelas circulares foi obtido pelo algoritmo LI (3.0), com RMSE de 15,66%, seguido proximamente pelo LMF (5.0), com 16,33%. A dificuldade desses métodos em isolar as copas corrobora a literatura científica, que aponta uma expressiva perda de precisão em plantios florestais mais antigos. Conforme destacado por Aubry-Kientz et al. (2019) e Mohan et al. (2021), à medida que os povoamentos atingem a maturidade, as copas perdem a dominância apical, desenvolvendo arquiteturas mais achatadas e ramificações laterais irregulares. Essa complexidade morfológica cria múltiplos picos altimétricos para um mesmo indivíduo, tornando o uso de janelas móveis altamente ineficiente e limitando severamente a aplicação de algoritmos como o LMF em dosséis fechados.

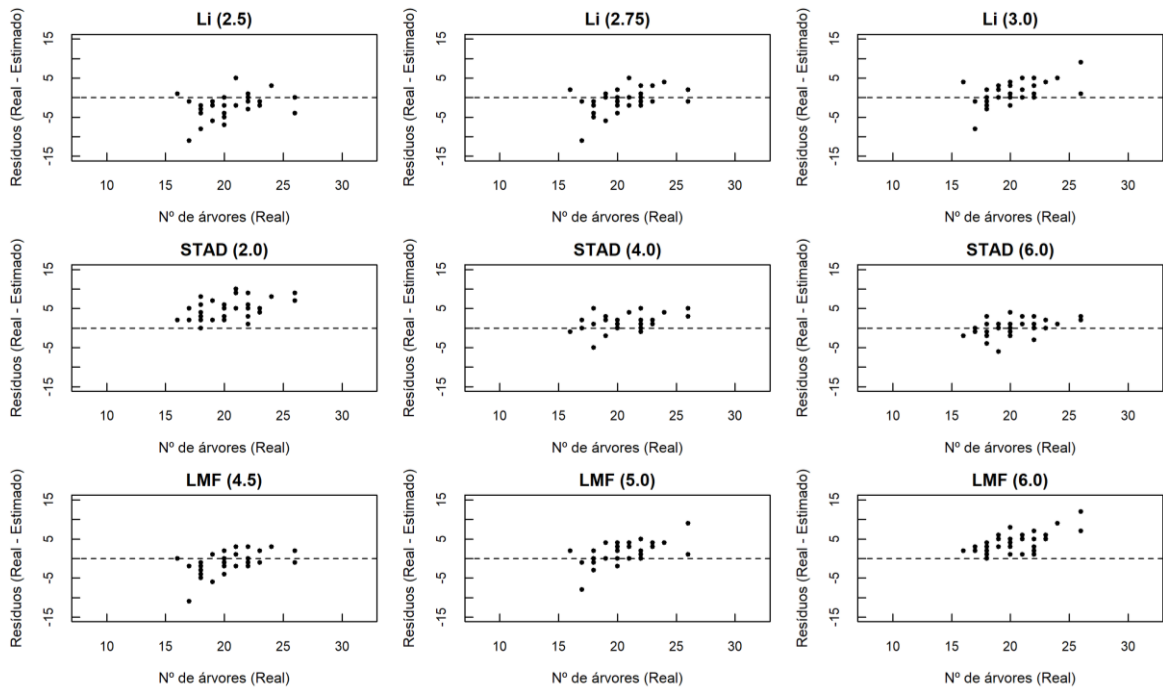
A análise da distribuição dos resíduos (Figuras 9 e 10) elucida a forte sensibilidade da parametrização espacial nos métodos LMF e LI. Ao utilizar janelas móveis ou raios de busca menores, como no LMF (4.5) e LI (2.5), observou-se um viés positivo característico de erros de superestimativa. Nesses cenários, o algoritmo fragmenta copas largas e identifica incorretamente ramificações laterais vigorosas como sendo novos ápices. Inversamente, a ampliação exagerada desses parâmetros, evidenciada no LMF (6.0), gera subestimativas drásticas (viés negativo em torno de -20%), pois a área de busca passa a englobar árvores vizinhas dominadas, fundindo-as em um único indivíduo detectado.

Figura 9 – Distribuição de resíduos nas parcelas circulares.



Fonte: Elaborado pelo autor.

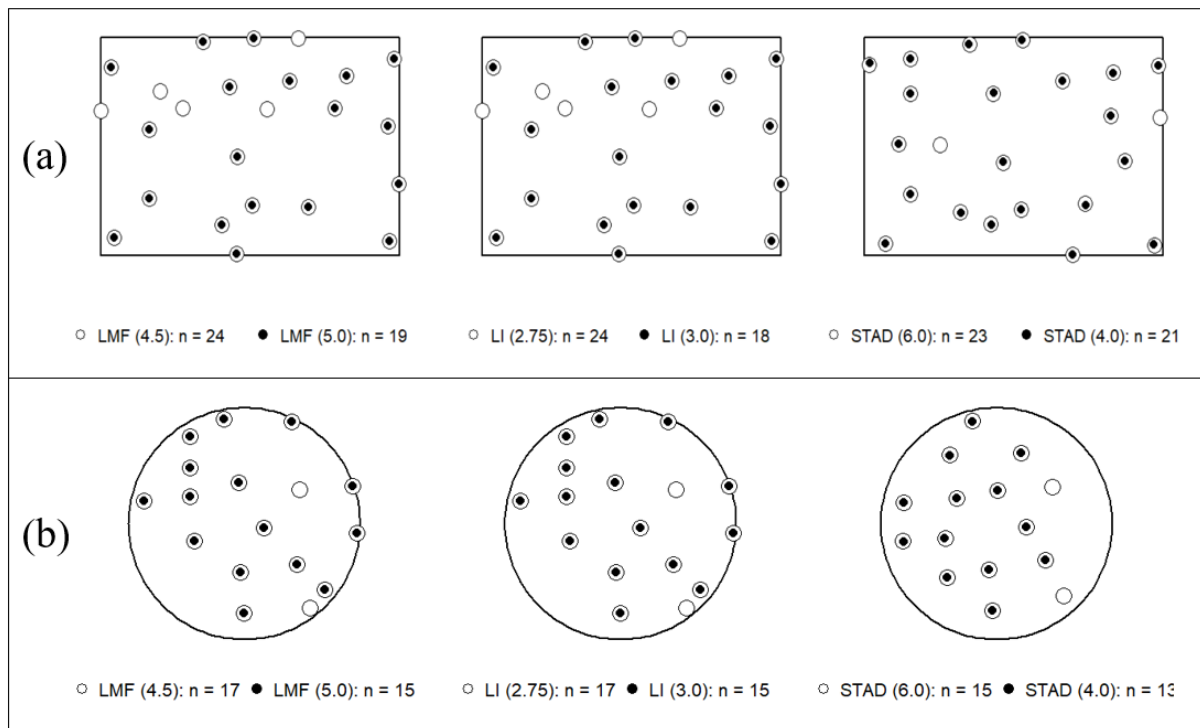
Figura 10 – Distribuição de resíduos nas parcelas retangulares.



Fonte: Elaborado pelo autor.

A visualização espacial da detecção, apresentada na Figura 11, evidencia de forma clara as divergências estatísticas e o comportamento preditivo detalhado anteriormente. Fica evidente a alta suscetibilidade dos algoritmos baseados na estrutura do dossel (LMF e LI) à calibração de seus parâmetros espaciais, bem como a superioridade posicional do método STAD.

Figura 11 – Detecção de fustes nos metodos avaliados. (a) Parcela retangular com contagem real de 23 fustes. (b) Parcela circular com contagem real de 15 fustes.



Fonte: Elaborado pelo autor

Na parcela retangular (Figura 11a), cuja contagem real aferida em campo foi de 23 fustes, as parametrizações com raios de busca e janelas menores (LMF 4.5 e LI 2.75) incorreram em superestimativas, detectando 24 indivíduos. Visualmente, nota-se que essas detecções excedentes (representadas pelos pontos em branco) ocorrem frequentemente próximas a outras árvores ou nas bordas, caracterizando erros de comissão onde galhos laterais de copas largas e irregulares são identificados como novos ápices. Em contrapartida, ao tentar mitigar esse efeito ampliando as áreas de busca para LMF 5.0 e LI 3.0, a contagem na mesma parcela reduziu para 19 e 18 indivíduos detectados, respectivamente. Essa subestimativa ocorre, em grande parte, porque o algoritmo não consegue separar árvores codominantes ou com copas muito próximas, acabando por registrar um único indivíduo.

O mesmo padrão de instabilidade repete-se na parcela circular (Figura 11b, contagem real de 15 fustes). Embora o LMF 5.0 e o LI 3.0 tenham atingido numericamente a contagem correta ($n = 15$), a disposição planimétrica dos pontos evidencia falhas de posicionamento, sugerindo que o acerto numérico total pode ter sido influenciado por uma compensação entre erros de omissão internos e erros de comissão nas bordas.

O método STAD, por sua vez, demonstrou excepcional estabilidade e aderência à distribuição espacial real do povoamento. A configuração STAD (6.0) atingiu a contagem exata tanto na parcela retangular (23 indivíduos) quanto na circular (15 indivíduos). A distribuição planimétrica das detecções do STAD revela a principal vantagem da técnica que ao segmentar e agrupar os pontos na porção inferior e desobstruída do sub-bosque, a coordenada estimada se aproxima da base do tronco do fuste. Essa abordagem isola a influência da assimetria das copas impedindo que árvores validamente pertencentes à unidade amostral sejam omitidas caso suas copas se projetem para fora dos limites da parcela.

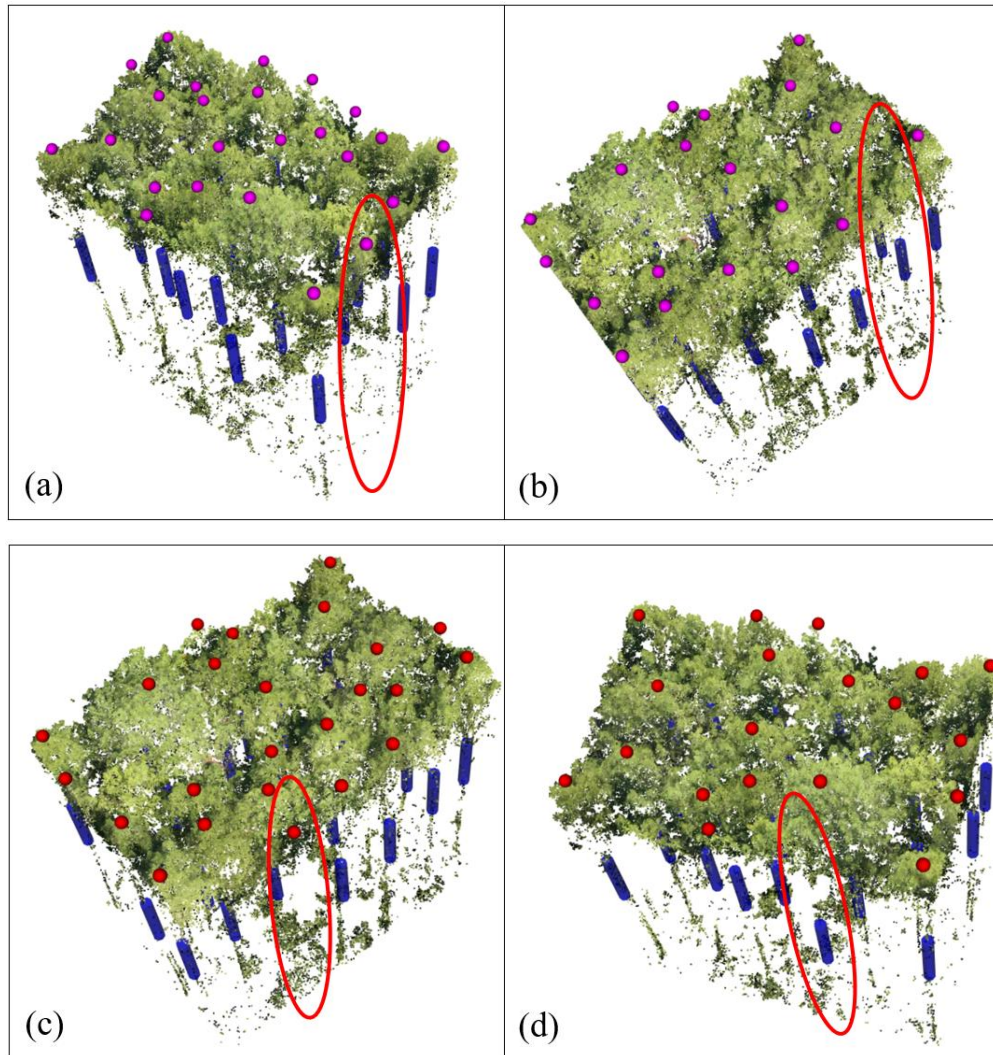
Neste sentido, a variação de desempenho entre os algoritmos é impulsionada pela incidência do efeito de borda nas unidades amostrais. Conforme abordado por Dalponte et al. (2016) e Mascaro et al. (2011), inventários florestais por sensoriamento remoto lidam com incertezas estruturais inerentes às extremidades das parcelas virtuais.

A validação visual tridimensional, apresentada nas Figuras 12 e 13, elucida o comportamento espacial dos algoritmos frente à estrutura do plantio do *Pinus elliottii*. Nessas representações, os cilindros azuis demarcam a localização real dos fustes enraizados dentro dos limites da parcela (detectados com assertividade pelo método STAD), enquanto as esferas (em magenta para LMF e vermelho para LI) indicam os ápices detectados pelos métodos baseados no dossel.

Nas Figuras 12a e 12c, nota-se a ocorrência clássica de erros de comissão, os algoritmos LMF (4.5) e LI (2.75) posicionam esferas de detecção nas extremidades superiores da nuvem de pontos, impulsionados por copas de árvores externas que se projetam para o espaço aéreo da parcela. Como evidenciado pelas elipses vermelhas, não há cilindros azuis (fustes) sob essas copas, resultando em uma contagem falsamente inflada de indivíduos.

Simultaneamente, a pequena diferença nos parâmetros foi responsável por gerar o efeito reverso no LMF (5.0) na Figura 12b e no LI (3.0) na Figura 12d. As elipses vermelhas nestas imagens destacam cilindros azuis validados pelo método STAD que não possuem correspondência de ápices (esferas) no dossel. Isso ocorre porque as copas dessas árvores estão suprimidas, inclinadas ou fundidas morfológicamente com árvores dominantes vizinhas, indetectáveis pelos algoritmos.

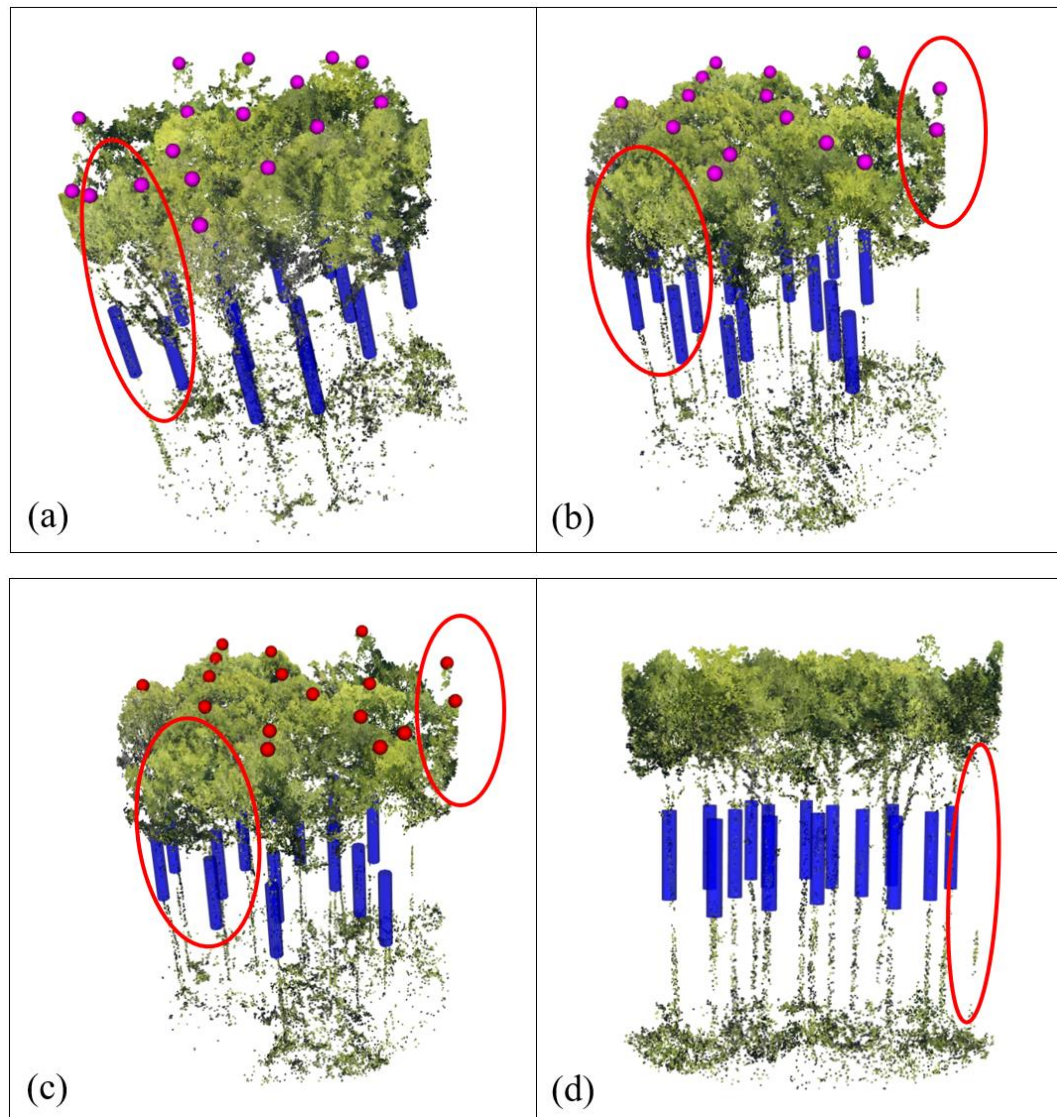
Figura 12 – Ilustração das divergências nos métodos LMF e LI em parcelas retangulares. (a) LMF (4,5) Detecção de copa não inclusa na parcela. (b) Fuste detectado por STAD (6,0), mas ausente em LMF (5,0). (b) Detecção de copa não inclusa na parcela em LI (2,75). (d) Copa não considerada em LI (3,0) foi detectada por STAD (6,0).



Fonte: Elaborado pelo autor.

A Figura 13 aprofunda a análise das falhas de detecção nas parcelas circulares. A Figura 13a ilustra a instabilidade geométrica do LMF quando submetido a janelas restritas (4,5 m). A elipse destaca a alocação de múltiplas esferas sobre o que aparenta ser um único indivíduo ou um agrupamento muito denso, evidenciando a fragmentação da copa.. As Figuras 13b e 13c reiteram o padrão de falha nas bordas, onde o LMF (5.0) e o LI (2.75 / 3.0) contabilizam copas intrusas e, contraditoriamente, omitem fustes reais estabelecidos no interior da amostra.

Figura 13. (a) Dupla detecção de copa em LMF (4,5). (b) Algoritmo LMF (5,0) com inclusão de duas copas ausentes na parcela e ausência de contagem em copa com fuste identificado em STAD (3,0). (c) LI (2,75) e LI (3,0) com o mesmo comportamento de LMF (5,0) na imagem (b). (d) Fuste não contabilizado em STAD (6,0) devido ausência de pontos na espessura da secção.



Fonte: Elaborado pelo autor.

Contudo, a análise visual também impõe o reconhecimento das limitações inerentes ao método STAD, conforme ilustrado na Figura 13d. A elipse vermelha aponta um fuste real que não foi contabilizado pelo STAD. Essa omissão decorre da oclusão do feixe laser ou de sombras geradas pela copa, resultando em uma drástica redução da densidade de pontos LiDAR naquela coordenada específica. Conseqüentemente, o número de retornos presentes na seção de 6 metros

não foi suficiente para atingir o limiar de adensamento ($minPts = 5$) exigido pelo algoritmo DBSCAN, impedindo a formação do agrupamento e detecção deste fuste.

Apesar dessa limitação, a análise tridimensional atesta que a transição da detecção de árvores individuais do dossel para a secção desobstruída do fuste constitui uma alternativa altamente efetiva. Embora o método STAD seja suscetível a oclusões locais que reduzem a densidade da nuvem de pontos, sua robustez contra o efeito de borda e a fragmentação de copas garante o seu desempenho superior. Essa eficácia do agrupamento espacial é diretamente corroborada por Gollob *et al.* (2020) e Tockner *et al.* (2022), que reportaram uma taxa de detecção de 100 e 96%, respectivamente, embora tenham aplicado em TLS, oem que a densidade de pontos no fuste é superior. De modo semelhante, outros autores alcançaram alta assertividade na detecção de fustes ao aplicarem o algoritmo DBSCAN em seções bidimensionais de dados LiDAR aéreos, com taxas de 100% de detecção para *Pinus sp.*, mesmo sob condições de severa oclusão (Hyypä *et al.*, 2020).

Além da acurácia de detecção, a avaliação da eficiência computacional (Tabela 4) revelou contrastes expressivos entre as abordagens avaliadas, constatando a complexidade de cada algoritmo pelo tempo de processamento por parcela.

Tabela 4 – Tempo médio de processamento computacional por unidade amostral (em segundos) para as diferentes parametrizações dos algoritmos de detecção de árvores individuais (LMF, LI e STAD).

Método	Configuração	Parcela Circular (s)	Parcela Retangular (s)
LMF	LMF (4.5)	0,4	0,5
	LMF (5.0)	0,5	0,4
	LMF (6.0)	0,4	0,4
LI	LI (3.00)	120,4	142,6
	LI (2.75)	132,4	164,3
	LI (2.50)	136,5	171,8
STAD	STAD (2m)	0,5	0,7
	STAD (4m)	0,6	0,8
	STAD (6m)	0,6	0,8

O método LMF apresentou menor tempo de processamento, variando de 0,4 a 0,5 segundos por parcela. Essa alta performance justifica-se por sua operação sobre o Modelo Digital de Superfície Normalizado (MDSN), que exige baixo esforço computacional.

Em contrapartida, o algoritmo de Li et al. (2012) demandou um custo computacional muito alto em relação aos demais, alcançando entre 120,4 e 171,8 segundos por parcela, devido ao modelo de crescimento de região diretamente na nuvem de pontos. Embora o LI entregue a modelagem tridimensional de cada indivíduo, sua exigência de processamento é um gargalo restritivo para escalas operacionais restritas na detecção e contagem dos fustes.

Neste cenário, o STAD demonstrou uma relação de tempo e eficiência favorável entre os demais métodos avaliados. Operando na nuvem de pontos, assim como o LI, o método contorna o alto custo computacional ao recortar a seção transversal da nuvem para o agrupamento bidimensional via DBSCAN.

2.4 CONCLUSÃO

A avaliação de algoritmos de ITD em plantio de *Pinus elliottii* evidenciou os desafios e limitações da aplicação de métodos clássicos centrados na estrutura do dossel (LMF e LI).

O Seccionamento Transversal do Fuste associado ao agrupamento DBSCAN (STAD) demonstrou ser superior para a população em estudo.

A configuração de seccionamento com 6,0 metros de espessura (STAD 6.0) revelou-se a parametrização ótima ao direcionar a detecção para a porção vertical desobstruída dos fustes.

A transição da análise da superfície do dossel para a detecção direta na estrutura do fuste das árvores diminui a dependência de parâmetros de copa preestabelecidos. Essa abordagem consolida-se como uma ferramenta computacional robusta, capaz de contornar inclinações do fuste e a presença de falsos ápices.

REFERÊNCIAS

AUBRY-KIENTZ, M.; DUTRIEUX, R.; FERRAZ, A.; SAATCHI, S.; HAMRAZ, H.; WILLIAMS, J.; COOMES, D.; PIBOULE, A.; VINCENT, G. A Comparative Assessment of the Performance of Individual Tree Crowns Delineation Algorithms from ALS Data in Tropical Forests. **Remote Sensing**, v. 11, n. 9, p. 1086, 2019. DOI: 10.3390/rs11091086.

BATER, C. W.; COOPS, N. C. Evaluating error associated with lidar-derived DEM interpolation. *Computers & Geosciences*, v. 35, n. 2, p. 289-300, 2009.

BIGDELI, B.; AMINI AMIRKOLAEI, H.; PAHLAVANI, P. DTM extraction under forest canopy using LiDAR data and a modified invasive weed optimization algorithm. **Remote Sensing of Environment**, [S. l.], v. 216, p. 289-300, 2018.

CORTE, A. P. D. *et al.* Forest inventory with high-density UAV-Lidar: machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, [S. l.], v. 179, p. 105815, 2020. Disponível em: <https://doi.org/10.1016/j.compag.2020.105815>.

CORTE, A. P. D. *et al.* High-density UAV-LiDAR in an integrated crop-livestock-forest system: sampling forest inventory or forest inventory based on individual tree detection (ITD). **Drones**, Basel, v. 6, n. 2, p. 48, 2022.

CLOUDCOMPARE. **CloudCompare**: 3D point cloud and mesh processing software. Open Source Project. Versão [Coloque a sua versão]. Disponível em: <https://www.cloudcompare.org/>.

DALPONTE, M.; COOMES, D. A. Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. **Methods in Ecology and Evolution**, [S. l.], v. 7, n. 10, p. 1236-1245, 2016.

DE CONTO, T. *et al.* Performance of stem denoising and stem modelling algorithms on single tree point clouds from terrestrial laser scanning. **Computers and Electronics in Agriculture**, [S. l.], v. 143, p. 165-176, 2017.

DJI. Zenmuse L2: Especificações Técnicas. Shenzhen, China: DJI, 2023. Disponível em: <https://enterprise.dji.com/zenmuse-l2/specs>.

ESTER, M.; KRIEGEL, H. P.; SANDER, J.; XU, X. A density-based algorithm for discovering clusters in large spatial databases with noise. In: **PROCEEDINGS OF THE SECOND INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING (KDD-96)**, 1996. p. 226–231.

GOLLOB, C.; RITTER, T.; NOTHDURFT, A. Forest Inventory with Long Range and High-Speed Personal Laser Scanning (PLS) and Simultaneous Localization and Mapping (SLAM) Technology. **Remote Sensing**, v. 12, n. 9, p. 1509, 8 maio 2020. DOI: <https://doi.org/10.3390/rs12091509>.

HAHSLER, M.; PIEKENBROCK, M.; DORAN, D. dbscan: Fast density-based clustering with R. **Journal of Statistical Software**, [S. l.], v. 91, n. 1, p. 1-30, 2019.

HYYPPÄ, E.; HYYPPÄ, J.; HAKALA, T.; KUKKO, A.; WULDER, M. A.; WHITE, J. C.; PYÖRÄLÄ, J.; YU, X.; WANG, Y.; VIRTANEN, J. P.; POHJAVIRTA, O.; LIANG, X.; HOLOPAINEN, M.; KAARTINEN, H. Under-canopy UAV laser scanning for accurate forest field measurements. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 164, p. 41-60, 2020. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.03.021>.

IBRAHIM, M.; WANG, H.; IQBAL, I. A.; MIAO, Y.; ALBAQAMI, H.; BLOM, H.; MIAN, A. Forest Stem Extraction and Modeling (FoSEM): A LiDAR-Based Framework for Accurate Tree Stem Extraction and Modeling in *Pinus radiata* Plantations. **Remote Sensing**, [S. l.], v. 17, n. 3, p. 445, 2025. Disponível em: <https://doi.org/10.3390/rs17030445>.

KANGAS, A. *et al.* Remote sensing and forest inventories in Nordic countries – roadmap for the future. **Scandinavian Journal of Forest Research**, [S. l.], v. 33, n. 4, p. 397-412, 2018.

LI, W.; GUO, Q.; JAKUBOWSKI, M. K.; KELLY, M. A new method for segmenting individual trees from the lidar point cloud. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 78, n. 1, p. 75-84, 2012.

MASCARO, J.; DETTO, M.; ASNER, G. P.; MULLER-LANDAU, H. C. Evaluating uncertainty in mapping forest carbon with airborne LiDAR. **Remote Sensing of Environment**, v. 115, n. 12, p. 3770-3774, 2011.

MOHAN, M. *et al.* Individual tree detection using UAV-lidar and UAV-SfM data: a tutorial for beginners. **Open Geosciences**, [S. l.], v. 13, p. 1028-1039, 2021. Disponível em: <https://doi.org/10.1515/geo-2020-0290>.

NEUVILLE, R.; BATES, J. S.; JONARD, F. Estimating Forest Structure from UAV-Mounted LiDAR Point Cloud Using Machine Learning. **Remote Sensing**, [S. l.], v. 13, n. 3, p. 352, 2021. Disponível em: <https://doi.org/10.3390/rs13030352>.

PACKALEN, P.; STRUNK, J.; MALTAMO, M.; MYLLYMÄKI, M. Circular or square plots in ALS-based forest inventories—does it matter? **Forestry: An International Journal of Forest Research**, v. 96, n. 1, p. 49-61, 2023. DOI: <https://doi.org/10.1093/forestry/cpac032>.

PAUL, T. S. H.; KIMBERLEY, M. O.; BEETS, P. N. Thinking outside the square: Evidence that plot shape and layout in forest inventories can bias estimates of stand metrics. **Methods in Ecology and Evolution**, v. 10, n. 3, p. 384-394, 2019. DOI: <https://doi.org/10.1111/2041-210X.13113>.

POPESCU, S. C.; WYNNE, R. H. Seeing the trees in the forest: Using lidar and multispectral data to estimate tree height and crown diameter. **International Journal of Remote Sensing**, v. 25, n. 19, p. 5233-5246, 2004.

PULITI, S.; BREIDENBACH, J.; ASTRUP, R. Estimation of Forest Growing Stock Volume with UAV Laser Scanning Data: Can It Be Done without Field Data?. **Remote Sensing**, [S. l.], v. 12, n. 8, p. 1245, 2020. Disponível em: <https://doi.org/10.3390/rs12081245>.

R CORE TEAM. **R**: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2024. Disponível em: <https://www.r-project.org/>. Acesso em: 21 fev. 2026.

ROUSSEL, J.-R. *et al.* lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, [S. l.], v. 251, p. 112061, 2020.

RUSU, R. B.; MARTON, Z. C.; BLODOW, N.; DOLHA, M.; BEETZ, M. Towards 3D point cloud based object maps for household environments. **Robotics and Autonomous Systems**, [S. l.], v. 56, n. 11, p. 927-941, 2008.

SCOLFORO, J. R. S. **Biometria florestal**: inventário florestal. Lavras: UFLA, 2025.

TOCKNER, A.; GOLLOB, C.; KRASSNITZER, R.; RITTER, T.; NOTHDURFT, A. Automatic tree crown segmentation using dense forest point clouds obtained by Personal Laser Scanning (PLS). **International Journal of Applied Earth Observation and Geoinformation**, v. 114, p. 103025, nov. 2022.

WANG, X.; ZHANG, Y.; LUO, Z. Combining trunk detection with canopy segmentation to delineate single deciduous trees using airborne LiDAR data. **IEEE Access**, [S. l.], v. 8, p. 99783-99796, 2020.

WALLACE, L. O., MUSK, R., & LUCIEER, A. An assessment of the repeatability of automatic forest inventory metrics derived from UAV-borne laser scanning data. **IEEE Transactions on Geoscience and Remote Sensing**, 52(11), 7160–7169. 2024. <https://doi.org/10.1109/TGRS.2014.2308208>

WHITE, J. C. *et al.* Remote sensing technologies for enhancing forest inventories: a review. **Canadian Journal of Remote Sensing**, [S. l.], v. 42, n. 5, p. 619-641, 2016.

XU, D.; WANG, H.; XU, W.; LUAN, Z.; XU, X. LiDAR Applications to Estimate Forest Biomass at Individual Tree Scale: Opportunities, Challenges and Future Perspectives. **Forests**, [S. l.], v. 12, n. 5, p. 550, 2021. Disponível em: <https://doi.org/10.3390/f12050550>.

YU, X.; HYYPPA, J.; HOLOPAINEN, M.; VASTARANTA, M. (2021). Comparison of methods for individual tree detection and canopy height modeling using UAV LiDAR data in *Pinus massoniana* forests. **Remote Sensing**, 13(7), 1360. <https://doi.org/10.3390/rs13071360>

ZHANG, W. *et al.* An easy-to-use airborne LiDAR data filtering method based on cloth simulation. **Remote Sensing**, Basel, v. 8, n. 6, p. 501, 2016.

3 CAPÍTULO 2

CUBAGEM RIGOROSA UTILIZANDO CONTORNOS POR CLASSES ANGULARES EM NUVEM DE PONTOS LiDAR HMLS

RESUMO

BOGGIANI, Fernando Santos. Título: **CUBAGEM RIGOROSA UTILIZANDO CONTORNOS POR CLASSES ANGULARES EM NUVEM DE PONTOS LiDAR MLS**. Sorocaba: UFSCar, 2026. Cap 2. P. 40. Dissertação (Mestrado em Planejamento e Uso de Recursos Renováveis) – Universidade Federal de São Carlos, Sorocaba, 2026.

A cubagem rigorosa tradicional, embora essencial nos inventários florestais, é um procedimento destrutivo, moroso e de alto custo. O uso de sistemas de varredura a laser móvel portáteis (*Mobile Laser Scanning* – MLS) consolida-se como uma alternativa não destrutiva. Este estudo objetivou validar uma metodologia em linguagem R, denominado Seccionamento Transversal e Contornos por Classes Angulares (STAC), para a medição de seções transversais em fustes de *Pinus elliottii* a partir de dados MLS. O desempenho foi avaliado em contraposição à cubagem rigorosa tradicional realizada com suta e ao processamento automatizado pelo plugin *3DFin (CloudCompare)*. Foram avaliadas 91 seções transversais dos fustes de 0,3 a 10m de altura. O método STAC foi avaliado sob discretizações de 72 e 120 classes angulares, combinadas com diferentes métricas de distância radial (ponto mínimo, média, mediana e percentis). Os resultados indicaram a superioridade técnica da rotina desenvolvida em R em relação ao 3DFin (RMSE de 8,86%), sendo a parametrização do STAC com 72 ângulos associada à métrica do ponto mínimo a mais acurada, resultando em um RMSE de 5,94% e BIAS de 2,5%. A análise do perfil vertical dos resíduos evidenciou que as maiores superestimativas concentram-se na base das árvores (0,3 m) devido ao formato da base, havendo notável estabilização do erro a partir de 1,3 m de altura. Embora o tempo de processamento em R (23,3 segundos por árvore) seja superior ao do 3DFin, o algoritmo demonstrou-se plenamente viável para rotinas operacionais de biometria florestal, justificando-se pela flexibilidade de parametrização e significativa redução no erro das estimativas diamétricas.

Palavras-chave: Cubagem não destrutiva; Biometria florestal; R.

3.1 INTRODUÇÃO

A acurácia das estimativas volumétricas em inventários florestais depende fundamentalmente do ajuste de modelos matemáticos de afilamento e ou volume. Para que esses modelos sejam representativos, a realização da cubagem rigorosa tradicional, com o abate das árvores, geralmente é considerada (Soares et al., 2011), sendo um procedimento destrutivo, de baixa ergonomia, com risco de acidentes e elevado custo operacional. A cubagem rigorosa consiste na divisão do fuste em seções transversais, nas quais são medidos diâmetros, possibilitando o cálculo do volume por métodos como Smalian, Huber ou Newton (Campos *et al.*, 2017).

Em levantamentos operacionais, essas medições são comumente realizadas com instrumentos como a suta, amplamente utilizada pela sua praticidade, embora sujeita a erros operacionais e limitações de precisão em decorrência do formato e deformidade das seções do fuste (Campos *et al.*, 2017; Thiersch *et al.*, 2021). Por seu caráter destrutivo e oneroso, a cubagem rigorosa restringe o tamanho da amostra e pode comprometer a representatividade das estimativas quando aplicada à totalidade de um povoamento (White et al., 2016).

Contudo, diante do avanço tecnológico, o mapeamento terrestre por meio de escâners a laser tem se consolidado como uma alternativa para a cubagem não destrutiva (Vatandaslar *et al.*, 2021; Tran *et al.*, 2025), com destaque para abordagens baseadas em sistemas terrestres (*Terrestrial Laser Scanning – TLS*) e, em sistemas móveis portáteis (*Mobile Laser Scanning – MLS*) (Liang *et al.*, 2018).

O MLS, equipado com sensor LiDAR (*Light Detection and Ranging*) e integrado a algoritmos de *Simultaneous Localization and Mapping* (SLAM), permite que um operador caminhe pelo sub-bosque e digitalize os fustes em 360 graus, mesmo sob densa cobertura de dossel onde o sinal GNSS é inoperante (Bauwens et al., 2016). A nuvem de pontos resultante atua como uma representação tridimensional detalhada da árvore, permitindo a extração de atributos dendrométricos, incluindo diâmetros ao longo do fuste (Liang *et al.*, 2018, Dalla Corte *et al.*, 2020).

Apesar da capacidade de coleta acelerada do MLS, o principal gargalo operacional reside no processamento pós-coleta e na extração automatizada de perfis transversais confiáveis, dada a presença de ruídos e oclusões causadas pela folhagem do sub-bosque. Para superar esse desafio e reduzir a dependência de *softwares* comerciais, o desenvolvimento de rotinas computacionais robustas e de código aberto tem sido essencial para democratizar o processamento de grandes bases de dados tridimensionais, como o pacote *LidR* (Roussel *et al.*, 2020).

Neste cenário, de transição tecnológica, se consolidam ferramentas dedicadas à biometria florestal, a exemplo do pacote *TreeLS*, desenvolvido para a extração de métricas individuais em linguagem de programação R (De Conto, 2020), e de *plugins* especializados como o *3DFin* (Laino *et al.*, 2024) no *software CloudCompare* (Cloudcompare, 2024). Embora essas soluções facilitem a extração de parâmetros diretamente da nuvem de pontos, o desempenho de suas modelagens e a acurácia na obtenção de diâmetros ao longo do fuste ainda demandam validação de campo.

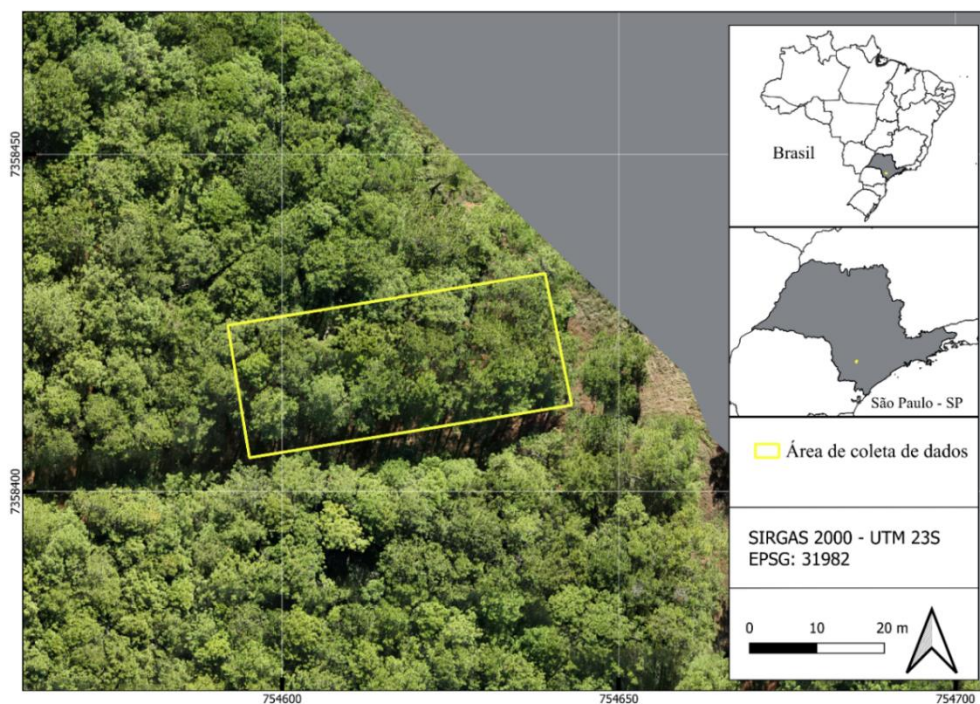
Diante desta demanda, este estudo tem como objetivo de avaliar um algoritmo de classes angulares em ambiente R para a medição de seções transversais de fustes de *Pinus elliottii* a partir de dados LiDAR em sistema MLS.

3.2 MATERIAL E MÉTODOS

3.2.1 Área de estudo

O estudo foi conduzido em um plantio de *Pinus elliottii*, com idade aproximada de 41 anos, localizado na Floresta Nacional (FLONA) de Capão Bonito, localizadano município de Capão Bonito – SP.

Figura 14 – Localização da área de estudo na Floresta Nacional de Capão Bonito, Capão Bonito, São Paulo.




Fonte: Elaborado pelo autor.

3.2.2 Coleta MLS e pré-processamento da nuvem de pontos

Para a avaliação dos fustes, foram selecionados sete indivíduos amostrais. O escaneamento terrestre foi realizado com o sistema HMLS LiGrip Lite O1 (GreenValley International), equipado com o sensor LiDAR Livox Mid-360 (comprimento de onda de 903 nm). O equipamento integra uma Unidade de Medição Inercial (IMU) e opera fundamentado no algoritmo SLAM, combinando os dados inerciais à varredura a laser para a reconstrução tridimensional precisa do ambiente. O sensor apresenta taxa de emissão de 200.000 pulsos s^{-1} , alcance de até 40 m (a 10% de refletividade), acurácia de 2 cm e campo de visão de 360° na horizontal e 59° na vertical (Greenvalley International, 2023) conforme ilustra a figura 15.

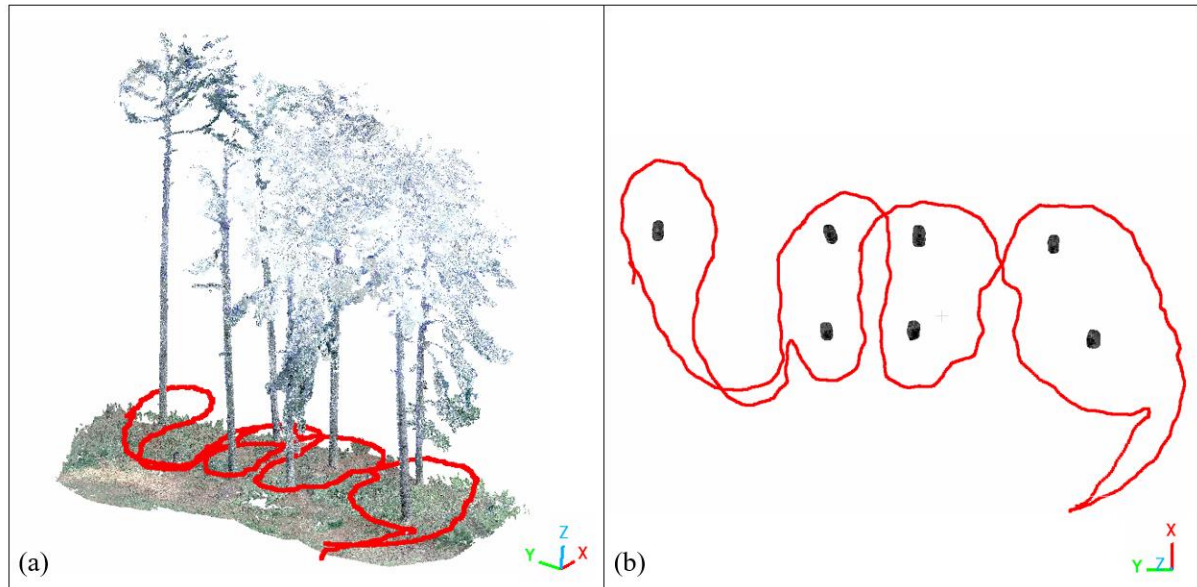
Figura 15 – Ilustração do sensor direcionado ao fuste, indicando seu campo de visão vertical de 59° (α), com inclinação do sensor LiDAR em 20° (θ) no equipamento.



Fonte: Elaborado pelo autor.

O caminhamento foi realizado no entorno de cada árvore (Figura 16), com o equipamento posicionado à altura de 1,30 m do solo e velocidade de deslocamento de 1 m s^{-1} , garantindo a varredura horizontal de 360° do fuste.

Figura 16 – Nuvem de pontos da amostra ilustrando caminhamento de coleta realizado com sensor LiDAR MLS. (a) Nuvem de pontos 3D com o caminhamento realizado em vermelho. (b) Ilustração do caminhamento bidimensional (X,Y).




Fonte: Elaborado pelo autor.

O processamento da nuvem de pontos do sistema HMLS foi realizado no ambiente R (R CORE TEAM, 2024), utilizando as funções de manipulação de dados LiDAR do pacote *LidR* (Roussel *et al.*, 2020).

A identificação inicial dos pontos correspondentes ao terreno foi realizada com a função *classify_ground*, aplicando o algoritmo *Cloth Simulation Filter* (CSF) (ZHANG *et al.*, 2016). Diferentemente das varreduras aéreas, os escaneamentos terrestres geram nuvens com altíssima densidade de pontos próximos ao nível do solo. Como evidenciado por Bailey *et al.* (2022), o desempenho do CSF nesses cenários é sensível à parametrização. Diante disso, foram avaliados diferentes valores para a resolução da malha (parâmetro *cloth_resolution*): 0,5; 0,7; 0,9 e 1,0 m, conforme ilustra a Figura 17. A partir de análise visual, constatou-se que resoluções menores, embora acompanhem os microdetalhes do relevo, classificam erroneamente a base dos tocos como terreno (Figura 17a e b). Em contrapartida, as resoluções de 0,9 m e 1,0 m proporcionaram uma suavização mais adequada da superfície (Figura 17c e d), contornando o problema. Por apresentar o melhor resultado, adotou-se a resolução de 1,0 m.

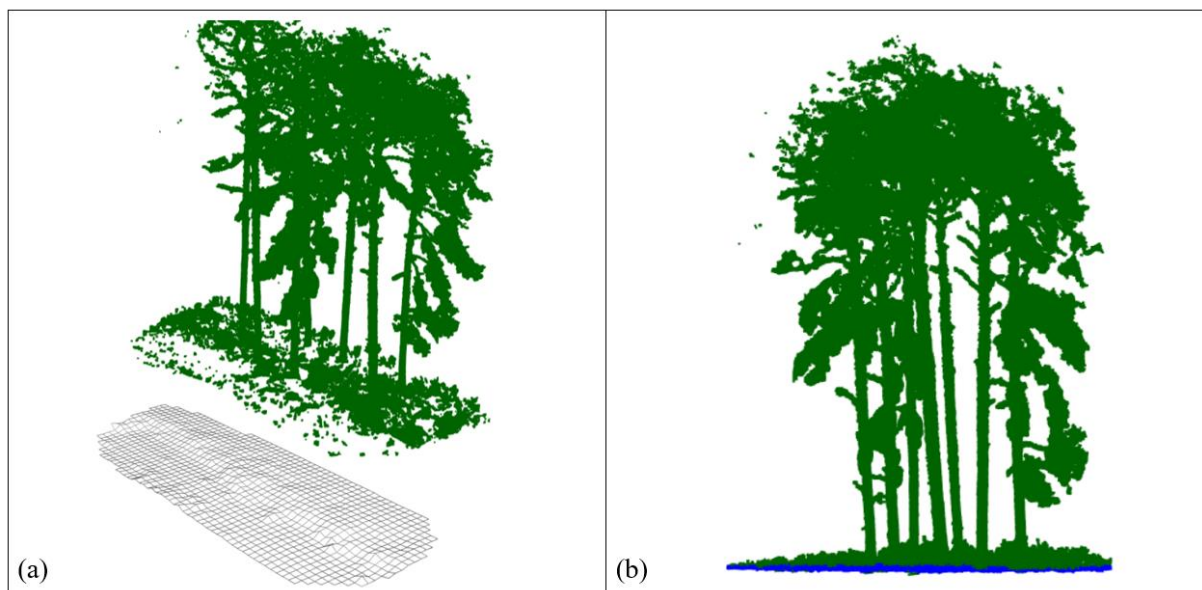
Figura 17 – Pontos classificados como terreno sob valores de resolução de malha (*cloth_resolution*) em 0,5, 0,7, 0,9 e 1,0 m (a, b, c e d, respectivamente).



Fonte: Elaborado pelo autor.

Com os retornos de solo devidamente classificados, o Modelo Digital de Terreno (MDT) (Figura 18a) foi gerado com a função *rasterize_terrain* pela Ponderação pelo Inverso da Distância (*Inverse Distance Weighting* - IDW) baseada no algoritmo dos vizinhos mais próximos (*k-Nearest Neighbors* - KNN) (Bater *et al.*, 2009). Por fim, a normalização das alturas da nuvem de pontos foi executada a função *normalize_height*, utilizando o MDT como superfície de referência, de modo a equalizar os pontos de vegetação para o plano $Z = 0$ (Figura 18b).

Figura 18 – (a) Pontos classificados como vegetação em coloração verde sob MDT com malha de $1,1\text{m}^2$. (b) Nuvem de pontos normalizada e classificada com vegetação (verde) e terreno (azul).



Fonte: Elaborado pelo autor.

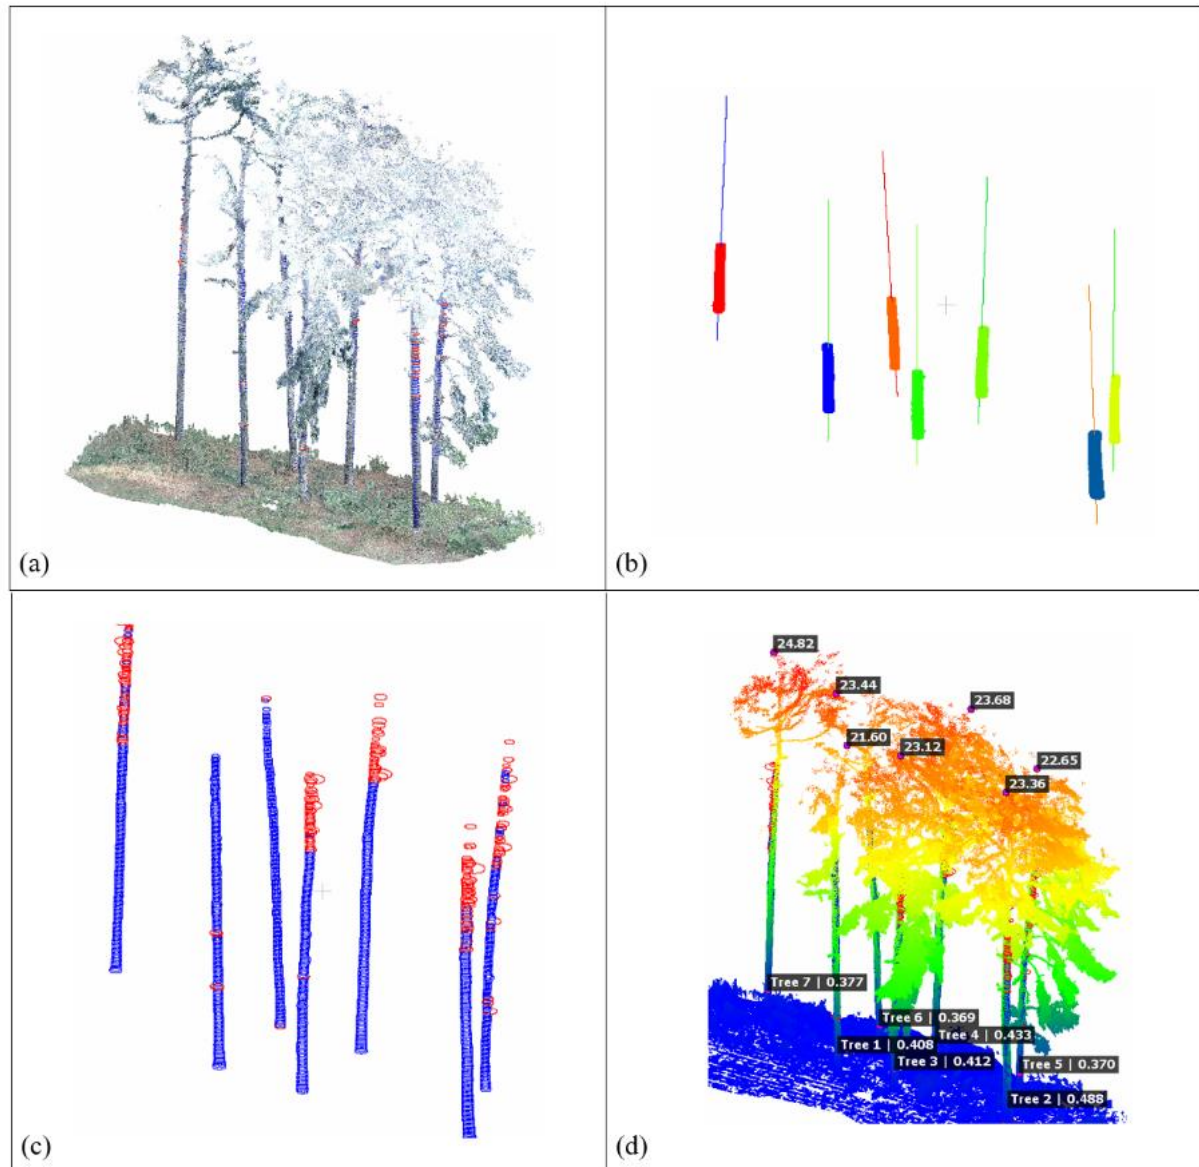
3.2.3 Métodos de obtenção e estimativa diamétrica avaliados

3.2.3.1 Algoritmo 3Dfin

Com a nuvem de pontos normalizada (Figura 19a), a extração das variáveis dendrométricas foi realizada utilizando o algoritmo 3Dfin, descrito por Laino *et al.* (2024), em linguagem de programação C++, e executada em plataforma interativa no *software CloudCompare*, baseando-se em regras geométricas e de agrupamento espacial para a detecção de árvores, medição da altura total e cálculo de diâmetros ao longo do fuste.

Inicialmente, o algoritmo define uma faixa horizontal parametrizada no intervalo de 0,7 a 3,5m de altura. Os pontos contidos nesta faixa são avaliados quanto a sua verticalidade, onde pontos com baixos valores de verticalidade são descartados, e os remanescentes são agrupados por distância euclidiana via DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) (Cabo *et al.*, 2014, Cabo *et al.*, 2018). Esse procedimento atua de forma análoga a uma desrama dos troncos, isolando as bases dos fustes na faixa horizontal (Laino *et al.*, 2024), conforme ilustra a Figura 19b.

Figura 19 – Etapas do processamento via 3Dfin. (a) Nuvem de pontos normalizada. (b) Faixas horizontais e hastes de cada fuste identificado. (c) Seções transversais. (d) Nuvem de pontos com fuste detectado, DAP e altura total.




Fonte: Elaborado pelo autor.

A partir das bases identificadas, os eixos iniciais dos fustes são computados considerando a direção do primeiro componente principal das coordenadas de cada tronco, onde todos os pontos da nuvem são mapeados para o eixo de árvore mais próximo, e assim segmentadas por eixo.

O diâmetro de cada seção é calculado a partir de seções horizontais com 0,1 m de espessura, extraídas em intervalos sucessivos de 0,1 m ao longo do fuste (Figura 19c e 20). Para

a estimativa do diâmetro, o algoritmo aplica o ajuste de círculos via minimização dos mínimos quadrados não lineares sobre as coordenadas bidimensionais (x,y) dos pontos selecionados.

Figura 20 . Ilustração das seções obtidas na altura de 1,3 m a 2,3m. (a) Visualização em 3D. (b) Visualização em 2D.



Fonte: Elaborado pelo autor.

3.2.3.2 Seccionamento Transversal e Contornos por Classes Angulares (STAC)

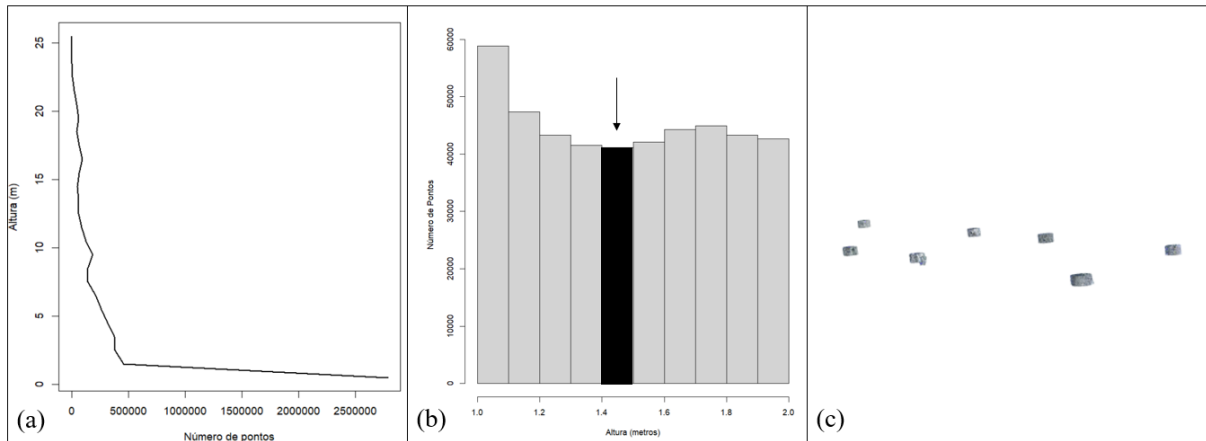
A metodologia para individualização e extração das seções transversais foi implementada em ambiente de programação R (R Core Team, 2024), com o suporte dos pacotes *lidR* (Roussel *et al.*, 2020) e *sf* (Pebesma, 2018). O procedimento consistiu na adaptação de abordagens descritas por Černava *et al.* (2019), Hyyppä *et al.* (2020) e Bernardi (2024) que utilizam a discretização em classes angulares sobre projeções bidimensionais das seções para a definição de arcos, círculos e contornos representativos a partir de seus centroides. Complementarmente, considerou-se a lógica de Wang *et al.* (2017) para a caracterização de contornos transversais por meio de coordenadas polares. Para a individualização dos fustes, utilizou-se uma rotina em linguagem R com o pacote *dbscan* para o agrupamento espacial bidimensional desenvolvido por Hahsler *et al.* (2019).

3.2.3.2.1 Individualização dos fustes

A definição da altura de cada seção baseou-se na identificação automática do estrato vertical com a menor densidade de pontos, no intervalo pré-definido de 1 a 3 m, com base na observação da distribuição de pontos em relação a altura da nuvem (Figura 21a). Este intervalo

foi discretizado em um histograma com densidade de pontos para cada classe de 0,1 metro, e o valor central da classe com menor frequência de retornos (Figura 21b) dentro deste intervalo (1,45m) foi selecionada para o recorte de espessura de 0,1 m (Figura 21c).

Figura 21 – (a) Perfil de distribuição vertical do número de pontos LiDAR em relação à altura. (b) Disposição lateral dos pontos nos eixos X e Z. (c) Recorte da seção na altura de 1,45m.



Fonte: Elaborado pelo autor.

A partir do recorte, a nuvem foi projetada no plano bidimensional (X,Y). Em seguida, aplicou-se o algoritmo DBSCAN com a função *dbscan* utilizando um raio de busca (*epsilon*) de 1,5 m e um critério mínimo de 100 pontos vizinhos (*minPts*) para a formação de cada agrupamento, ou seja, cada fuste identificado. O centroide de cada fuste foi calculado utilizando a função de centroide geométrico (*st_centroid*) do pacote *sf* (Pebesma, 2018). A partir de cada centroide, estabeleceu-se um *buffer* circular de 2,5 m de raio no plano (X,Y) para segmentar cada árvore individual. A projeção dessa área ao longo do eixo Z delimitou um cilindro na nuvem de pontos tridimensional, de modo que todos os retornos contidos em seu interior foram classificados como parte de um fuste (figura 22).

Figura 22 – Árvores segmentadas a partir do raio de 2,5m do centroide de cada agrupamento.

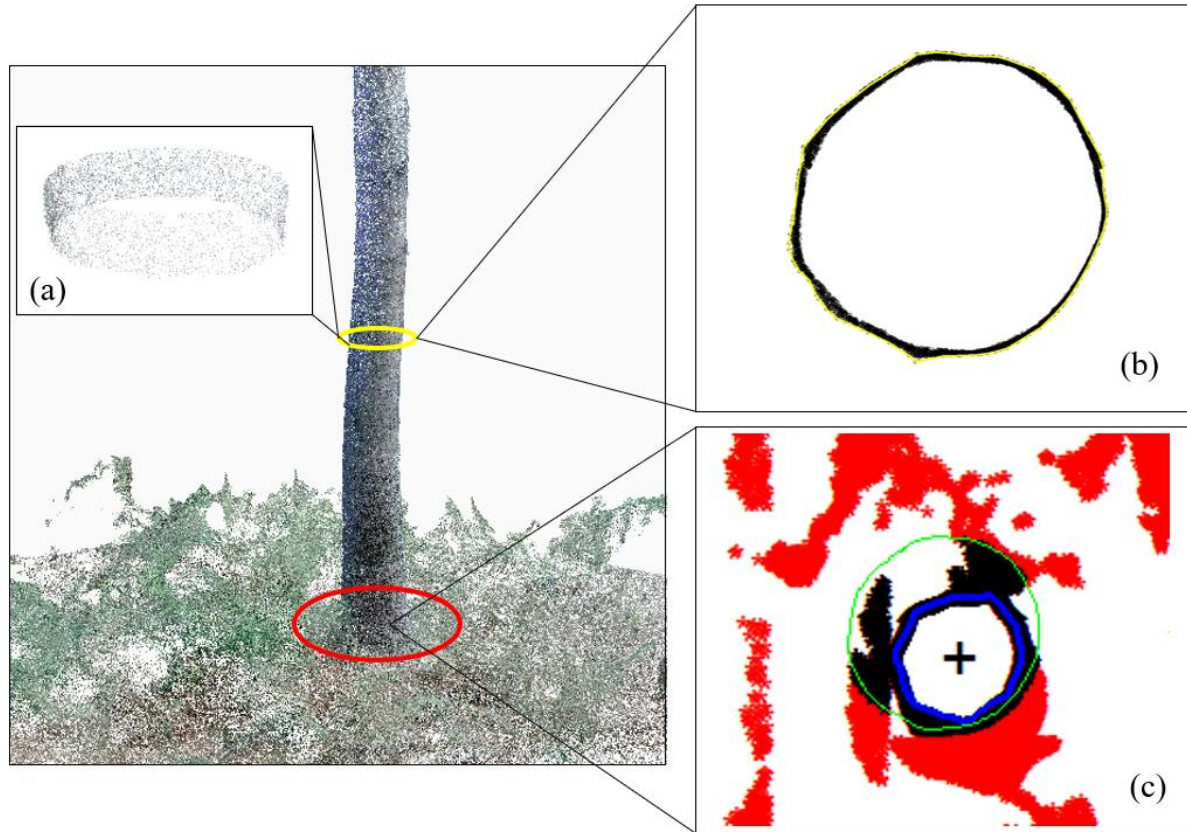


Fonte: Elaborado pelo autor.

3.2.3.2.2 Seccionamento transversal e definição de contornos

Após a individualização das árvores descritas na etapa anterior, o seccionamento se inicia com a leitura individual de cada uma delas, seguida do recorte de uma seção de 0,10 m de comprimento, entre as alturas de 1,95 e 2,05 m (Figura 23a) para iniciar o processamento das seções seguintes. Essa seção é projetada bidimensionalmente (X, Y) e submetida à função *st_convex_hull* para a determinação do seu perímetro convexo (Figura 23b). O centroide dessa seção é calculado pela função *st_centroid* do pacote *sf*. Em seguida, o perímetro convexo é utilizado para recortar a base do fuste, na primeira seção (0,1m), no qual aplica-se um *buffer* de 0,20 m para isolar e remover pontos externos (Figura 23c).


Figura 23 – Seção do fuste na altura de 2,0 m (a) com 0,1 m de espessura. Projeção bidimensional da seção com perímetro convexo em amarelo (b). Em vermelho, pontos descartados pelo *buffer*, e em preto, pontos inclusos para a primeira seção do fuste(c).



Fonte: Elaborado pelo autor.

A partir desta primeira seção, o algoritmo avança iterativamente para as seções superiores. Para garantir a continuidade cilíndrica da reconstrução, cada nova seção transversal é filtrada espacialmente utilizando um *buffer* de 0,03 m gerado no entorno do polígono da seção inferior, com o intuito de remover galhos e corrigir inclinações (Figura 24).


Figura 24 – Seções na altura 3,8 e 3,9m (a e b, respectivamente) ilustrando o *buffer* da seção anterior para remoção de galhos na seção atual.



Fonte: Elaborado pelo autor.

Após a filtragem espacial de cada seção, seu novo centroide é calculado e os pontos cartesianos (X , Y) são convertidos para coordenadas polares, obtendo-se o ângulo e a distância Euclidiana (radial) de cada ponto em relação ao centro. Para avaliar a influência da resolução angular na reconstrução geométrica do fuste, o plano transversal de 360° foi discretizado e testado sob dois cenários metodológicos distintos com 72 e 120 classes angulares (STAD-72 e STAD-120), o que corresponde a amplitudes de 5° e 3° por classe, respectivamente (Figura 25a).

Figura 25 – Distribuição de pontos por classe angular na projeção bidimensional da seção (a). Mediana de cada classe angular na seção (b). Polígono formado pelos pontos de cada classe angular (c).



Fonte: Elaborado pelo autor.

Para a definição do contorno da seção transversal, a distância do centroide até a borda do fuste (raio) foi sumarizada por classe angular. Com o intuito de definir o melhor ajuste do contorno (figura 25b), diferentes métricas foram avaliadas com base na distância dos pontos de cada classe: valores mínimo, média, mediana e percentis (20, 30, 40, 60, 70). Para as classes angulares sem retornos LiDAR, aplicou-se uma interpolação linear, conectando os ângulos adjacentes.

Os vértices resultantes foram ordenados de forma crescente e conectados pela função *st_polygon* do pacote *sf* para formar um polígono fechado (Figura 25c). A área de cada polígono gerado foi calculada e convertida para o diâmetro da seção transversal (*d*), conforme a seguinte equação:

$$d = \sqrt{\frac{4A}{\pi}} \times 100 \quad (6)$$

Em que:

d é o diâmetro da seção estimado em centímetros;

A é a área do polígono delineado em metros quadrados.

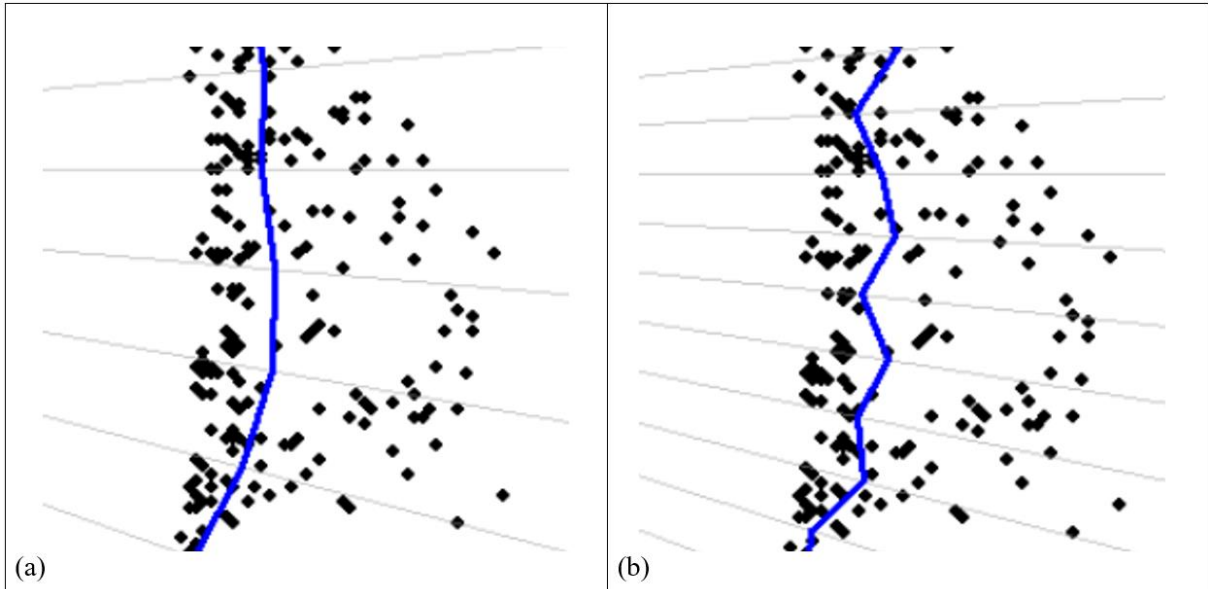
Ao final de cada contorno, o polígono gerado pelo limiar mínimo de distância foi adotado como a base geométrica (seção anterior) para direcionar o *buffer* de 0,03m de busca da seção subsequente, da mesma forma descrita para a primeira seção do fuste.

Para garantir a consistência geométrica da reconstrução, foi aplicado um critério de validação de cada seção transversal com exigência mínima de 50% de suas classes angulares com pelo menos dois pontos LiDAR. Na prática, isso exigiu um mínimo de 36 classes preenchidas para o cenário STAD-72, e 60 classes para o cenário STAD-120. Seções que não atenderam o critério estabelecido foram descartadas, indicando que o limite do fuste havia sido ultrapassado ou que a densidade do dossel impedia a amostragem adequada, finalizando o seccionamento da árvore atual e avançando para a próxima.

Ao reconstruir essa geometria a partir de nuvens de pontos LiDAR, surge um compromisso entre a aderência da forma gerada e a densidade de pontos amostrada (Witzmann *et al.*, 2022). O uso de um maior número de classes angulares permite capturar as irregularidades do contorno com um nível superior de detalhamento. No entanto, o estreitamento da classe angular reduz o número de pontos LiDAR por classe, o que pode tornar a reconstrução do contorno vulnerável a perdas de precisão em seções com baixa densidade ou oclusão (Figura 26). Desta forma, conforme estabelecido, os contornos foram processados sob

as duas classes angulares (72 e 120 classes), a fim de para avaliar o comportamento dos contornos.

Figura 26 – Contorno da seção bidimensional para as classes angulares STAC-72 (a) e STAC-120 (b).




Fonte: Elaborado pelo autor.

3.2.3.3 Cubagem Rigorosa tradicional com suta

As sete árvores selecionadas foram submetidas ao abate para a realização da cubagem rigorosa destrutiva. Previamente à derrubada, foi marcada em cada indivíduo a posição correspondente ao diâmetro à altura do peito (DAP), a 1,30 m do solo, com a finalidade de servir como referência para o correto posicionamento da fita métrica ao longo do fuste após o abate, garantindo a precisão na localização das seções de medição.


Figura 27 – (a) Abate das árvores de *Pinus elliottii*. (b) Medição das seções transversais com suta.



Fonte: Elaborado pelo autor.

Após o corte, os fustes foram mantidos inteiros, sendo estendida uma fita métrica ao longo de todo o seu comprimento, desde a base até o ápice (Figura 27). A partir dessa referência longitudinal, foram demarcadas as posições correspondentes às seções de medição nas alturas de 0,3; 0,7; 1,0; 1,3; 2,0; 3,0; 4,0 m e assim sucessivamente, até o final do fuste (Figura 28).

Figura 28 - Ilustração da distribuição das seções de medição ao longo do fuste para cubagem rigorosa.



Fonte: Elaborado pelo autor.

Em cada uma dessas posições, os diâmetros com casca foram mensurados com o uso de suta florestal modelo Mantax Blue, fabricada pela Haglöf Sweden (Haglof Sweden,2021), sendo realizadas medições em duas direções perpendiculares, até o diâmetro mínimo de 5cm. A partir dessas medições, o diâmetro equivalente (dicc) de cada seção foi calculado, conforme equação (7).

$$dicc = \sqrt{dicc_1 \times dicc_2} \quad (7)$$

Em que:

dicc₁ e dicc₂ correspondem aos diâmetros com casca medidos em direções perpendiculares.

3.2.3.4 Síntese dos cenários avaliados

A Tabela 5 sintetiza todas as configurações parametrizadas para os metodos avaliados neste estudo, com breve descrição da metodologia para cada configuração.

Tabela 5 – Síntese dos cenários avaliados.

Método	Coleta	Ferramenta / ambiente	Descrição da coleta por seção
3DFIN	Nuvem de pontos	<i>CloudCompare</i> (C++)	Ajuste de círculos por mínimos quadrados não lineares
STAD-72	Nuvem de pontos	Linguagem R	Contorno discretizado em 72 classes angulares e métricas de distância
STAD-120	Nuvem de pontos	Linguagem R	Contorno discretizado em 120 classes angulares e métricas de distância
Cubagem Rigorosa	Manual	Suta (campo)	2 medições perpendiculares

3.2.4 Análise estatística e eficiência computacional

Para quantificar a acurácia de cada método baseado em nuvem de pontos LiDAR, as estimativas diamétricas foram comparadas com as medições manuais realizadas em campo, pelo método da cubagem tradicional com uso da suta.

A comparação estatística assume a suta como valor de referência, pela necessidade de avaliar a viabilidade de substituição do padrão operacional atual pelos métodos LiDAR. No

entanto, os erros estatísticos devem ser interpretados sob a ressalva de que uma maior convergência numérica com a suta não implica, obrigatoriamente, na reconstrução mais fiel da arquitetura real da árvore.

Com base nessa premissa, as divergências entre os diâmetros estimados pelos algoritmos e os diâmetros observados pela suta foram comparados por meio da Raiz do Erro Quadrático Médio (*Root Mean Square Error* - RMSE) e Viés (*Bias* - *BIAS*), calculados pelas respectivas equações:

$$BIAS = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (8)$$

$$BIAS (\%) = \left(\frac{BIAS}{\bar{y}} \right) \times 100 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

$$RMSE (\%) = \left(\frac{RMSE}{\bar{y}} \right) \times 100 \quad (11)$$

Em que:

\hat{y}_i é o diâmetro estimado pelo algoritmo na seção i ;

y_i é o diâmetro mensurado pela suta na seção i ;

\bar{y} é o diâmetro médio das seções;

e n é o número total de seções.

A eficiência computacional foi computada pelo tempo de segmentação e seccionamento das sete árvores na nuvem de pontos normalizada no software *CloudCompare* com o algoritmo *3Dfin* e no R (Equação 5). A extração dos tempos foi realizada de forma automatizada no R utilizando a função *Sys.time()* desde o carregamento da nuvem de pontos até o seccionamento da última árvore. Todos os processamentos foram executados em um computador equipado com processador Intel Core i5 9ª geração, 24 GB de memória RAM e sistema operacional Windows 11.

$$\bar{T}_p = \frac{T_f - T_i}{n} \quad (12)$$

Em que:

\bar{T}_p é o tempo médio de processamento por parcela (em segundos);

T_f corresponde ao tempo registrado no término do processamento do conjunto de parcelas;


T_i é o tempo inicial registrado antes da execução do algoritmo;

n o número de parcelas avaliadas.

3.3 RESULTADOS E DISCUSSÃO

Os métodos baseados em nuvem de pontos não alcançaram a mesma amplitude vertical da cubagem rigorosa realizada em campo (figura 29). Nas sete árvores avaliadas, o limite de detecção das seções transversais variou entre 10 e 15 m. Essa limitação é justificada pela perda de densidade de pontos do LiDAR à medida que a altura do fuste aumenta, ocasionada pela oclusão de pontos nas ramificações do fuste (Choi *et al.*, 2022). Portanto, para garantir uma base de comparação equivalente, o presente estudo avaliou apenas as seções extraídas até a altura de 10 m para todos os métodos.

Figura 29 – Distribuição das alturas de medição (h_i) ao longo do fuste para as sete árvores analisadas.



A avaliação do método STAC, 3Dfin e cubagem rigorosa tradicional foi realizada com base na extração de 91 seções transversais distribuídas ao longo dos fustes de sete árvores, compreendendo medições até a altura de 10 m. A Tabela 6 apresenta as estatísticas de BIAS e RMSE resultantes da comparação entre os diâmetros estimados pelos diferentes métodos avaliados com a nuvem de pontos LiDAR em relação a medição realizada em campo na cubagem rigorosa tradicional com suta.

Tabela 6 –RMSE e BIAS para o algoritmo 3DFin e parametrizações avaliadas em STAC.

Método	Métricas	BIAS	BIAS (%)	RMSE	RMSE (%)
3DFin	-	2,47	6,57	3,33	8,86
	Mínimo	0,94	2,5	2,24	5,94
	P20	1,57	4,18	2,75	7,32
	P30	1,81	4,81	3,01	8
STAC - 72	P40	2,04	5,42	3,29	8,74
	Mediana	2,28	6,05	3,6	9,55
	Media	2,34	6,22	3,67	9,74
	P60	2,52	6,69	3,91	10,37
	P70	2,79	7,42	4,27	11,36
	Mínimo	1,1	2,92	2,37	6,3
	P20	1,65	4,39	2,85	7,56
	P30	1,87	4,98	3,08	8,18
STAC - 120	P40	2,09	5,55	3,33	8,85
	Mediana	2,31	6,14	3,62	9,63
	Media	2,37	6,3	3,7	9,82
	P60	2,54	6,74	3,91	10,39
	P70	2,79	7,41	4,24	11,27

Para o método STAC, a análise dos dados revela que as métricas baseadas nos menores valores de distância (Mínimo, P20 e P30) apresentaram desempenho estatístico superior às medidas de tendência central (Média e Mediana) e aos percentis mais elevados (P60 e P70) em ambas as configurações angulares. Na discretização de 72 classes (STAC-72), o uso do ponto Mínimo resultou no método de maior acurácia em relação à suta (RMSE de 5,94% ou 2,24 cm), superando o desempenho do algoritmo 3DFin (RMSE de 8,86% ou 3,33 cm).

Entretanto, esse desempenho superior das métricas de limite inferior deve ser interpretado considerando as características de cada método avaliado. Embora a medição com suta seja adotada neste estudo como o método de referência, por ser o instrumento padrão nos inventários florestais tradicionais (Scolforo *et al.*, 2025), é fundamental ressaltar que seus valores não representam a geometria exata da seção transversal (Lavagnoli *et al.*, 2025).

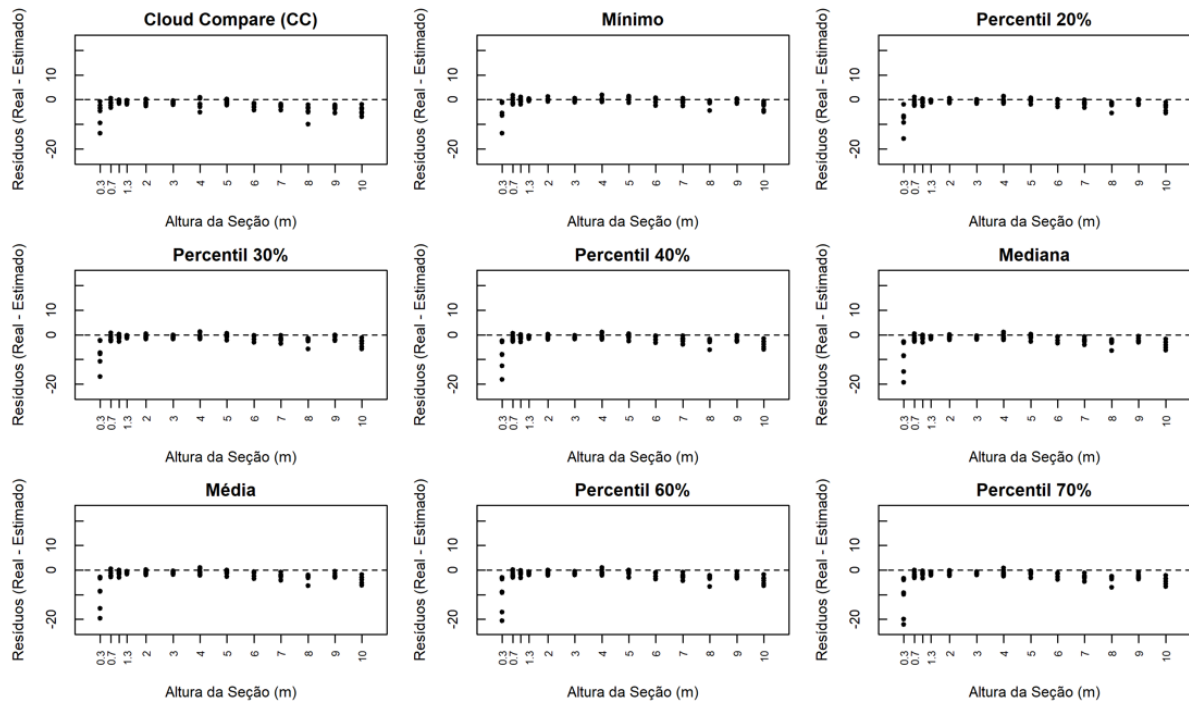
Conforme demonstrado por Witzmann *et al.* (2022) e Lavagnoli *et al.* (2025), a suta mensura a distância linear entre dois planos paralelos tangentes à casca e calcula a área sob a premissa de circularidade perfeita do fuste. O fuste, além de apresentar desvios de circularidade e convexidade transversais, possui uma morfologia longitudinal complexa que transita entre formas de neiloide, parabolóide e cone ao longo de sua extensão (Thiersch *et al.*, 2021; Mctague *et al.*, 2021). Consequentemente, medições baseadas em diâmetros únicos estão sujeitas a

superestimar ou subestimar a área real da seção, dependendo do ângulo de posicionamento do operador e das irregularidades locais do tronco (Lavagnoli *et al.*, 2025).

Ao utilizar o ponto mínimo ou percentis baixos, o algoritmo seleciona apenas os pontos mais internos de cada classe angular, resultando em um polígono de menor área. Numericamente, isso gera um efeito compensatório que aproxima o resultado do círculo teórico da suta, mas não necessariamente representa a geometria real da seção transversal (Witzmann *et al.*, 2022; Lavagnoli *et al.*, 2025).

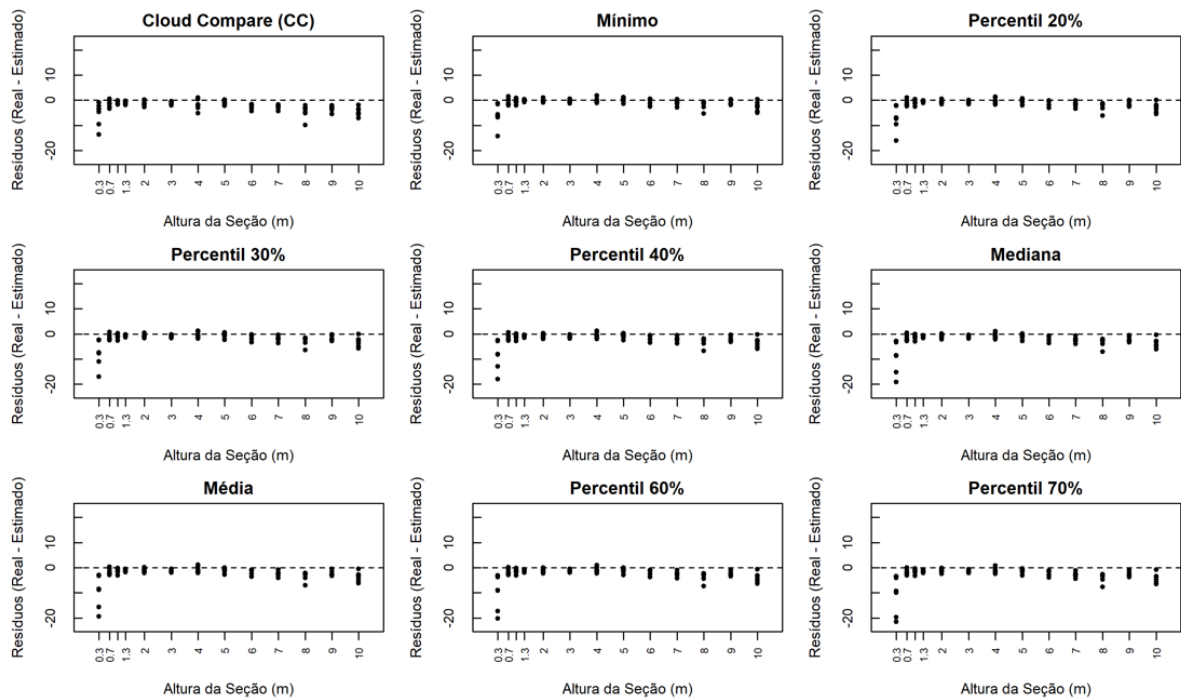
A análise dos resíduos ao longo da altura (Figuras 30 e 31) revelou que o erro não é uniforme, sendo influenciado pela variação morfológica do fuste. As maiores discrepâncias e superestimativas ocorreram na seção de 0,3 m. Nesta região, a árvore assume a forma de um neiloide (Mctague *et al.*, 2021), caracterizada por sapopemas e transições abruptas. Como a suta baseia-se na suposição de circularidade, ela falha em capturar as concavidades entre as sapopemas. Em contrapartida, o STAC utiliza a nuvem de pontos para descrever o contorno real, gerando uma aparente superestimativa estatística que, na verdade, representa uma medição mais fiel da área ocupada pelo fuste.

Figura 30 – Distribuição de resíduos para o algoritmo 3DFin e parametrizações avaliadas em STAC – 72.



Fonte: Elaborado pelo autor.

Figura 31 – Distribuição de resíduos para o algoritmo 3DFin e parametrizações avaliadas em STAC – 120.



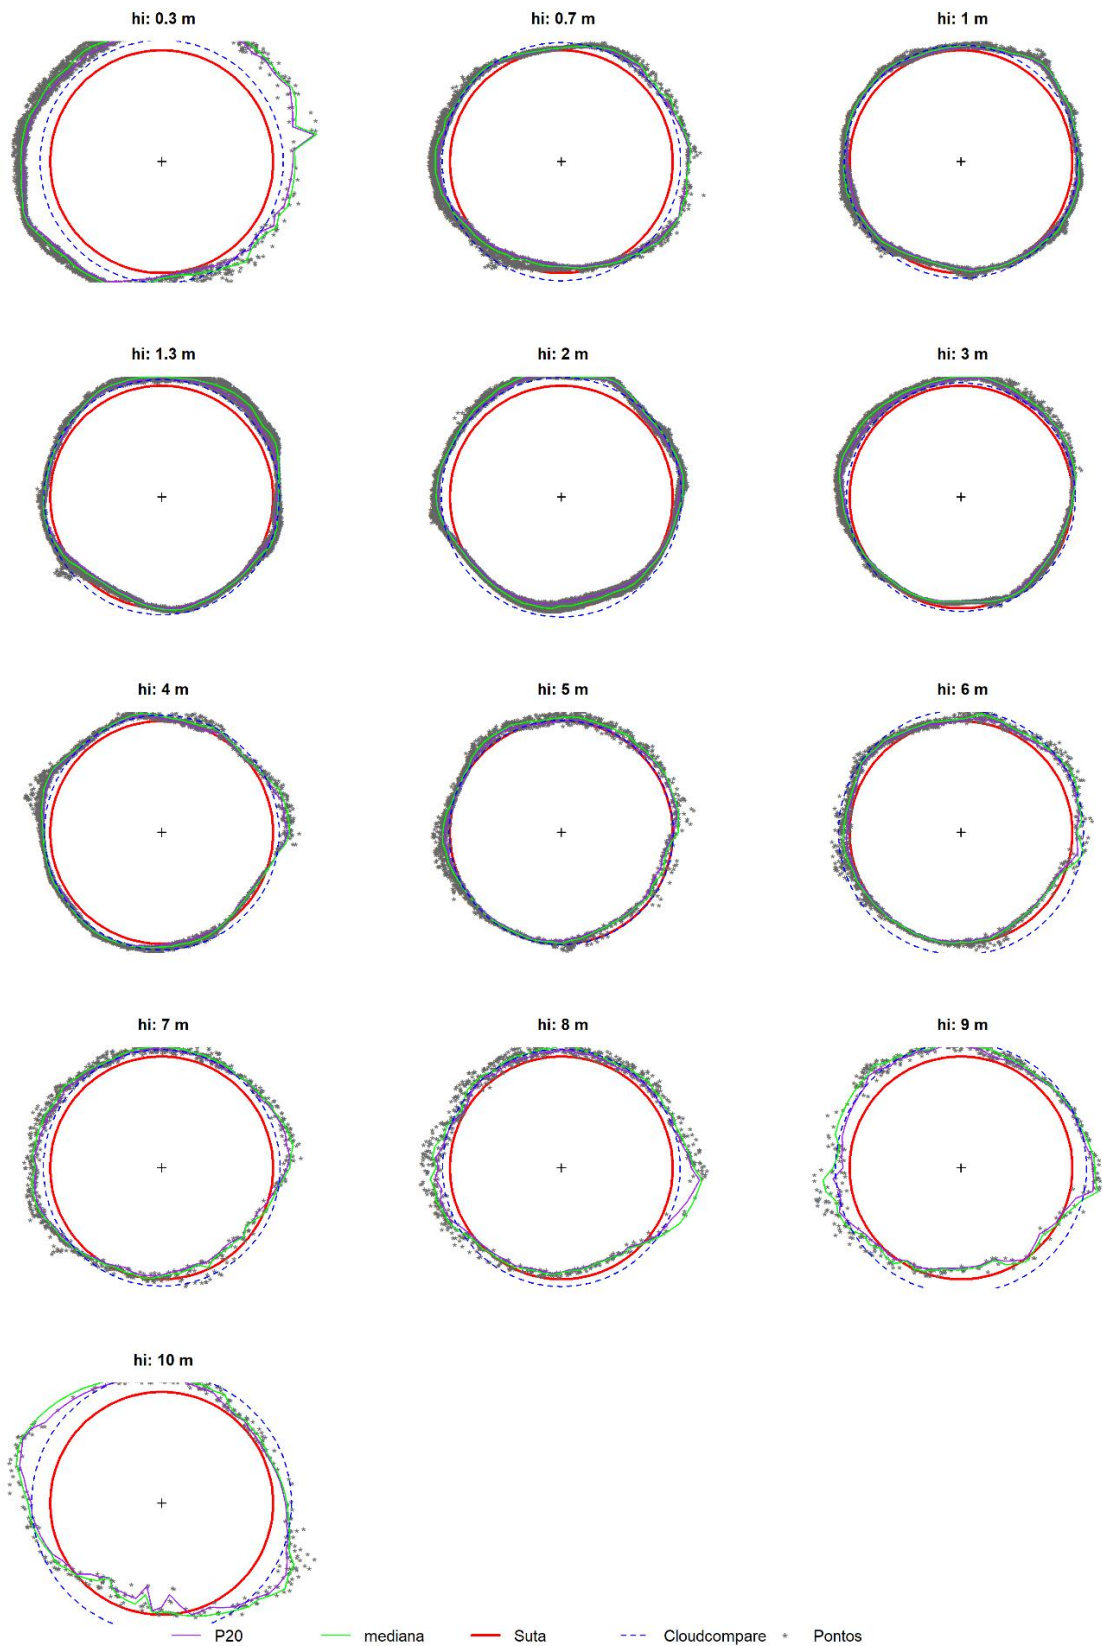
Fonte: Elaborado pelo autor.

A estabilização do erro observada entre 1,3 m (DAP) e 5,0 m coincide com a transição para formatos circulares e regulares (Figuras 32 e 33). Nesta região, a maior regularidade geométrica do fuste reflete nos menores desvios entre os métodos.

As Figuras 32 e 33 corroboram que a convergência numérica com a cubagem tradicional não garante fidelidade geométrica. Visualmente, a a valiação de pontos do método STAC pela mediana apresentaram contornos mais aderentes à densidade principal de pontos LiDAR. A suta, embora estatisticamente próxima ao método STAC com pontos mínimos, subestima a área real ao projetar circunferência inferior aos pontos visíveis da nuvem de pontos.

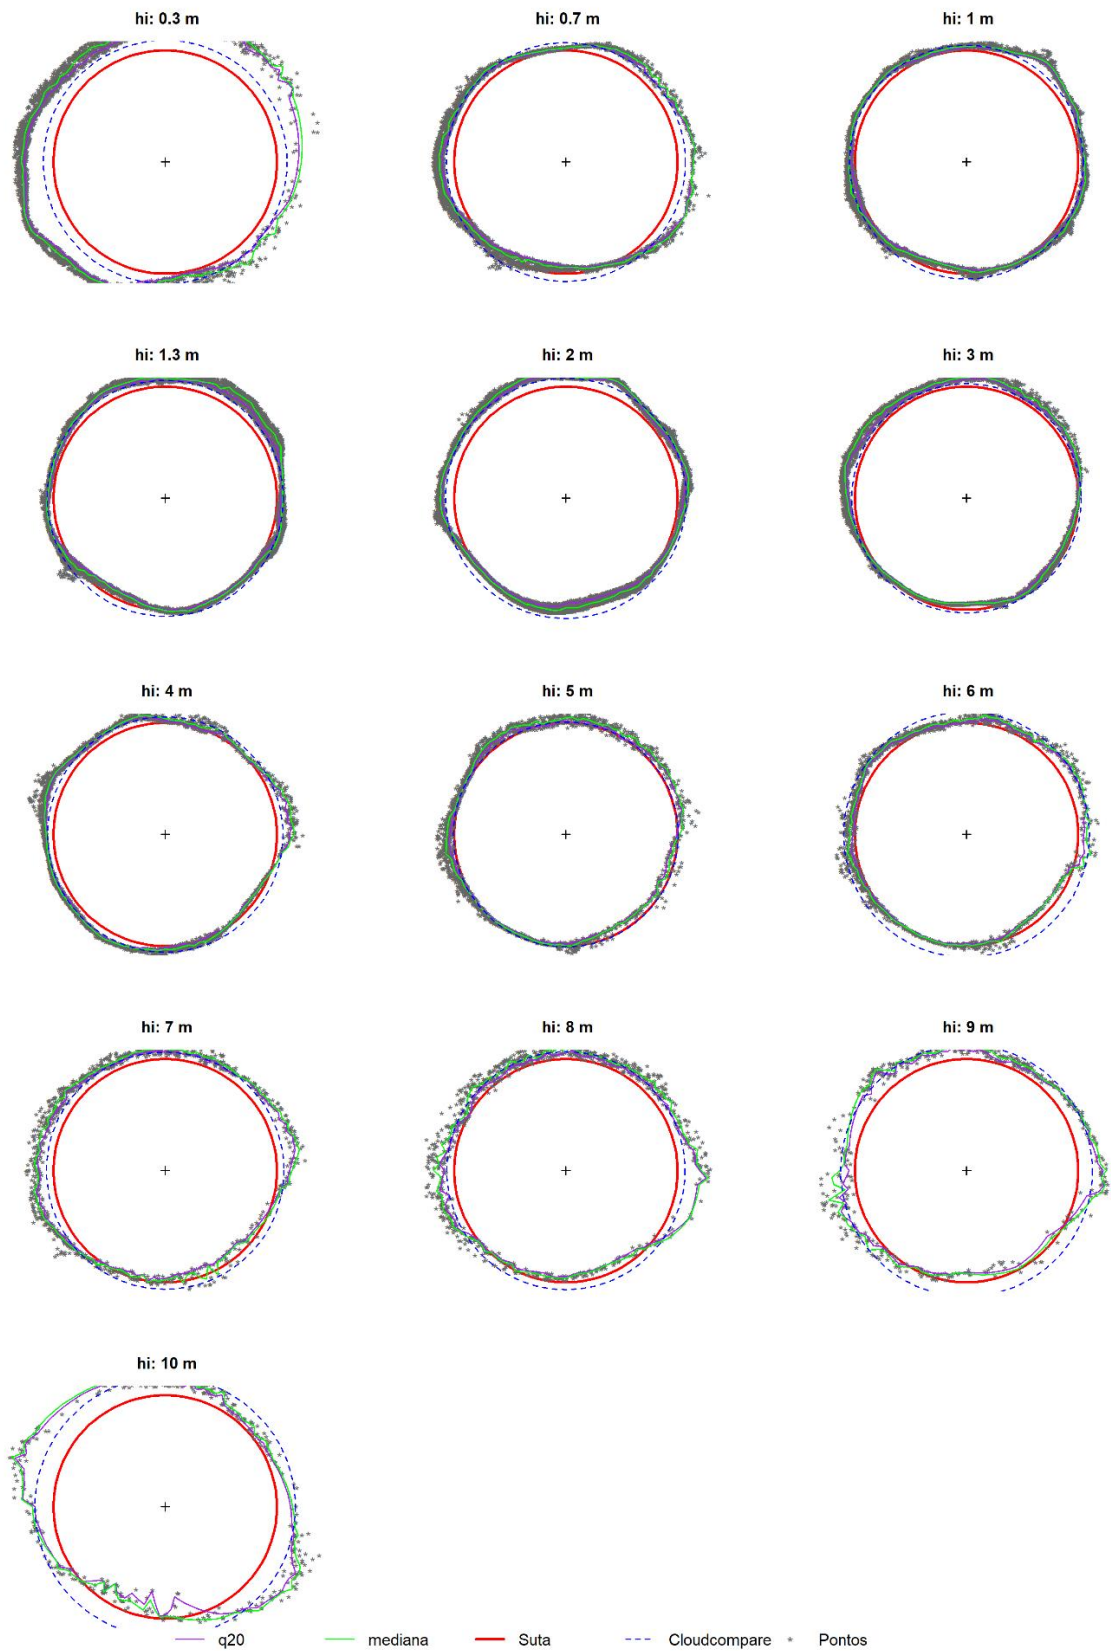
Deve-se considerar, adicionalmente, a acurácia nominal de 2 cm do equipamento utilizado (Greenvalley International, 2023), cujos efeitos residuais podem persistir mesmo após a mitigação de ruídos via estimativa pela mediana no método STAC. Tockner *et al.* (2022), ao avaliarem 434 medições de DAP via LiDAR e suta, encontraram um RMSE de 11,44% e BIAS de 5,29%, atribuindo tais discrepâncias aos ruídos da nuvem de pontos e à tolerância intrínseca do sensor. De maneira análoga, Gollob *et al.* (2020) obtiveram um RMSE de 12,01% na comparação de dados MLS com suta, identificando uma tendência de subestimativa do LiDAR em diâmetros maiores, decorrente de oclusões e interferências na nuvem.

Figura 32 - Ilustração da árvore 1 com os pontos (X, Y) contidos em cada seção com a circunferência da suta, algoritmo 3DFin e método STAC em 72 ângulos.



Fonte: Elaborado pelo autor.

Figura 33 – Ilustração da árvore 1 com os pontos (X, Y) contidos em cada seção com a circunferência da suta, algoritmo 3DFin e método STAC em 120 ângulos.



Fonte: Elaborado pelo autor.

Em relação à resolução angular, a comparação entre 72 e 120 classes revelou que o aumento do detalhamento não resultou em ganhos de acurácia quando comparado. Pelo contrário, o RMSE para o método do ponto mínimo subiu de 5,94% (72 classes) para 6,3% (120 classes).

Este comportamento deve-se ao fato de que, ao reduzir o intervalo angular para 3° (120 classes), o número de pontos por classe diminuiu drasticamente. Em zonas de menor densidade ou oclusão, essa fragmentação resultou em classes com menos de dois pontos ou dominadas por ruídos, aumentando a dependência de interpolações e a instabilidade do contorno final. Desta forma, a resolução de 72 classes (5°) mostrou-se mais robusta e eficiente, pois, ao agrupar mais pontos por classe, o algoritmo minimiza o efeito de *outliers*.

A análise de eficiência (Tabela 7) evidencia um compromisso entre precisão e tempo de processamento operacional, onde o processamento no *software CloudCompare* (3DFin) foi mais rápido, com tempo médio de 3,6 segundos por árvore. Em contrapartida, a rotina metodológica executada no ambiente R demandou, em média, 23,3 segundos por árvore na parametrização de 72 ângulos e 29,3 segundos na de 120 ângulos.

O tempo de processamento alcançado pela rotina em R é viável para fins de inventário florestal e processamentos, oferecendo como contrapartida principal a flexibilidade de parametrização e um ganho substancial na redução do erro de estimativa diamétrica.

3.4 CONCLUSÃO

A rotina STAC demonstrou superioridade técnica ao 3DFin na reconstrução de fustes, apresentando maior aderência contorno do fuste e acurácia estatística frente à cubagem rigorosa tradicional.

A parametrização com 72 classes angulares e métrica de ponto mínimo atingiu o melhor desempenho quantitativo (RMSE de 5,94% e BIAS de 2,5%), sendo a mais indicada para assegurar a compatibilidade do método com medições de cubagem tradicional com uso da suta.

A análise qualitativa revelou que o STAC supera a suta ao descrever contornos reais e irregularidades da casca que são sistematicamente negligenciados pelos instrumentos manuais.

O método STAC é plenamente viável para inventários operacionais, oferecendo o equilíbrio ideal entre flexibilidade de parametrização e precisão biométrica na modelagem de fustes individuais.

REFERÊNCIAS

- BAILEY, G.; LI, Y.; MCKINNEY, N.; YODER, D.; WRIGHT, W.; HERRERO, H. Comparison of Ground Point Filtering Algorithms for High-Density Point Clouds Collected by Terrestrial LiDAR. **Remote Sensing**, v. 14, n. 19, p. 4776, 2022. DOI: <https://doi.org/10.3390/rs14194776>.
- BATER, C. W.; COOPS, N. C. Evaluating error associated with lidar-derived DEM interpolation. *Computers & Geosciences*, v. 35, n. 2, p. 289-300, 2009.
- BAUWENS, S.; BARTHOLOMEUS, H.; CALDERS, K.; LEJEUNE, P. Forest inventory with terrestrial LiDAR: A comparison of static and hand-held mobile laser scanning. **Forests**, Basel, v. 7, n. 6, p. 127, 2016.
- BERNARDI, Lucas Kröhling. **Estimativa de volume do tronco por reconstrução tridimensional e triangulação de contornos**. 2024. 76 f. Tese (Doutorado em Planejamento e Uso de Recursos Renováveis) – Centro de Ciências e Tecnologias para a Sustentabilidade, Universidade Federal de São Carlos, Sorocaba, 2024.
- CABO, C.; ORDÓÑEZ, C.; GARCÍA-CORTÉS, S.; MARTÍNEZ, J. An algorithm for automatic detection of pole-like street furniture objects from Mobile Laser Scanner point clouds. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 47-56, 2014. DOI: <https://doi.org/10.1016/j.isprsjprs.2013.10.008>.
- CABO, C.; ORDÓÑEZ, C.; LÓPEZ-SÁNCHEZ, C. A.; ARMESTO, J. Automatic dendrometry: Tree detection, tree height and diameter estimation using terrestrial laser scanning. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, p. 164-174, 2018. DOI: <https://doi.org/10.1016/j.jag.2018.01.011>.
- CAMPOS, João Carlos; LEITE, Henrique Garcia. *Mensuração florestal*. 5. ed. Viçosa, MG: UFV, 2017.
- ČERŇAVA, J.; MOKROŠ, M.; TUČEK, J.; ANTAL, M.; SLATKOVSKÁ, Z. Processing Chain for Estimation of Tree Diameter from GNSS-IMU-Based Mobile Laser Scanning Data. **Remote Sensing**, v. 11, n. 6, p. 615, 12 mar. 2019. DOI: <https://doi.org/10.3390/rs11060615>.

CHOI, H.; SONG, Y. Comparing tree structures derived among airborne, terrestrial and mobile LiDAR systems in urban parks. **GIScience & Remote Sensing**, v. 59, p. 843-860, 2022. Disponível em: <https://doi.org/10.1080/15481603.2022.2076381>. Acesso em: 8 maio 2026.

CLOUDCOMPARE. **CloudCompare**: 3D point cloud and mesh processing software. Open Source Project. Versão [Coloque a sua versão]. Disponível em: <https://www.cloudcompare.org/>.

DALLA CORTE, A. P.; SOUZA, D. V.; REX, F. E.; SANQUETTA, C. R.; et al. *Forest inventory with high-density UAV-LiDAR: Machine learning approaches for predicting individual tree attributes*. **Computers and Electronics in Agriculture**, v. 179, 105815, 2020.

DE CONTO, T. **TreeLS: Terrestrial Point Cloud Processing of Forest Data**. R package version 2.0. 2020. Disponível em: <https://cran.r-project.org/package=TreeLS>.

GREENVALLEY INTERNATIONAL. **LiGrip Lite O1 User Manual**. Berkeley: GreenValley International, 2023. Disponível em: <https://www.greenvalleyintl.com/>. Acesso em: 25 de fevereiro de 2026

HAGLOF SWEDEN. **MANTAX BLUE**. 2021. Disponível em: . Acesso em: 20 jan. 2026.
 HYYPPÄ, E.; KUKKO, A.; KAIJALUOTO, R.; WHITE, J. C.; WULDER, M. A.; PYÖRÄLÄ, J.; LIANG, X.; YU, X.; WANG, Y.; KAARTINEN, H.; VIRTANEN, J.-P.; HYYPPÄ, J. Accurate derivation of stem curve and volume using backpack mobile laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 161, p. 246-262, mar. 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.01.018>.

HAHSLER, M.; PIEKENBROCK, M.; DORAN, D. dbSCAN: Fast density-based clustering with R. **Journal of Statistical Software**, [S. l.], v. 91, n. 1, p. 1-30, 2019.

LAINO, D.; CABO, C.; PRENDES, C.; JANVIER, R.; ORDONEZ, C.; NIKONOVAS, T.; DOERR, S.; SANTIN, C. 3DFin: a software for automated 3D forest inventories from terrestrial point clouds. **Forestry: An International Journal of Forest Research**, v. 97, n. 4, p. 479–496, 2024.

LIANG, X.; HYYPPÄ, J.; KAARTINEN, H.; LEHTOMÄKI, M.; PYÖRÄLÄ, J.; PFEIFER, N.; HOLLAUS, M. International benchmarking of terrestrial laser scanning approaches for forest inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 144, p. 137-179, 2018.

LAVAGNOLI, G. L.; SILVA, G. F.; VIEIRA, G. C.; ALMEIDA, A. Q.; MENDONÇA, A. R.; SOARES, C. P. B. Estimation of cross-sectional areas of individual tree stems using remotely collected data. **Journal of Forestry Research**, v. 36, artigo 118, 2025. DOI: <https://doi.org/10.1007/s11676-025-01920-0>.

MCTAGUE, J. P.; WEISKITTEL, A. Evolution, history, and use of stem taper equations: a review of their development, application, and implementation. **Canadian Journal of Forest Research**, v. 51, n. 2, p. 210–235, 2021. Disponível em: <https://doi.org/10.1139/cjfr-2020-0326>

PEBESMA, E. Simple Features for R: Standardized Support for Spatial Vector Data. *The R Journal*, v. 10, n. 1, p. 439-446, 2018.

R CORE TEAM. **R**: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2024. Disponível em: <https://www.r-project.org/>. Acesso em: 21 fev. 2026.

ROUSSEL, J.-R.; AUTY, D.; COOPS, N. C.; TOMPALSKI, P.; GOODBODY, T. R. H.; MEADOR, A. S.; BOURDON, J.-F.; BOISSIEU, F. DE; ACHIM, A. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, Amsterdã, v. 251, p. 112061, 2020.

SCOLFORO, J. R. S. **Biometria florestal**: inventário florestal. Lavras: UFLA, 2025.

SOARES, C. P. B.; PAULA NETO, F. DE; SOUZA, A. L. DE. **Dendrometria e inventário florestal**. 2. ed. Viçosa, MG: Editora UFV, 2011.

THIERSCH, C. R.; SANTOS, C. J.; BERNARDI, L. K.; PÁDUA, F. A. de; THIERSCH, M. F. B. M. Uso de fotografias digitais como alternativa à fita e a suta na cubagem rigorosa.

Research, Society and Development, v. 10, n. 16, p. e62101623153, 2021. Disponível em: <https://doi.org/10.33448/rsd-v10i16.23153>

TOCKNER, A.; GOLLOB, C.; KRASSNITZER, R.; RITTER, T.; NOTHDURFT, A. Automatic tree crown segmentation using dense forest point clouds obtained by Personal Laser Scanning (PLS). **International Journal of Applied Earth Observation and Geoinformation**, v. 114, p. 103025, nov. 2022.

TRAN, Lan Thi Ngoc; KIM, Myeongjun; BANG, Hongseok; PARK, Byung Bae; CHOI, Sung-Min. Comparação de métodos de operação de LiDAR para inventário florestal em florestas de pinheiros coreanas. **Forests**, Basel, v. 16, n. 4, p. 643, 2025. DOI: <https://doi.org/10.3390/f16040643>.

VATANDAŞLAR, Can; ZEYBEK, *Mustafa*. Extraction of forest inventory parameters using handheld mobile laser scanning: a case study from Trabzon, Turkey. **Measurement**, v. 177, p. 109328, jun. 2021. DOI: <https://doi.org/10.1016/j.measurement.2021.109328>

WANG, D.; KANKARE, V.; PUTTONEN, E.; HOLLAUS, M.; PFEIFER, N. Reconstructing Stem Cross Section Shapes From Terrestrial Laser Scanning. **IEEE Geoscience and Remote Sensing Letters**, 2017. DOI: <https://doi.org/10.1109/LGRS.2016.2638738>.

WHITE, J. C.; COOPS, N. C.; WULDER, M. A.; VASTARANTA, M.; HILKER, T.; TOMPALSKI, P. Remote sensing technologies for enhancing forest inventories: A review. **Canadian Journal of Forest Research**, Ottawa, v. 46, n. 5, p. 619-646, 2016.

WITZMANN, S.; MATITZ, L.; GOLLOB, C.; RITTER, T.; KRAßNITZER, R.; TOCKNER, A.; STAMPFER, K.; NOTHDURFT, A. Accuracy and precision of stem cross-section modeling in 3D point clouds from TLS and caliper measurements for basal area estimation. **Remote Sensing**, v. 14, n. 8, p. 1923, 2022. DOI: <https://doi.org/10.3390/rs14081923>.

ZHANG, W. *et al.* An easy-to-use airborne LiDAR data filtering method based on cloth simulation. **Remote Sensing**, Basel, v. 8, n. 6, p. 501, 2016.

4 CONCLUSÕES GERAIS

O presente estudo validou o uso de tecnologias LiDAR no inventário de *Pinus elliottii*, por meio da integração de sensores LiDAR UAV e HMLS, viabilizando a contagem de árvores e cubagem rigorosa em nuvem de pontos tridimensionais.

No primeiro capítulo, o algoritmo de seccionamento transversal STAD provou ser superior aos métodos LMF e LI na detecção de árvores individuais. A contagem a partir das seções dos fustes com o agrupamento DBSCAN reduziu erros de omissão e comissão ocasionados pela densidade e sobreposição das copas. Assim, recomenda-se para trabalhos futuros a aplicação do método para a obtenção do censo em área total do povoamento.

No segundo capítulo, a definição de diâmetros por seção do fuste pelo método STAC foi mais aderente na representação do contorno em relação aos círculos projetados pela cubagem rigorosa tradicional com uso da suta. A parametrização com 72 classes angulares e o ponto mínimo apresentou maior proximidade com a suta, enquanto a mediana apresentou maior aderência em relação ao verdadeiro contorno de cada seção.

Desta forma, o uso do LiDAR MLS é recomendado para a cubagem rigorosa não destrutiva, apresentando-se como uma alternativa viável para a modelagem do fuste. No entanto, observou-se que a altura de coleta dos pontos do sensor atua como um fator limitante. Como recomendação para trabalhos futuros, sugere-se investigar se essa limitação pode ser contornada por meio do ajuste de modelos de afilamento e da aplicação de sensores com maior amplitude vertical.