

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

Avaliação da discrepância de modelos digitais de terreno obtidos por diferentes sensores LiDAR, algoritmos classificadores de ponto em solo e resolução espacial em um ambiente florestal

VINICIUS DA CUNHA AMARAL

BURI/SP

2025

VINICIUS DA CUNHA AMARAL

Avaliação da discrepância de modelos digitais de terreno obtidos por diferentes sensores LiDAR, algoritmos classificadores de ponto em solo e resolução espacial em um ambiente florestal

Trabalho de Conclusão de Curso apresentado como exigência parcial para a obtenção do grau de Bacharel em Engenharia Ambiental na Universidade Federal de São Carlos.

Orientação: Prof. Dr. Paulo Guilherme Molin

BURI/SP

2025

Amaral, Vinicius da Cunha

avaliação da discrepância de modelos digitais de terreno obtidos por diferentes sensores LiDAR, algoritmos classificadores de ponto em solo e resolução espacial em um ambiente florestal / Vinicius da Cunha Amaral -- 2025.
40f.

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

Orientador (a): Paulo Guilherme Molin

Banca Examinadora: Andre Marcondes Toledo, Giulio Brossi Santoro

Bibliografia

1. Geotecnologias; . 2. Modelos Digitais de Terreno; . 3. Escaneamento a Laser.. I. Amaral, Vinicius da Cunha. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)


DADOS FORNECIDOS PELO AUTOR

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


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

Folha de Aprovação


Assinatura dos membros da comissão examinadora que avaliou e aprovou a Defesa de Trabalho de Conclusão de Curso do(a) candidato(a) Vinicius da Cunha Amaral, realizada em 19/11/2025:

Documento assinado digitalmente
 PAULO GUILHERME MOLIN
Data: 24/11/2025 16:26:51-0300
Verifique em <https://validar.iti.gov.br>

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

Documento assinado digitalmente
 ANDRE MARCONDES ANDRADE TOLEDO
Data: 26/11/2025 12:18:17-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Andre Marcondes Toledo
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente
 GIULIO BROSSI SANTORO
Data: 24/11/2025 16:35:47-0300
Verifique em <https://validar.iti.gov.br>

Me. Giulio Brossi Santoro
Esalq / Universidade de São Paulo

AGRADECIMENTOS

Nessa seção, eu registro a minha eterna gratidão aos meus pais (Claudio Cândido do Amaral e Maria Helena da Cunha Freitas) que trabalharam e lutaram desde o dia que eu nasci pela minha educação. Também agradeço a eles, a minha avó (Mercedia Amaral) e ao meu irmão (Arthur da Cunha Amaral) por toda a preocupação, amor, momentos e cuidado que tiveram comigo. Farei tudo o que eu puder para compensá-los até o meu último dia.

Morar longe de casa tem seu preço e eu tenho certeza que esse teria sido bem mais caro se eu não tivesse feito a escolha de morar na República VamoET. Lugar em que vivi durante toda a minha graduação e encontrei fraternidade, parceria e felicidade. Onde pude aprender diversos tipos de cultura, valores e conhecer pessoas.

Guardarei por toda minha vida as memórias em que construí no meu segundo lar e na UFSCar Lagoa do Sino. Em especial: Cirineo (Eduardo Cirineo), Achado (João Camargo), Sumido (Guilherme Pereira), Raja (Raja Yamma), Dimenó (Vinicius Giovanni), Roddy (Lucca Cestari), Barbatana (Angelo Furquim), Arthurzão (Arthur Santos), Leozão (Leonardo Stanckevicius), Karlinha (Guilherme Cunto), Rato (Marcelo Quaiotti), Tay (Taynara Beaut), Sofia (Sofia Galasso) e demais amigos não aqui citados.

Ao Centro de Pesquisas e Extensão em Geotecnologias (CePE-Geo), que forneceu todo o ambiente e estrutura para o meu desenvolvimento e além disso, apresentou as duas grandes áreas que guiaram minha carreira até o momento e com certeza guiará pelos próximos anos, que é o geoprocessamento/sensoriamento remoto e as ciências florestais. Em especial: José Matheus, Vinicius Moura, Giovana Andrade, Giulio Santoro, Patrick Fernandes, José Roberto Kill, Mel, Paulo Guilherme Molin e André Toledo.

Ao projeto Estratégia Mata Atlântica (Processo nº 2021/11940-0) da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil que apoiou a realização do projeto. Por fim, a Bracell empresa onde fiz meu estágio em geoprocessamento, forneceu estrutura para essa pesquisa e onde me desenvolvi exponencialmente. Em especial: Daniel Batista, Júlio Guimarães, Tainã Scarano, Aline Vergani, Marieli Ruza, Ricardo Souto, Wagner Paz, Gabriel Lee, Gabriel Valério, Gabriel Pinto, João Eduardo, Amanda, João Victor, João Marcelo, Carla Chiles, João Rebessi, Dimas e Emerson.

Vinicius da Cunha Amaral

RESUMO

O presente trabalho teve como objetivo avaliar a discrepância entre Modelos Digitais de Terreno (MDT) gerados a partir de diferentes sensores LiDAR aerotransportados (Zenmuse L1 e L2), algoritmos classificadores de ponto em solo e resoluções espaciais, em um ambiente florestal localizado no município de Angatuba (SP). Foram realizados voos com Aeronaves Remotamente Pilotadas (ARP) equipadas com sensores LiDAR L1 e L2, sob as mesmas condições operacionais, resultando em nuvens de pontos processadas pelos algoritmos Cloth Simulation Filter (CSF), Progressive Morphological Filter (PMF) e Curvature Smoothing Surface (CSS). O processamento foi conduzido nos ambientes RStudio e LiDAR360, onde foram gerados os Modelos Digitais de Terreno (MDT) correspondentes às combinações entre sensores, algoritmos e resoluções espaciais, totalizando dezoito produtos derivados nas resoluções de 0,1 m, 0,5 m e 1 m. As análises estatísticas foram realizadas com base em 300 parcelas de 20 × 20 m, abrangendo 14,93% da área de estudo. Os resultados dos testes de Wilcoxon demonstraram diferenças estatisticamente significativas entre os sensores L1 e L2 ($p < 0,01$) para todos os algoritmos, com tamanhos de efeito classificados por Cohen, na classe pequenos ($d \approx 0,10-0,18$), indicando variações sutis entre os níveis. Entre os algoritmos, observou-se que o CSS gerou superfícies mais suavizadas, apresentando diferenças moderadas a altas em relação ao CSF ($p < 10^{-38}$; $d = 0,44-0,53$) e ao PMF ($p < 10^{-45}$; $d = 0,67-1,57$). O CSF e o PMF apresentaram alta similaridade ($p < 10^{-33}$; $d = 0,20-0,25$). As comparações entre resoluções espaciais não indicaram diferenças significativas ($p > 0,05$; $d < 0,15$), demonstrando estabilidade dos métodos frente à variação de resolução.

Palavras-chave: Geotecnologias; Modelos Digitais de Elevação; Escaneamento a Laser.

ABSTRACT

This study aimed to evaluate the discrepancy among Digital Terrain Models (DTMs) generated from different airborne LiDAR sensors (Zenmuse L1 and L2), ground point classification algorithms, and spatial resolutions in a forested environment located in Angatuba, São Paulo State, Brazil. Flights were carried out using Remotely Piloted Aircraft Systems (RPAS) equipped with LiDAR L1 and L2 sensors under identical operational conditions, resulting in point clouds processed by the *Cloth Simulation Filter* (CSF), *Progressive Morphological Filter* (PMF), and *Curvature Smoothing Surface* (CSS) algorithms. Data processing was performed in RStudio and LiDAR360, generating Digital Terrain Models corresponding to each combination of sensor, algorithm, and spatial resolution, totaling eighteen derived products at 0.1 m, 0.5 m, and 1.0 m resolutions. Statistical analyses were based on 300 plots of 20×20 m, representing 14.93% of the study area. The Wilcoxon tests indicated statistically significant differences between L1 and L2 sensors ($p < 0.01$) for all algorithms, with effect sizes classified as small ($d \approx 0.10$ – 0.18), suggesting subtle variations between platforms. Among the algorithms, CSS produced smoother surfaces, showing moderate to large differences compared to CSF ($p < 10^{-38}$; $d = 0.44$ – 0.53) and PMF ($p < 10^{-45}$; $d = 0.67$ – 1.57), while CSF and PMF exhibited high similarity ($p < 10^{-33}$; $d = 0.20$ – 0.25). Comparisons among spatial resolutions revealed no significant differences ($p > 0.05$; $d < 0.15$), demonstrating the stability of the methods across scales.

Keywords: Geotechnologies; Digital Elevation Models; Laser Scanner.

LISTA DE FIGURAS

Figura 1 – Mapa para representação da disposição das diferentes constelações de satélites no céu em um determinado momento.	16
Figura 2 – Representação dos pontos classificados como pontos em solo e pontos não solo.	20
Figura 3 - Mapa do local e uso e ocupação da área experimental	22
Figura 4 - Mapa com as classes de declividade EMBRAPA da área experimental	23
Figura 5 - Fluxograma do processamento das nuvens de ponto LiDAR	26
Figura 6 - Mapa com as parcelas do estudo piloto alocada	28
Figura 7 – Gráfico com o número de parcelas necessárias para obtenção de poder estatístico de 80, 90 e 95%	29
Figura 8 - Mapa com as parcelas do estudo piloto alocada	30
Figura 9 – Gráfico de colunas com as diferenças médias e medianas entre pares de comparação no nível de sensor.	35
Figura 10 - Diferentes <i>Hillshade</i> gerados em uma área de preservação permanente por diferentes algoritmos e sensores.	36

LISTA DE TABELAS

Tabela 1 – Pacotes utilizados neste estudo para o processamento da nuvem de pontos, classificação de pontos em solo e exportação dos MDT.	24
Tabela 2 – Bibliotecas utilizadas em Python para as ferramentas de geoprocessamento, amostragem, aquisição dos dados e análises estatísticas.	24
Tabela 3 - Parâmetros de voo empregados no levantamento de dados LiDAR.	26
Tabela 4 – Valores de d por classes	31
Tabela 5 – Valores obtidos com os testes estatísticos de Wilcoxon e Cohen para a comparação da discrepância entre os sensores LiDAR L1 e L2.	32
Tabela 6 – Valores obtidos com os testes estatísticos de Wilcoxon e Cohen para a comparação da discrepância entre os algoritmos CSS, CSF e PMF.	33
Tabela 7 – Valores obtidos com os testes estatísticos de Wilcoxon e Cohen para a comparação da discrepância entre as resoluções 0,10m, 0,50m e 1,00m	34
Tabela 8 – Estatísticas descritivas da comparação entre algoritmos na resolução de 1m.	36

LISTA DE SIGLAS

3D – Três Dimensões

AGB – *Above Ground Biomass* (Biomassa acima do solo)

ArcGIS – *Geographic Information System* (Sistema de Informação Geográfica) da Esri

ATIN – *Adaptive Triangulated Irregular Network*

CHM – *Canopy Height Model* (Modelo de Altura do Dossel)

CSF – *Cloth Simulation Filter*

CSS – *Curvature Smoothing Surface*

DJI – Da-Jiang Innovations (fabricante de drones)

GNSS – *Global Navigation Satellite System* (Sistema Global de Navegação por Satélite)

GPS – *Global Positioning System* (Sistema de Posicionamento Global)

IMU – *Inertial Measurement Unit* (Unidade de Medição Inercial)

INS – *Inertial Navigation System* (Sistema de Navegação Inercial)

LAS – *LiDAR Data File Format* (Formato de arquivo de dados LiDAR)

LASfile – Arquivo no formato LAS

LiDAR – *Light Detection and Ranging*

MDE – Modelo Digital de Elevação

MDS – Modelo Digital de Superfície

MDT – Modelo Digital de Terreno

PMF – *Progressive Morphological Filter*

R – Linguagem de Programação R

RPA – *Remotely Piloted Aircraft* (Aeronave Remotamente Pilotada)

RTK – *Real Time Kinematic* (Cinemático em Tempo Real)

RTX – *Real-Time eXtended* (Método Trimble CenterPoint RTX)

SAR – *Synthetic Aperture Radar* (Radar de Abertura Sintética)

SR – Sensoriamento Remoto

SVLA – Sistema de Varredura a LASER Aerotransportado

TIN – *Triangular Irregular Network* (Rede Triangular Irregular)

UAV – *Unmanned Aerial Vehicle* (Veículo Aéreo Não Tripulado)

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVO	15
2.1	Objetivo geral:	15
2.2	Objetivos específicos:	15
3	FUNDAMENTAÇÃO TEÓRICA	16
3.1	Sistema Global de Navegação por Satélite – GNSS (do inglês – <i>Global Navigation Satellite System</i>)	16
3.2	Sistema de Navegação Inercial – INS (do inglês: <i>Inertial Navigation System</i>)	18
3.3	Sistema de Varredura a LASER aerotransportado (SVLA) e fatores que prejudicam a qualidade de uma nuvem de pontos.	Erro! Indicador não definido.
3.4	LiDAR: Algoritmos classificadores de ponto em solo	20
4	MATERIAIS E MÉTODOS	22
4.1	Area de Estudo	22
4.2	Equipamentos, softwares e bibliotecas utilizadas.	23
4.3	Aquisição dos Dados LiDAR	25
4.4	Processamento da nuvem de pontos LiDAR e a geração dos MDT	26
4.5	Delimitação de tamanho amostral e abordagem estatística a ser realizada	27
4.6	Análise da variância entre os difentes sensores, algoritmos e resoluções	29
5	RESULTADOS E DISCUSSÃO	32
6	CONCLUSÃO	38
	REFERÊNCIAS	39

1 INTRODUÇÃO

O avanço das ações antrópicas sobre o meio ambiente e ao alto consumo de combustíveis fósseis e materiais derivados do petróleo, proporcionaram um cenário de aquecimento global. Como resposta a esse panorama, a Organização das Nações Unidas (ONU) declarou o período de 2021 a 2030 como a Década da Restauração dos Ecossistemas, com o objetivo de mitigar os impactos negativos causados pelas mudanças climáticas (Chazdon e Brancalion, 2019). Diante desse contexto, as florestas ganham destaque por serem um dos mais importantes sumidouros de carbono da atmosfera, uma vez que seu processo natural consiste na remoção do CO₂ do ar e na fixação desse carbono em galhos e troncos, que fazem parte da biomassa florestal acima do solo (*Above Ground Biomass – AGB*) (Hobbie e Grimm, 2020).

Nesse cenário, não apenas as florestas restauradas ou nativas contribuem para as ações climáticas, as florestas plantadas de eucalipto (*Eucalyptus spp.*) também se apresentam como uma alternativa para o sequestro de carbono, tratando-se de uma espécie majoritariamente cultivada para a produção de papel, celulose e energia, que possui rápido crescimento e grande importância econômica (Leite, 2020). Ao gerir esses ativos florestais, o monitoramento florestal em larga escala é um desafio devido ao seu custo, complexidade e riscos, e por esse motivo, as técnicas de Sensoriamento Remoto (SR) tem sido praticada por instituições, organizações e empresas que trabalham com florestas plantadas (Corte, 2022).

Segundo a Sociedade Internacional de Fotogrametria e Sensoriamento Remoto, essas tecnologias constituem ciências, artes e técnicas que possibilitam a obtenção de informações confiáveis de áreas remotamente (Sinégalia, 2024), que por sua vez podem englobar o uso de sensores ativos e passivos, onde os passivos são os que dependem da radiação solar, produzindo imagens e produtos como índices de reflectância, vigor de vegetação e análises que se limitam a duas dimensões, limitando as aplicações no eixo vertical (Corte *et al.*, 2022).

Já os sensores ativos, ganham destaque em relação aos passivos, pois não dependem de fatores externos a sua funcionalidade, visto que, esses equipamentos emitem sua fonte de energia, sejam elas oriundas de ondas de rádio ou LASER (*Light Amplification by Stimulated Emission of Radiation*), que é o contexto que tange a funcionalidade dos sensores LiDAR (*Light Detection and Ranging*), que possibilita a geração de modelos tridimensionais, cálculos de volume, biomassa e estudos da estrutura vertical de florestas (Corte *et al.*, 2022).

O sensor LiDAR emite pulsos de LASER em direção ao solo e mede o tempo de retorno desses pulsos, permitindo a geração de uma nuvem de pontos altimétrica que representa as características físicas do terreno e da vegetação (Kahraman e Bacher, 2021). Tais nuvens de pontos, podem ser processadas por diferentes parâmetros, softwares e métodos, com a finalidade de gerar um Modelo Digital de Terreno (MDT) e um Modelo Digital de Superfície (MDS), que são produtos fundamentais para o monitoramento florestal e o planejamento do manejo da área, uma vez que fornecem as cotas altimétricas do solo e da superfície da área, onde por meio de ferramentas de geoprocessamento, é possível calcular a diferença desses produtos, que resultam um modelo de altura de dossel florestal (CHM - *Canopy Height Model*), que é composto pela altura da copa de cada indivíduo arbóreo, e possibilita o monitoramento da densidade da vegetação, bem como a estimativa de biomassa, carbono estocado e volume de madeira (Ferreira, 2024).

No entanto, é sólido que o aerolevanteamento com sensores LiDAR dependem de um receptor geodésico com sinal do Sistema Global de Navegação por Satélite (Global Navigation Satellite System – GNSS), uma ciência onde fatores naturais comprometem a qualidade do sinal entre satélites e receptores e, conseqüentemente, afeta a acurácia posicional (Alves, 2013). Além disso, o LiDAR encontra dificuldades ao trabalhar em áreas de alta densidade de vegetação e cenários de declividade, que são situações que correspondem a florestas nativas e de atividades silviculturais.

Considerando esses desafios operacionais e a existência de uma ampla variedade de parâmetros, algoritmos e métodos de pós-processamento para nuvens de pontos, justifica-se a realização deste estudo. O presente trabalho teve como objetivo avaliar a discrepância entre produtos gerados por diferentes sensores LiDAR (especificamente os modelos L1 e L2) em distintos cenários de vegetação e relevo. A metodologia consistiu na execução de voos aerotransportados com os referidos sensores, no processamento dos dados brutos para a geração de Modelos Digitais de Terreno (MDT), e na aplicação de análises estatísticas para quantificar as diferenças atribuíveis aos sensores, aos algoritmos de classificação e às resoluções espaciais empregadas.

2 OBJETIVO

2.1 Objetivo geral:

Avaliar a similiaridade entre modelos digitais de terreno obtidos por diferentes sensores LiDAR a bordo de sistemas de aeronaves remotamente pilotadas e algoritmos classificadores de ponto em solo.

2.2 Objetivos específicos:


- Realizar coleta de dados LiDAR L1 e L2 acoplados em uma aeronave remotamente pilotada sobre condições e parâmetros semelhantes;
- Classificar os pontos em solos de ambas bases de dados com três algoritmos distintos;
- Gerar modelos digitais de terreno para os três algoritmos testados em cada nuvem de pontos e em diferentes resoluções;
- Quantificar a discrepância entre modelos digitais de terreno obtidos com os algoritmos classificadores *Cloth Simulation Filter* (CSF), *Progressive Morphological Filter* (PMF) e *Curvature Smoothing Surface* (CSS);
- Avaliar a variabilidade dos modelos digitais de terreno entre sensores L1 e L2 e em diferentes resoluções espaciais de 0,10 metros (m), 0,50m e 1,00m.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Sistema Global de Navegação por Satélite

O Sistema Global de Navegação por Satélite - GNSS (do inglês - *Global Navigation Satellite System*), é o sistema que proporciona a localização de qualquer ponto na superfície terrestre, desde que exista no mínimo 4 satélites acima do local. Trata-se de uma tecnologia que foi desenvolvida por ideais militares, mas atualmente é utilizada em várias áreas do conhecimento e desde o final de maio de 2022 estão disponíveis mais de 130 satélites operacionais, das diferentes constelações já existentes (Jin, 2022). As principais representadas na Figura 1 sendo: GPS (do inglês: *Global Positioning System*), GLONASS (do Russo: *Global'naya Navigatsionnaya Sputnikovaya System*), Galileo de origem Europeia e por fim, o sistema chinês: Beidou/Compass (MÔNICO, 2008).

Figura 1 – Mapa para representação da disposição das diferentes constelações de satélites no céu em um determinado momento.



Fonte: Autoria Própria, 2025

Em constante ascensão, o GNSS é aplicado em diversas áreas do conhecimento, como a geodésia, topografia, navegação terrestre, marítima e aérea e no aerolevanteamento de dados com Sistemas de Aeronaves Remotamente Pilotadas (RPAS - do inglês, Remotely Piloted Aircraft System). Esses dados podem variar de imagens georreferenciadas de alta resolução de uma área, até um levantamento com LiDAR (Gomes, 2022) De forma geral, esses sistemas fornecem as coordenadas horizontais e vertical de um determinado ponto, em qualquer horário e local do globo terrestre. Esse processo se dá através da transmissão de sinais para os

receptores, previamente referenciados a elipsoides terrestres, assim, possibilitando a realização de cálculos para determinada zona (fuso) do elipsoide.

A fim de êxito da realização do que esses sistemas propõem, acontece a divisão deles em três segmentos, que em conjunto conseguem determinar as coordenadas do local. O primeiro sendo o segmento espacial se refere às constelações em órbita na terra, os quais transmitem informações que receptores utilizam para determinar posicionamentos. O segundo segmento, intitulado segmento de controle, pode ser compreendido pelas estações de controle terrestre, que são estrategicamente posicionadas e realizam o monitoramento da distribuição de satélites em órbita e por fim, o terceiro segmento, que é o de usuário e engloba os receptores GNSS, os quais são programados para rastreamento e interação com os dados fornecidos pelos satélites (Timbó, 2000).

Em conjunto, as três segmentações permitem a obtenção das observáveis GNSS, que são divididas em duas formas, a primeira sendo a da Pseudodistância, que é a situação em que os receptores trabalham com a medição da diferença de tempo que um sinal emitido por um satélite é recebido pelo equipamento. Dessa forma possibilitando a determinação da distância de um satélite específico para uma estação escolhida (Segantine, 1998), no entanto, existem fatores que afetam a qualidade posicional de um levantamento de dados GNSS, um desses fatores, é o uso de relógios atômicos que ficam alocados nos satélites e assim, sujeitos a inúmeras anomalias, como radiação, temperatura, envelhecimento e até mesmo uma parada súbita de funcionamento (Rodrigues, 2017).

Além disso, ainda existem diferenças de sincronização entre o tempo que é transmitido pelo satélite e o tempo medido pelo receptor, o que ocasiona erros de posicionamento (Segantine, 1998). Outra fonte de erro, provém do trânsito do sinal pela Troposfera e Ionosfera, que são camadas atmosféricas que contém uma alta densidade átomos neutros e moléculas livres, que afetam a propagação do sinal, e ocasionam a refração do sinal, independente da frequência dos sinais (Teunissen & Kleusberg, 1998). Sendo assim, afetam o código, a fase da onda portadora e consequentemente o cálculo da emissão e recebimento do sinal.

Diante dos diferentes fatores que influenciam a qualidade posicional de levantamentos com GNSS, existem diversos métodos de coleta e processamento de dados para mitigação dos erros de posicionamento. Uma dessas técnicas de coleta e processamento, é o *Trimble Centerpoint RTX*, que foi desenvolvido pela Trimble em 2011 e é um método que possibilita o posicionamento em tempo real com correções auxiliadas por algoritmos e dados

de centrais ligadas a estações de redes distribuídas globalmente. Nesses centros, a tecnologia *CenterPoint RTX* extrai a precisão do satélite, estimativa do erro de relógio, ambiguidade e efeito dos fatores atmosféricos e ajustam a coordenada levantada em campo (İlçi, 2019). Um outro método, é o cinemático em tempo real (RTK, sigla do inglês, *Real Time Kinematic*) que consiste no uso de dois receptores, um que é instalado em um ponto conhecido, denominado *base* e o outro é móvel e conhecido como *rover*. A funcionalidade baseia-se no princípio da correção diferencial em tempo real, onde via rádio, a *base* corrige o posicionamento do *rover*, refinando os resultados e minimizando as interferências do ambiente no receptor móvel (Rocha, 2018).

3.2 Sistema de Navegação Inercial – INS (do inglês: *Inertial Navigation System*)

As técnicas para determinar com precisão a posição e a orientação de um RPAS, passam pelo sistema de navegação inercial (do inglês, *Inertial Navigation System* — INS), que se trata de um sistema que não depende de outros fatores, como infraestrutura e fontes externas de informação (El-Sheimy e Youssef, 2020). Isso ocorre porque sua funcionalidade baseia-se nas leis de Newton, tendo em sua composição uma unidade de medição inercial (do inglês, *Inertial Measurement Unit* — IMU), que abriga sensores giroscópios, responsáveis por medir as taxas de rotação angulares, e acelerômetros, que medem a aceleração linear (El-Sheimy e Youssef, 2020).

A execução do INS é, em essência, um processo matemático integrado, no qual, a partir de um ponto de origem com coordenadas horizontais e verticais conhecidas, o sistema processa as medições obtidas pelos sensores do IMU e realiza correções dos efeitos causados pela gravidade e rotação (El-Sheimy e Youssef, 2020). Dessa forma, obtém com precisão as coordenadas afins de posicionamento e navegação, uma vez em que os acelerômetros são utilizados para obtenção da velocidade e uma integração é realizada para definir a posição atual e as próximas mudanças de orientação e altitude são detectadas pelo giroscópio.

Nesse contexto, a composição do INS em RPAS é fundamental para garantir a estabilidade da aeronave e a continuidade das estimativas de posição e atitude ao longo da missão, especialmente em situações de degradação ou perda temporária do sinal GNSS. A elevada taxa de amostragem dos sensores inerciais permite ao sistema fornecer informações contínuas de navegação, essenciais para o controle de voo e para a execução de trajetórias previamente planejadas. Além disso, a integração do INS com outros sistemas de

posicionamento possibilita a correção dos erros acumulados no processo de integração inercial, ampliando a confiabilidade das soluções de navegação.

3.3 Escaneamento Laser Aerotransportado (ALS – do inglês, Airbone Laser Scanning)

Por meio de um ALS, é possível gerar uma nuvem de pontos com coordenadas nas três dimensões (3D), onde a coordenada vertical é gerada por meio da emissão de um pulso LASER na direção da superfície e um espelho de varredura. Onde a interação do pulso com a superfície e o espelho de varredura faz com que parte da energia emitida no pulso seja reconhecida e com base nisso, calculado a distância entre o sensor e o objeto por meio da inferência do intervalo de tempo entre a emissão e retorno do LASER (Dalmolin e Santos, 2003).

A Equação (1) explora esse conceito, de forma que a determinação de distância (D) entre o sensor e o alvo, é calculada a partir do produto da constante de velocidade da luz (c , aproximadamente $300 \cdot 10^3$ km/s) pela metade da variação de tempo $\left(\frac{\Delta t}{2}\right)$ entre a emissão e o retorno do pulso LASER (Wehr e Lohr, 1999).

$$D = c \left(\frac{\Delta t}{2}\right) \quad \text{Equação (1)}$$

Já as coordenadas horizontais são levantadas por meio da integração das técnicas de posicionamento (GNSS) e de orientação (INS). Em um SVLA, essa combinação de técnicas é fundamental, onde uma técnica complementa a outra (Kraus, 2007; Schimalesky e Centeno, 2008). No entanto, não se trata de um sistema perfeito, uma nuvem de pontos LiDAR está passível de erros aleatórios e sistemáticos, os quais podem vir de diversos fatores, sendo os principais causadores, a influência dos sistemas de posicionamento e orientação (Integração do GNSS e INSS), as características da superfície e as condições da vegetação do local (Habib *et al.*, 2008 *apud* Komazaki, 2021). Isso pois é conhecido que existem fatores que naturalmente afetam a qualidade posicional de receptores GNSS e que o INS está sujeito a desalinhamentos e à deriva giroscópica ao longo do tempo, o que afeta diretamente os cálculos no sentido da direção e orientação, registro de deslocamento e velocidade (Habib *et al.*, 2008 *apud* Komazaki, 2021).

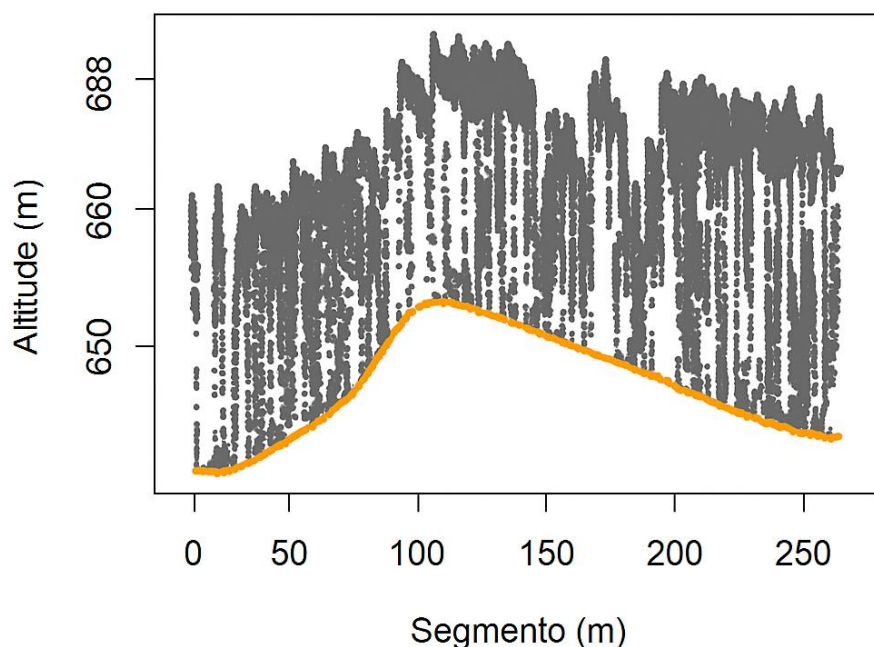
Além disso, a qualidade de uma nuvem em um ambiente florestal, também depende do procedimento da aquisição dos dados. Isso pois, erros também podem advir durante esse processo, como uma falha na montagem, erro na calibração do sistema de varredura a LASER,

parâmetros de voo mal planejados e até mesmo uma situação externa, como a de condições climáticas (Bang, 2010).

3.4 LiDAR: Algoritmos classificadores de ponto em solo

Para as aplicações florestais, a distinção dos pontos do solo daqueles que não representam o solo, como folhas, galhos ou qualquer outra estrutura é uma etapa preliminar e fundamental no processamento da nuvem de pontos LiDAR (Nord-Larsen e Riis-Nielsen, 2010). Essa separação pode ser observada pela figura 2, que diferencia uma plantação de eucalipto (em cinza) da superfície do terreno (em laranja).

Figura 2 – Representação dos pontos classificados como pontos em solo e pontos não solo.



Fonte: Autoria própria, 2025.

Essa classificação pode ser realizada por diferentes algoritmos de filtragem e interpolação, com o objetivo de representar de forma contínua e precisa a superfície terrestre. Esse processo vem se tornando cada vez mais avançado e automatizado, no entanto, esses algoritmos não foram desenvolvidos especificamente para lidar com a complexidade dos terrenos onde se situam as florestas, nem com a alta densidade de vegetação dessas áreas (Pingel *et al.*, 2013).

Um desses algoritmos é o *Curvature Smoothing Surface (CSS)* que está inserido no método *Adaptive Triangulated Irregular Network (ATIN)*, que tem como objetivo, refinar e suavizar a superfície do terreno a partir da nuvem de pontos LiDAR, onde o seu princípio de funcionamento é baseado em iterações adaptativas de triangulação, nas quais são inicialmente selecionados potenciais pontos em solo, geralmente associados às menores altitudes da nuvem, que são progressivamente avaliados e incorporados à triangulação com base em critérios geométricos e topográficos, como distância vertical, ângulo e continuidade da superfície. Essa abordagem iterativa permite uma adaptação dinâmica da malha às variações do relevo, contribuindo para a redução de ruídos e artefatos associados a vegetação, edificações ou objetos elevados. Como resultado, obtém-se uma representação mais fiel e suavizada da superfície terrestre, especialmente em áreas com topografia complexa (Zheng et al., 2024).

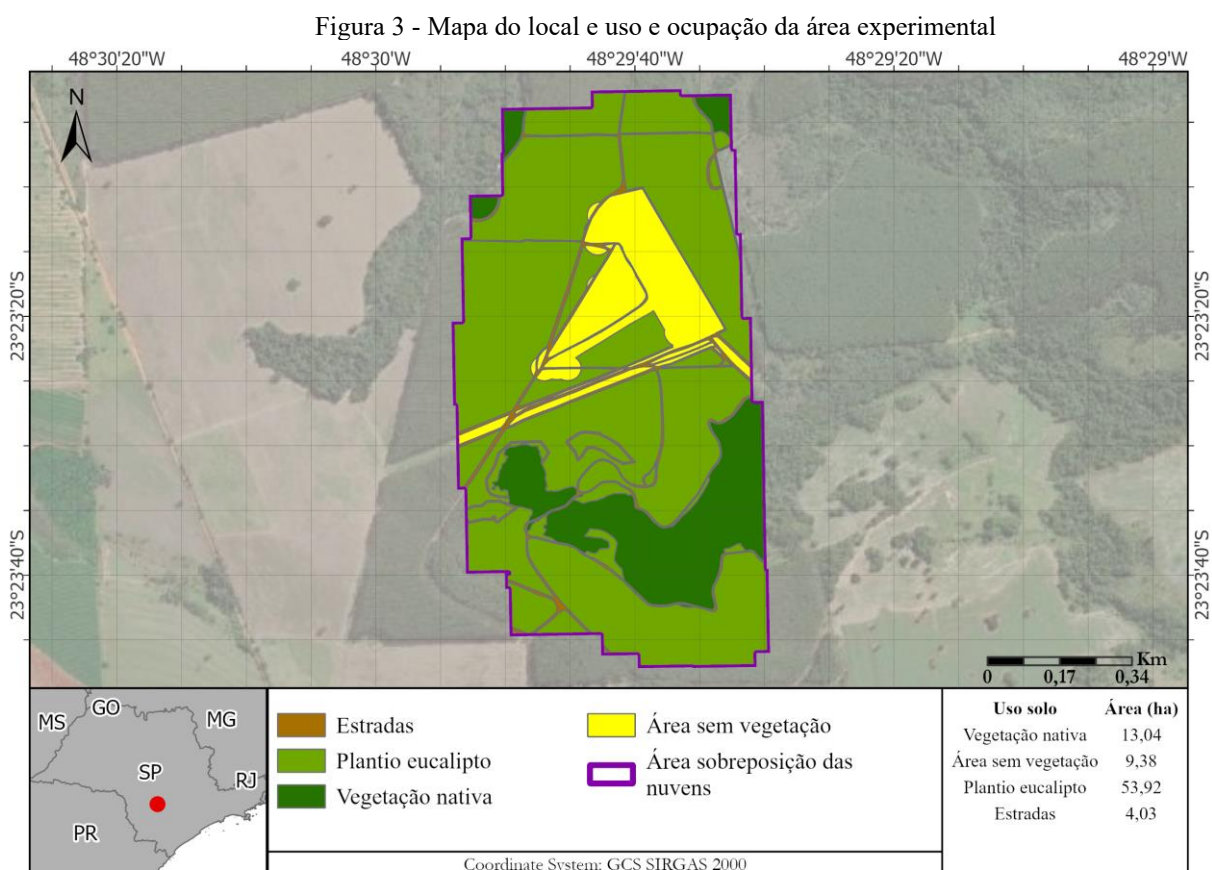
Outro algoritmo é o *Cloth Simulation Filter (CSF)*, que é inspirado em princípios físicos de simulação para classificar pontos em solo da nuvem de pontos, processo que consiste em simular a queda de uma malha flexível (*Cloth*) sobre a nuvem de pontos invertida. Onde progressivamente a malha se ajusta aos pontos mais baixos e formam uma superfície aproximada do terreno e com base em limiares de distância, o algoritmo classifica o ponto como em solo ou não solo, de forma que é possível configurar esses valores de limite de forma mais conservadora ou flexível, o que torna o CSF eficiente em áreas com variação gradual de relevo (Bailey et al., 2022).

O *Progressive Morphological Filter (PMF)* é outro algoritmo, que se baseia em operações morfológicas matemáticas aplicadas de forma progressiva para a filtragem dos pontos de solo. O algoritmo divide a área de estudo em quadrantes e aplica operadores morfológicos, como erosão e dilatação, considerando limiares de altura e inclinação entre os pontos de maneira iterativa, iniciando com janelas de menor dimensão, que capturam detalhes locais, e aumentam gradualmente o tamanho das janelas até abranger toda a área de estudo. Em cada iteração, pontos que excedem os limiares definidos são classificados como não solo e removidos progressivamente. Essa abordagem permite uma separação eficaz entre terreno e objetos elevados, sendo especialmente adequada para áreas urbanas ou com vegetação esparsa, embora possa apresentar limitações em terrenos muito acidentados (Štroner et al., 2021).

4 MATERIAIS E MÉTODOS

4.1 Área de Estudo

A área experimental é localizada em uma propriedade rural no município de Angatuba, região sudoeste do Estado de São Paulo. O clima dessa área, segundo a classificação de Köppen, é do tipo Cwa, caracterizado por verões quentes e chuvosos e invernos secos e amenos, onde a precipitação média anual da região é de cerca de 1.300 mm e a temperatura média gira em torno de 21 °C, tornando se um atrativo para espécies florestais. A escolha da área baseou-se nos fatores que guiam a problemática alvo deste trabalho, como a situação de uso e cobertura do solo que foi mapeada por fotointerpretação e representada pela Figura 3.



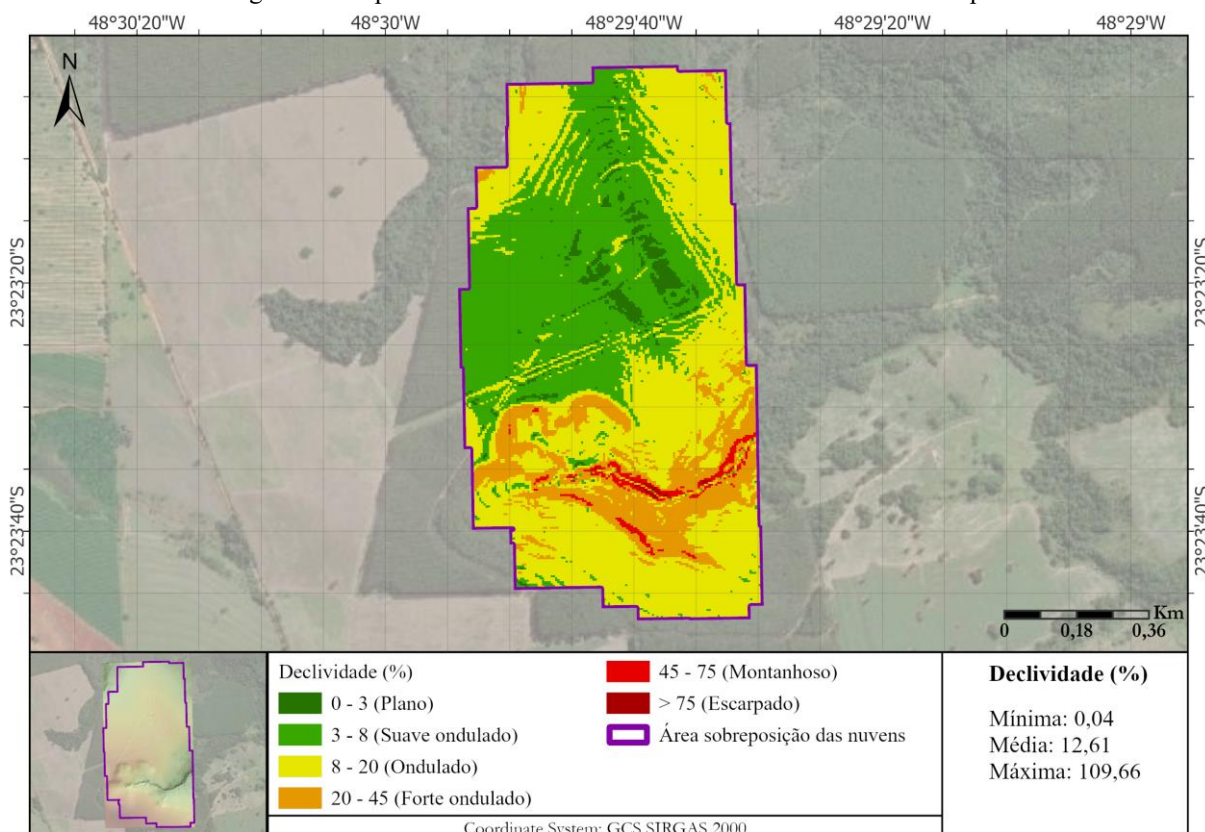
Fonte: Autoria própria, 2025.

Onde a área experimental abrange 80,37 hectares (ha) e diversas situações de uso e cobertura, como 53,92ha de plantio de eucalipto, 13,04ha de vegetação nativa e um fragmento desprovido de cobertura vegetal de 13,41ha, o qual inclui estradas e uma área de agricultura pós colheita.

Um outro fator levado em consideração, foi o relevo do local, que está representado pela Figura 4. Onde foi extraído a declividade de um MDT, LiDAR na resolução de 1 metro

rearranjado para 5 pelo software ArcGIS Pro e representado pelas classes de declividade definidas pela Embrapa. No mapa, é possível observar a predominância do relevo ondulado e suave ondulado, mas também que existe fragmentos de áreas montanhosas e de relevo forte ondulado. O que no final, contempla uma área com uma diversidade de situações de relevo.

Figura 4 - Mapa com as classes de declividade EMBRAPA da área experimental



Fonte: Autoria própria, 2025.

4.2 Equipamentos, softwares e bibliotecas utilizadas.

Dos dispositivos necessários para a execução do trabalho, foram utilizados um drone multirrotor da marca DJI, com o nome “DJI Matrice 350 RTK”, com dois sensores LiDAR acoplados, no caso se trata dos sensores Zenmuse L1 e Zenmuse L2, que se diferenciam pela versão e capacidade de registro de número de retornos. Também receptores GNSS para fins de posicionamento e navegação, no caso o receptor “D-RTK 2” e o “Spectra Precision SP-60”.

Quanto aos softwares, o primeiro utilizado foi o *DJI Terra*, destinado ao pré-processamento dos dados brutos capturados pelos sensores LiDAR, sendo responsável pela reconstrução das nuvens de pontos em formato *LASfile*, que serviram como entrada para toda a metodologia desenvolvida.

Foi adotado o software *LiDAR360*, que se trata de um programa licenciado da empresa Green Valley International, para um dos processamentos da nuvem de pontos. Por meio dele, foi aplicado o algoritmo CSS, com o método ATIN (Adaptive TIN Ground Filter), sendo gerados os MDT.

O software de acesso livre denominado *RStudio*, versão 4.4.1, com a linguagem de programação *R* e os pacotes descritos na Tabela 1, foi utilizado para o processamento da nuvem e a aplicação dos algoritmos CSF e PMF, com o objetivo de classificar os pontos em solo e gerar os MDT.

Tabela 1 – Pacotes utilizados neste estudo para o processamento da nuvem de pontos, classificação de pontos em solo e exportação dos modelos digitais de terreno.

Pacote	Versão (recomendada/testada)	Finalidade do uso
lidR	4.0.4	Processamento de dados LiDAR. Utilizado para leitura dos arquivos .las/.laz, classificação do terreno com os algoritmos PMF e CSF, e geração dos MDT.
raster	3.6-26	Manipulação, visualização e exportação de dados raster, incluindo a gravação dos MDT em formato GeoTIFF.
sp	2.1-4	Suporte a objetos espaciais (pontos, linhas, polígonos) e integração entre dados vetoriais e raster.
rgdal	1.6-7	Interface com a biblioteca GDAL, permitindo leitura e escrita de formatos geoespaciais como GeoTIFF, LAS e SHP.
rlas	2.2.1	Biblioteca usada internamente pelo lidR para leitura e escrita eficiente de arquivos LAS/LAZ.
terra	1.7-78	Responsável pelas operações com grids (otimização do processamento) e superfícies.
rgl	1.3.1	Utilizada para visualização 3D interativa das nuvens de pontos e produtos derivados.

Fonte: Autoria própria, 2025.

Por fim, foi utilizado o *ArcGIS Pro 3.0*, que se trata de um software licenciado da empresa *Esri*, para a geração dos produtos cartográficos e estruturação da lógica e das ferramentas necessárias à formulação de um script. Nesse caso, o script utilizou a linguagem de programação *Python 3.0*, com o módulo *Arcpy*, e as bibliotecas estão descritas na Tabela 2. O script foi desenvolvido no ambiente de desenvolvimento *Jupyter Notebook 3.0* para a execução dos processos de amostragem, extração de cotas dos MDT, análises estatísticas e ferramentas de geoprocessamento.

Tabela 2 – Bibliotecas utilizadas em Python para as ferramentas de geoprocessamento, amostragem, aquisição dos dados e análises estatísticas.

Biblioteca / Módulo	Versão (recomendada/testada)	Finalidade do uso
arcpy	ArcGIS Pro 3.0	Geoprocessamento: buffer, dissolve, controle de geodatabases, operações espaciais

pandas	≥ 1.5	Manipulação e análise de dados tabulares, leitura/escrita de Excel
numpy	≥ 1.25	Operações numéricas, cálculo de diferenças, mediana, média Testes estatísticos: Shapiro-Wilk, Wilcoxon
scipy.stats	≥ 1.10	
matplotlib.pyplot	≥ 3.8	Visualização: gráficos de barras, ajustes de layout, exportação de imagens
seaborn	≥ 0.12	Visualização estatística avançada: heatmaps, paletas de cores, estilo de gráficos
statsmodels.stats.power	≥ 0.14	Cálculo do tamanho amostral e poder estatístico (TTestPower)
os	Nativo Python	Manipulação de arquivos e diretórios (criação de pastas, caminhos)

Fonte: Autoria própria, 2025.

Adicionalmente, foram realizados processamentos utilizando o ArcGIS Pro para a geração de produtos cartográficos como declividade e hillshade que auxiliem na visualização das diferenças de forma prática. O hillshade é calculado a partir de dois componentes derivados de um MDT. Sendo a declividade (*slope*), que representa a inclinação da superfície em cada célula do *raster*, e o aspecto (*aspect*), que indica a direção (em graus) para a qual a encosta está voltada.

Com base nesses parâmetros e na posição do sol, definida por ângulo de elevação e azimute solar, o algoritmo simula o quanto cada ponto do terreno recebe de luz ou sombra, resultando em uma imagem em tons de cinza que evidencia as formas do relevo, como encostas, vales e cristas, proporcionando uma visualização tridimensional mais realista e facilitando a interpretação das variações topográficas.

4.3 Aquisição dos Dados LiDAR

O ponto de partida do levantamento foi definido a partir da análise das curvas de nível, priorizando-se uma posição topograficamente mais elevada em relação à área experimental. Em campo, selecionou-se uma área com condições favoráveis à operação dos receptores GNSS, correspondente a um talhão de eucalipto em fase pós-corte, localizado em uma fazenda vizinha. Sobre um ponto de coordenadas conhecidas, determinado previamente por meio de coleta utilizando o método RTX com o receptor GNSS Spectra Precision SP60, foi instalado o receptor D-RTK 2, o qual atuou como estação base operando em modo RTK e mantendo comunicação contínua com a aeronave durante os voos. Os levantamentos aéreos foram realizados em dois dias consecutivos, empregando-se os sensores LiDAR Zenmuse L1 e L2 embarcados na aeronave DJI Matrice 350 RTK, sob condições climáticas e parâmetros de voo semelhantes, de modo a garantir a comparabilidade entre os dados adquiridos. Para isso,

foram mantidas constantes a velocidade, a altura de voo e as sobreposições para ambos os sensores, conforme apresentado na Tabela 3.

Tabela 3 - Parâmetros de voo empregados no levantamento de dados LiDAR.

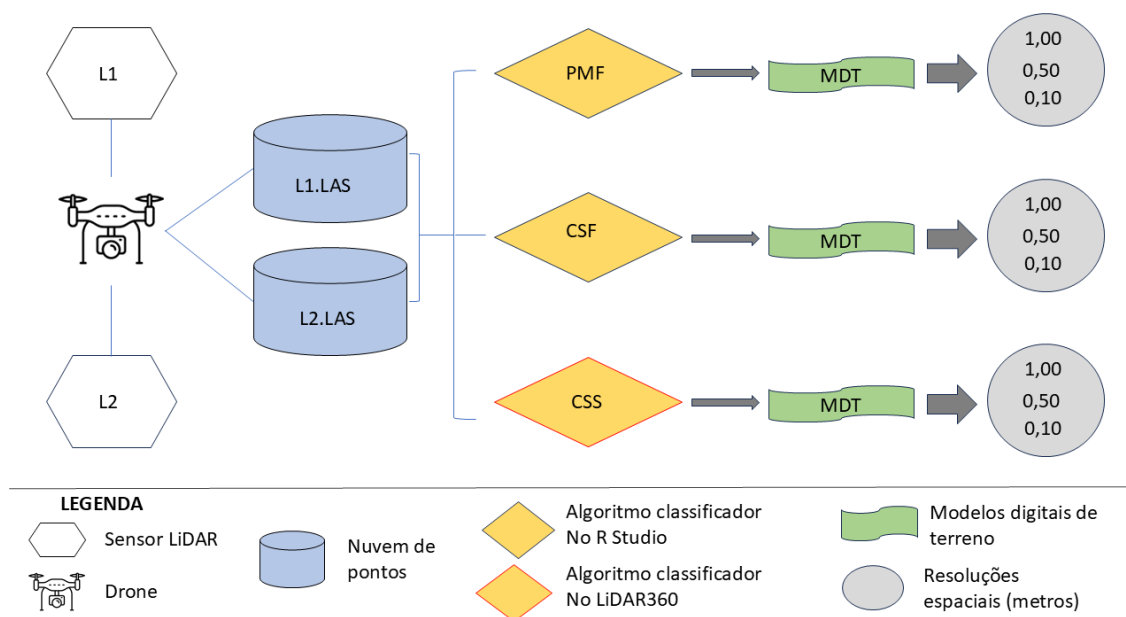
Sensor	Velocidade média (m/s)	Altura (m)	Sobreposição lateral (%)	Sobreposição frontal (%)	Quantidade de retornos	Densidade de pontos/m ²
L1	8	100	50	50	2	150
L2	8	100	50	50	5	200

Fonte: Autoria própria, 2025

4.4 Processamento da nuvem de pontos LiDAR e a geração dos MDT

O fluxo de trabalho adotado que é representado pela Figura 5, envolveu as etapas de aquisição dos dados, classificação dos pontos de terreno e geração dos Modelos digitais de terreno providos de diferentes algoritmos e em distintas resoluções espaciais. Processo que em um todo, totalizou em dezoito modelos digitais de terreno. Isso pela existência de dois sensores, três algoritmos e três resoluções espaciais distintas.

Figura 5 - Fluxograma do processamento das nuvens de ponto LiDAR



Fonte: Autoria própria, 2025

Os arquivos de extensão LASfile (.las) provenientes dos diferentes voos foram agrupados em um catálogo LAS utilizando a função `readLAScatalog()` do pacote *lidR* no ambiente R. O que permitiu os processamentos em blocos, denominados como *Chunks* de 200 x 200 metros.

Em seguida, foi realizada a classificação dos pontos de terreno, por meio do algoritmo CSF no ambiente R por meio do pacote *lidR*. Onde os principais parâmetros configurados foram: o ângulo máximo entre o terreno e a malha que é simulada sobre a nuvem de pontos em 0,5 rad. (*class_threshold*); a resolução dessa malha foi adotada como 1 metro (*cloth_resolution*); o parâmetro de rigidez do terreno (*rigidness*) também foi estabelecido como 1 e por fim, o número de iterações como 500.

Ainda no ambiente R, aplicou-se o algoritmo PMF por meio do pacote *lidR* para a distinção entre pontos de solo e não solo com janelas móveis progressivas variando de 3 a 15 metros por meio do parâmetro (*ws = seq(3, 15, 3)*) com valores limiares de altura ajustados de 0,10 a 1,5 metros por meio do parâmetro (*th = seq(0,1m 1,5, length_out=5)*), o que permitiu um diagnóstico dos pontos em solo de forma progressiva.

Os MDT foram gerados ainda no ambiente R por meio do método TIN (*Triangular Irregular Network*), utilizando a função *rasterize_terrain()* do pacote *raster* para a exportação em formato de arquivo GeoTIFF (.tif) nas resoluções de 0,10 metros, 0,50 metros e por fim de 1 metro.

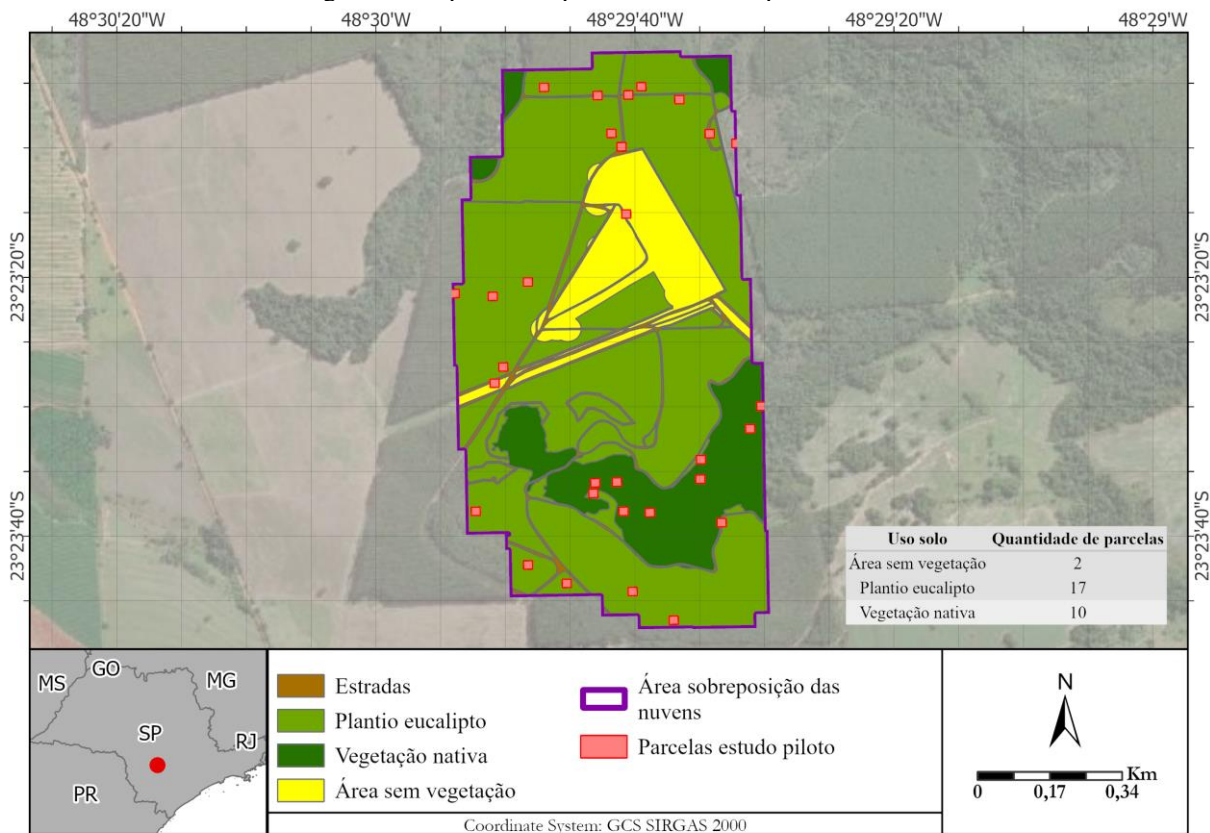
Adicionalmente, foi realizado a classificação dos pontos em solo no software LiDAR360, empregando o algoritmo ATIN com o método CSS. Onde foi definido como 1 metro o valor de interpolação para geração do MDT e realizado uma suavização na superfície com base na curvatura local. Os demais parâmetros foram definidos pelo próprio software que utiliza a densidade da nuvem de pontos para determinar o número mais adequado de iterações e o valor limiar de curvatura.

4.5 Delimitação de tamanho amostral e abordagem estatística a ser realizada

Após a geração dos MDT, foi realizado um estudo piloto objetivando avaliar a variabilidade dos dados para a definição da abordagem estatística que deveria ser realizada no estudo e o tamanho amostral necessário para a identificação de diferenças significativas entre os sensores se elas existirem.

Para isso, com técnicas de geoprocessamento no ambiente Jupyter Notebook, foram gerados 30 pontos aleatórios dentro da área experimental, um buffer de 10m e por fim o uso da função *envelope polygon* para a criação de parcelas quadradas de 20x20 metros sobre esses pontos. Para cada parcela, foi extraída a cota Z de altitude média de cada um dos 18 MDT gerados anteriormente pelos diferentes sensores, algoritmos e resoluções testadas. As parcelas delimitadas podem ser visualizadas de acordo com a Figura 6.

Figura 6 - Mapa com as parcelas do estudo piloto alocada



Fonte: Autoria própria, 2025.

Inicialmente, foi calculado a diferença entre os valores de altitude obtidos pelos diferentes sensores em pares, ou seja, entre os mesmos algoritmos e resoluções. A partir disso, foi realizado um teste t pareado, que é um método para comparar as médias de duas amostras dependentes e obter o desvio padrão.


Com base nos resultados obtidos, foi realizado o cálculo do tamanho de efeito que é uma medida padronizada para expressar a intensidade da diferença entre dois grupos de forma independente. Para esse cálculo, foi empregada a equação de Cohen's d (Equação 02), onde o tamanho de efeito (d), é determinado pela razão entre a diferença média dos valores do sensor L1 (\bar{X}_1) e L2 (\bar{X}_2) pelo desvio padrão (s_d) das diferenças observadas.

$$d = \frac{\bar{X}_1 - \bar{X}_2}{s_d} \quad (\text{Equação 2})$$

Com base nesses resultados, foi realizado um cálculo de poder estatístico (power analysis) utilizando a função TTestPower da biblioteca Statsmodels (Python), o qual leva em consideração o tamanho de efeito calculado no estudo piloto para estimar o número amostral mínimo para a obtenção dos níveis 80, 90 e 95% de poder estatístico. Os resultados deste teste indicaram que seriam necessárias entre 138 e 302 parcelas para atingir 95% de poder estatístico

com nível de significância de 5%. Tais informações podem ser visualmente avaliadas de acordo com o gráfico representado pela Figura 7.

Figura 7 – Gráfico com o número de parcelas necessárias para obtenção de poder estatístico de 80, 90 e 95%



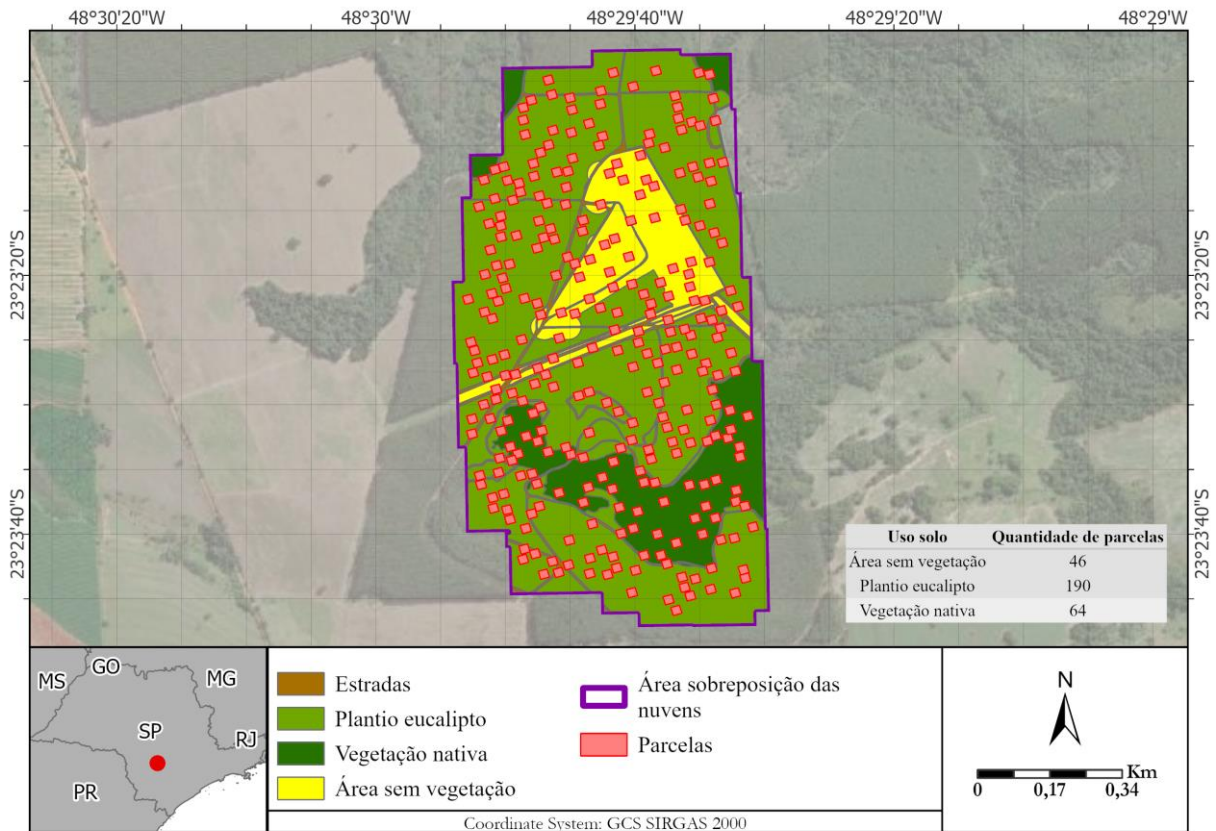
Fonte: Autoria própria, 2025

O teste piloto indicou ausência de normalidade nas distribuições de diferença entre sensores (L1–L2) pelo teste de Shapiro-Wilk. Dessa forma, optou-se pela aplicação do teste não paramétrico de Wilcoxon, adequado para dados pareados e sem distribuição normal, e pela medição da magnitude das diferenças por Cohen.

4.6 Análise da variância entre os difentes sensores, algoritmos e resoluções

Após o estudo piloto, definiu-se o uso de 300 parcelas de 20×20 m (400 m^2) cada, totalizando aproximadamente 12 hectares amostrados, o que representa 14,93% da área total de estudo. As parcelas alocadas podem ser visualizadas por meio da Figura 8, a qual contém um buffer negativo no limite, com o objetivo de evitar amostragem em bordas de MDTs, onde podem ocorrer inconsistências ou ausência de dados. Para cada parcela, foi extraída a cota Z de altitude média em cada um dos 18 MDT.

Figura 8 - Mapa com as parcelas do estudo piloto alocado



Fonte: Autoria própria, 2025.

Por meio de um script em python com módulo arcpy, foi extraído para cada parcela a cota Z de altitude e a declividade média de cada um dos 18 MDT. Em seguida, foi definido os pares de comparação que quando objetivou avaliar os sensores, a análise foi restringida aos mesmos algoritmos e resoluções, totalizando 9 pares.

Para o estudo dos algoritmos, foram definidos 6 pares por sensor, onde objetivou-se comparar CSSvsCSFvsPMF limitando a análise na mesma resolução espacial e entre o mesmo sensor. Para mensuração no nível de resolução espacial, também se utilizou de 6 pares, onde se fixou a análise entre o mesmo sensor e os mesmos algoritmos.

Após a definição dos pares, foi criado um script para o cálculo da diferença entre pares e a geração da estatística descritiva, contendo média, mediana, valores mínimos e máximos, amplitude, desvio padrão e variância. Adicionalmente, foi realizado o teste estatístico não paramétrico de Wilcoxon para amostras pareadas e calculado o tamanho de efeito pela equação de Cohens'd apresentada na Equação 2.

O teste de Wilcoxon baseia-se na ordenação dos valores absolutos das diferenças entre os pares, aos quais são atribuídas notas, definidas como ranks de acordo com a magnitude

da diferença. Aplica-se os sinais da diferença ao valor do rank e o valor estatístico de Wilcoxon (W) é definido como o menor somatório entre as medidas positivas e negativas.

A partir da distribuição amostral do valor W calculado, é obtido o valor-p (p-value), que é definido como a probabilidade de se observar um valor igual ou maior do que o obtido experimentalmente, sobre a suposição da não existência de diferença entre os pares (Hipótese nula - H0). De forma que quanto mais baixo o valor, menor a chance de a fonte do erro ser uma variação aleatória.

Diante do contexto, adotou-se como critério de significância os valores de p que são menores que 0,05 (p-value < 0,05), rejeitando-se a hipótese nula e aceitando que há diferença estatisticamente significativa entre os pares, quando o valor de p for maior do que 0,005 (p-value > 0,05) indicam a ausência de diferença significativa.

Além disso, para complementar a análise e estimar a magnitude prática das diferenças observadas, foi calculado o tamanho de efeito utilizando a equação de Cohen's d (Equação 2), conforme sugerido por Cohen (1988). Esse índice permite avaliar se as diferenças estatísticas possuem relevância e qual seria a magnitude da diferença por meio da Tabela 4.

Tabela 4 – Valores de d por classes

Faixa de <i>d</i>	Classe	Interpretação prática
$d < 0,2$	Insignificante	Diferenças praticamente imperceptíveis. Relevância prática mínima.
$0,2 \leq d < 0,5$	Pequeno	Diferença leve, detectável apenas em amostras grandes.
$0,5 \leq d < 0,8$	Médio	Diferença moderada, visível em situações práticas.
$d \geq 0,8$	Grande	Diferença acentuada, facilmente observável e com grande impacto.

Fonte: Cohen, 1988.

5 RESULTADOS E DISCUSSÃO

Para a comparação entre os diferentes sensores LiDAR, o resultado do teste de Wilcoxon apresentou uma diferença estatística significava para todos os pares ($p < 0,05$). Enquanto o modelo de Cohens'd indica que o tamanho de efeito dessa diferença é insignificante, onde os valores d variam de 0,09 e 0,18 conforme apresentado pela Tabela 5.

Tabela 5 – Valores obtidos com os testes estatísticos de Wilcoxon e Cohen para a comparação da discrepância entre os sensores LiDAR L1 e L2.

Comparação	Wilcoxon_W	p_value	Significância ($\alpha = 0.05$)	Cohens_d	Classe de efeito
L1(CSF,0.1 m) vs L2(CSF,0.1 m)	16356	9.79564×10^{-5}	Significativo	0.1750	Insignificante
L1(CSF,0.5 m) vs L2(CSF,0.5 m)	16301	8.39870×10^{-5}	Significativo	0.1763	Insignificante
L1(CSF,1.0 m) vs L2(CSF,1.0 m)	16586	1.8378×10^{-4}	Significativo	0.1761	Insignificante
L1(CSS,0.1 m) vs L2(CSS,0.1 m)	17937	4.67983×10^{-3}	Significativo	0.0973	Insignificante
L1(CSS,0.5 m) vs L2(CSS,0.5 m)	17782	3.35788×10^{-3}	Significativo	0.1053	Insignificante
L1(CSS,1.0 m) vs L2(CSS,1.0 m)	18027	5.64836×10^{-3}	Significativo	0.1026	Insignificante
L1(PMF,0.1 m) vs L2(PMF,0.1 m)	15880	2.47639×10^{-5}	Significativo	0.1256	Insignificante
L1(PMF,0.5 m) vs L2(PMF,0.5 m)	15895	2.58995×10^{-5}	Significativo	0.1274	Insignificante
L1(PMF,1.0 m) vs L2(PMF,1.0 m)	15966	3.19807×10^{-5}	Significativo	0.1289	Insignificante

Fonte: Autoria própria, 2025

Na avaliação da disparidade entre os algoritmos classificadores de ponto em solo, o teste estatístico de Wilcoxon também apontou uma diferença estatística significativa entre todos os pares ($p < 0,05$). As magnitudes de efeito variaram de pequenas ($\approx 0.2-0.4$) a médias ($\approx 0.5-0.7$) e grandes (> 0.8), conforme apresentado pela Tabela 6.

Tabela 6 – Valores obtidos com os testes estatísticos de Wilcoxon e Cohen para a comparação da discrepância entre os algoritmos CSS, CSF e PMF.

Comparação	Wilcoxon W	p value	Significância ($\alpha=0.05$)	Cohen's d	Classe de efeito
L1 CSF(0.1 m) vs L1 CSS(0.1 m)	2215	3.42914×10^{-41}	Significativo	0.444	Pequeno
L1 CSF(0.1 m) vs L1 PMF(0.1 m)	4653	4.08528×10^{-32}	Significativo	0.252	Pequeno
L1 CSS(0.1 m) vs L1 PMF(0.1 m)	1098	9.68534×10^{-46}	Significativo	-0.675	Médio
L1 CSF(0.5 m) vs L1 CSS(0.5 m)	2187	2.65555×10^{-41}	Significativo	0.443	Pequeno
L1 CSF(0.5 m) vs L1 PMF(0.5 m)	4655	4.15133×10^{-32}	Significativo	0.252	Pequeno
L1 CSS(0.5 m) vs L1 PMF(0.5 m)	1234	3.57374×10^{-45}	Significativo	-0.670	Médio
L1 CSF(1.0 m) vs L1 CSS(1.0 m)	2229	3.89621×10^{-41}	Significativo	0.445	Pequeno
L1 CSF(1.0 m) vs L1 PMF(1.0 m)	4598	2.62639×10^{-32}	Significativo	0.253	Pequeno
L1 CSS(1.0 m) vs L1 PMF(1.0 m)	922	1.76576×10^{-46}	Significativo	-0.673	Médio
L2 CSF(0.1 m) vs L2 CSS(0.1 m)	2813	7.40674×10^{-39}	Significativo	0.527	Médio
L2 CSF(0.1 m) vs L2 PMF(0.1 m)	4362	3.88461×10^{-33}	Significativo	0.206	Pequeno
L2 CSS(0.1 m) vs L2 PMF(0.1 m)	0	1.88322×10^{-50}	Significativo	-1.554	Grande
L2 CSF(0.5 m) vs L2 CSS(0.5 m)	2810	7.2126×10^{-39}	Significativo	0.530	Médio
L2 CSF(0.5 m) vs L2 PMF(0.5 m)	4363	3.91641×10^{-33}	Significativo	0.205	Pequeno
L2 CSS(0.5 m) vs L2 PMF(0.5 m)	0	1.88322×10^{-50}	Significativo	-1.556	Grande
L2 CSF(1.0 m) vs L2 CSS(1.0 m)	2936	2.19311×10^{-38}	Significativo	0.533	Médio
L2 CSF(1.0 m) vs L2 PMF(1.0 m)	4350	3.5225×10^{-33}	Significativo	0.207	Pequeno
L2 CSS(1.0 m) vs L2 PMF(1.0 m)	0	1.88322×10^{-50}	Significativo	-1.570	Grande

Fonte: Autoria própria, 2025

Na comparação a nível de resolução, um dos pares (L2 CSS 0.1 m \times 0.5 m) apresentou uma diferença estatisticamente significativa ($p = 0.000188$) mas com tamanho de efeito Insignificante ($d = 0,15180$) enquanto o restante dos pares avaliados teve como não

significativa a diferença entre eles e de magnitude Insignificante ($d < 0,2$) conforme é demonstrado pela Tabela 7.

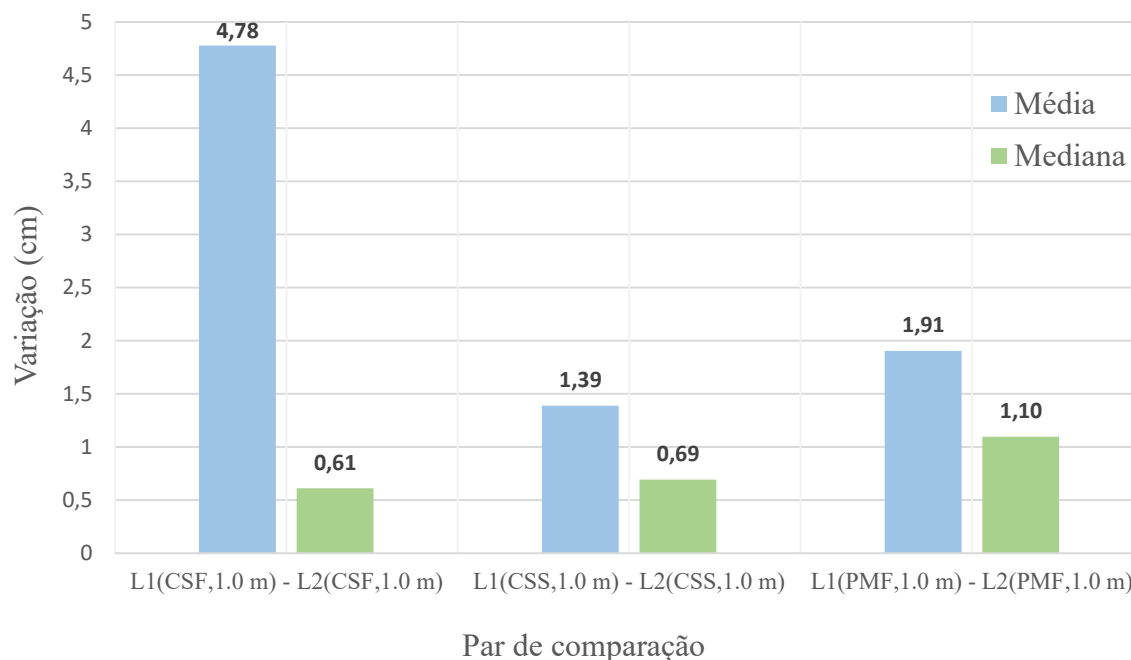
Tabela 7 – Valores obtidos com os testes estatísticos de Wilcoxon e Cohen para a comparação da discrepância entre as resoluções 0,10m, 0,50m e 1,00m.

Comparação	Wilcoxon_W	p_value	Significância ($\alpha=0.05$)	Cohen's d (d z)	Classe de efeito
L1 CSF(0.1 m) vs L1 CSF(0.5 m)	21789	0.8198	Não significativo	-0.0458	Insignificante
L1 CSF(0.1 m) vs L1 CSF(1.0 m)	21870	0.8625	Não significativo	-0.0279	Insignificante
L1 CSF(0.5 m) vs L1 CSF(1.0 m)	21877	0.8662	Não significativo	-0.0116	Insignificante
L1 CSS(0.1 m) vs L1 CSS(0.5 m)	20339	0.2275	Não significativo	-0.0665	Insignificante
L1 CSS(0.1 m) vs L1 CSS(1.0 m)	20756	0.3549	Não significativo	-0.0465	Insignificante
L1 CSS(0.5 m) vs L1 CSS(1.0 m)	19932	0.1385	Não significativo	0.0378	Insignificante
L1 PMF(0.1 m) vs L1 PMF(0.5 m)	21479	0.6620	Não significativo	-0.0432	Insignificante
L1 PMF(0.1 m) vs L1 PMF(1.0 m)	22041	0.9540	Não significativo	-0.0391	Insignificante
L1 PMF(0.5 m) vs L1 PMF(1.0 m)	21918	0.8881	Não significativo	-0.0284	Insignificante
L2 CSF(0.1 m) vs L2 CSF(0.5 m)	19710	0.1028	Não significativo	0.0472	Insignificante
L2 CSF(0.1 m) vs L2 CSF(1.0 m)	19378	0.0635	Não significativo	-0.0867	Insignificante
L2 CSF(0.5 m) vs L2 CSF(1.0 m)	19379	0.0636	Não significativo	-0.0923	Insignificante
L2 CSS(0.1 m) vs L2 CSS(0.5 m)	16594	0.000188	Significativo	0.1518	Insignificante
L2 CSS(0.1 m) vs L2 CSS(1.0 m)	20197	0.1927	Não significativo	0.0148	Insignificante
L2 CSS(0.5 m) vs L2 CSS(1.0 m)	21466	0.6557	Não significativo	-0.0556	Insignificante
L2 PMF(0.1 m) vs L2 PMF(0.5 m)	19593	0.0872	Não significativo	0.0517	Insignificante
L2 PMF(0.1 m) vs L2 PMF(1.0 m)	21236	0.5477	Não significativo	-0.0057	Insignificante
L2 PMF(0.5 m) vs L2 PMF(1.0 m)	20824	0.3792	Não significativo	-0.0198	Insignificante

Fonte: Autoria própria, 2025

Ao aferir que não existe diferença estatística significativa entre diferentes resoluções espaciais na cota de altitude média, foi realizado uma análise exploratória das variações obtidas com os diferentes sensores e algoritmos. A Figura 9 apresenta um gráfico de colunas com a média das diferenças entre os sensores com mesmo algoritmo e resolução variando de 1,39 a 4,78cm e a mediana de 0,61 a 1,10cm.

Figura 9 – Gráfico de colunas com as diferenças médias e medianas entre pares de comparação no nível de sensor.



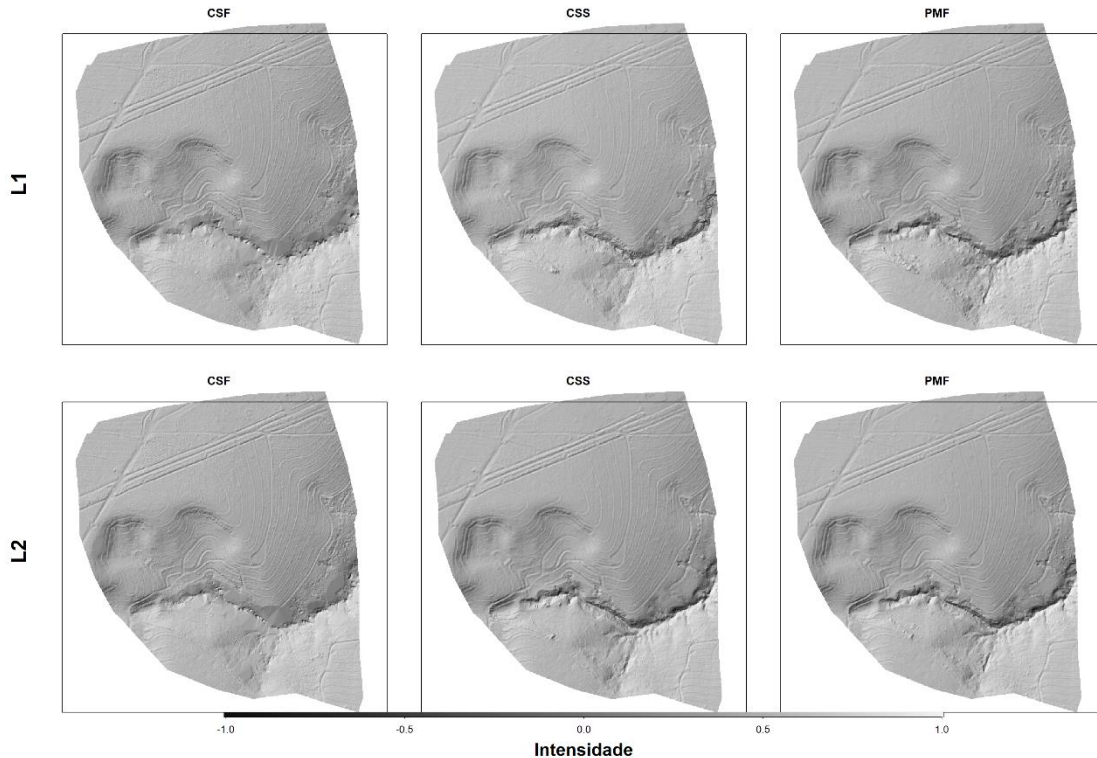
Fonte: Autoria própria, 2025.

A discrepância entre média e mediana sugere a presença de outliers associados a características de declividade e uso do solo da área de estudo, conforme discutido em um estudo de Macedo et al., 2013 que aponta um erro altimétrico (RMSE=0,50m) em áreas de relevo ondulado e de alta densidade de cobertura florestal, pois a presença de sub-bosque, terraços, troncos e afins dificultam a classificação dos pontos em solo pelos algoritmos.

A Figura 10, compila diferentes *hillshade* gerados a partir de cada sensor e algoritmo sobre as áreas de vegetação nativa. No caso sobre uma área de preservação permanente com cobertura florestal densa e ao comparar visualmente os produtos nos tons de intensidade mais escuros (valores próximos a -1), é possível visualizar que existem pontos que não foram triangulados e não apresentam uma superfície contínua.

Os pontos mais escuros representam a calha de um riacho e é possível aferir que nessas áreas os *hillshade* gerados para o sensor L2 apresentaram um maior nível de detalhamento do que o sensor L1, o que pode ser justificado pela maior quantidade de números de retornos que chegam nessas áreas mais baixas e de alta densidade de vegetação.

Figura 10 - Diferentes *Hillshade* gerados em uma área de preservação permanente por diferentes algoritmos e sensores.



Fonte: Autoria própria, 2025.

Sobre as diferenças altimétricas encontradas entre os algoritmos CSF, CSS e PMF, as estatísticas descritivas estão descritas na Tabela 8. Onde é possível aferir que a escolha do algoritmo classificador de pontos em solo tem impactos maiores na geração dos modelos digitais de terreno do que a especificação do sensor em si.

Tabela 8 – Estatísticas descritivas da comparação entre algoritmos na resolução de 1m.

Comparação	Sensor	Média (m)	Desvio Padrão (m)	Mediana (m)	Mínimo (m)	Máximo (m)
CSF vs CSS	L1	0,117	0,263	0,077	-0,573	2,877
CSF vs PMF	L1	0,059	0,233	0,029	-0,593	2,066
PMF vs CSS	L1	-0,058	0,087	-0,046	-0,811	0,537
CSF vs CSS	L2	0,083	0,157	0,077	-1,12	1,762
CSF vs PMF	L2	0,03	0,146	0,031	-1,241	1,42
PMF vs CSS	L2	-0,053	0,034	-0,045	-0,342	-0,005

Fonte: Autoria própria, 2025.

As médias e medianas das variações altimétricas entre os algoritmos situam-se entre 3 e 12 cm. As maiores divergências foram observadas entre o CSF e o CSS, com mediana de 8

cm, refletindo o caráter mais suavizador do CSS em relação ao CSF. As comparações CSF–PMF apresentaram diferenças médias de 3 a 5 cm, sugerindo maior similaridade e preservação de feições locais nesse par. Já o confronto entre PMF e CSS resultou em discrepâncias de 4 a 5 cm, compatíveis com o comportamento intermediário do PMF.

6 CONCLUSÃO

Os sensores LiDAR avaliados apresentaram diferenças estatisticamente significativas entre si, porém com tamanhos de efeito insignificantes. Por outro lado, as discrepâncias entre os algoritmos de classificação de pontos em solo apresentaram magnitudes de efeito variando de pequenas a grandes, indicando que a escolha do método de classificação exerce maior influência sobre a variação entre os modelos de terreno do que o sensor ou a resolução empregada, a qual não apresentou variação significativa. Além disso, as variações observadas ocorreram em escala centimétrica indicando uma alta similaridade, no entanto não foi possível definir o método mais acurado e diante disso, recomenda-se a realização de estudos complementares com técnicas topográficas e posicionamento GNSS de alta precisão, de modo a estabelecer pontos de controle em campo que permitam avaliar a acurácia real dos diferentes sensores e algoritmos de classificação.

REFERÊNCIAS

- ALVES, D. B. M.; ABREU, P. A. G.; SOUZA, J. S. GNSS: status, modelagem atmosférica e métodos de posicionamento. **Revista Brasileira de Geomática**, v. 1, n. 1, p. 2-7, 2013.
- BAILEY, G. et al. Comparison of ground point filtering algorithms for high-density point clouds collected by terrestrial LiDAR. **Remote Sensing**, v. 14, n. 19, p. 4776, 2022.
- BANG, K. I. **Alternative methodologies for LiDAR system calibration**. 2010. 177 f. Thesis (Doctor of Philosophy) – Department of Geomatics Engineering, University of Calgary, Calgary, 2010.
- CHAZDON, R.; BRANCALION, P. H. S. Restoring forests as a means to many ends: an urgent need to replenish tree canopy cover calls for holistic approaches. **Science**, v. 365, n. 6448, p. 24-25, 2019. Tradução. Disponível em: <https://doi.org/10.1126/science.aax9539>. Acesso em: 24 abr. 2025.
- CORTE, A. P. D. et al. **Aplicações do LiDAR para o inventário florestal – Enfoque unidade de área**. Ponta Grossa (PR): Atena Editora, 2022. ISBN 978-65-258-0122-3. DOI 10.22533/at.ed.223222904.
- COHEN, J. **Statistical power analysis for the behavioral sciences**. 2. ed. Hillsdale, NJ: Lawrence Erlbaum Associates, 1988.
- DALMOLIN, Q.; SANTOS, D. R. **Sistema Laser Scanner: conceitos e princípios de funcionamento**. Curitiba: UFPR, 2003. 111 p.
- EL-SHEIMY, N.; YOUSSEF, A. Inertial sensors technologies for navigation applications: state of the art and future trends. **Satellite Navigation**, v. 1, n. 1, p. 2, 2020.
- FERREIRA, M. P. et al. Estimating aboveground biomass of tropical urban forests with UAV-borne hyperspectral and LiDAR data. **Urban Forestry & Urban Greening**, v. 96, p. 128362, 2024.
- GOMES, L. F. **Uso do escaneamento a laser aerotransportado como ferramenta para monitoramento de variáveis estruturais de florestas manejadas na Amazônia**. 2022. 183 f., il. Tese (Doutorado em Geociências Aplicadas) – Universidade de Brasília, Brasília, 2022.
- HABIB, A. F. et al. Lidar strip adjustment using conjugate linear features in overlapping strips. In: **Proceedings of the XXI ISPRS Congress**, Commission I, Beijing, China, v. 37, part B1, 2008.
- HOBBIE, S. E.; GRIMM, N. B. Nature-based approaches to managing climate change impacts in cities. **Philosophical Transactions of the Royal Society B**, v. 375, n. 1794, p. 20190124, 2020.
- İLÇİ, V. Accuracy comparison of real-time GNSS positioning solutions: case study of Mid-North Anatolia. **Measurement**, v. 142, p. 40–47, 2019. ISSN 0263-2241. Disponível em: <https://doi.org/10.1016/j.measurement.2019.04.067>. Acesso em: 7 out. 2025.

JIN, S.; WANG, Q.; DARDANELLI, G. A review on multi-GNSS for Earth observation and emerging applications. **Remote Sensing**, 2022.

KAHRAMAN, S.; BACHER, R. A comprehensive review of hyperspectral data fusion with LiDAR and SAR data. **Annual Reviews in Control**, v. 51, p. 236-253, 2021.

KOMAZAKI, J. M. **Avaliação da acurácia posicional de nuvem de pontos LiDAR aerotransportado: análise comparativa de normas e padrões**. 2020. Dissertação (Mestrado em Ciências Cartográficas) — Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista (UNESP), Presidente Prudente, 2020.

KRAUS, K. **Photogrammetry: geometry from images and laser scans**. 2. ed. Berlin: Walter de Gruyter, 2007. ISBN 978-3-11-019007-6.

LEICK, A.; EMMONS, M. B. Quality control with reliability for large GPS networks. **Journal of Surveying Engineering**, v. 120, n. 1, p. 25-41, 1994.

LEITE, R. V. et al. Individual tree attribute estimation and uniformity assessment in fast-growing *Eucalyptus spp.* forest plantations using LiDAR and linear mixed-effects models. **Remote Sensing**, v. 12, n. 21, p. 3599, 2020.

MACEDO, Rodrigo; DOS SANTOS, João Roberto; SOARES, João Vianei. Validação de modelo digital de terreno em área florestal com relevo ondulado, gerado a partir de dados LiDAR. **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 65, n. 4, p. 695–702, 2013. Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto. ISSN 1808-0936.

MONICO, J. F. G. **Posicionamento pelo GNSS: descrição, fundamentos e aplicações**. São Paulo: Unesp, 2008. 476 p.

NORD-LARSEN, T.; RIIS-NIELSEN, T. Developing an airborne laser scanning dominant height model from a countrywide scanning survey and national forest inventory data. **Scandinavian Journal of Forest Research**, v. 25, n. 3, p. 262-272, 2010. DOI: <https://doi.org/10.1080/02827581.2010.486000>.

PINGEL, T.; CLARKE, K.; MCBRIDE, W. An improved simple morphological filter for the terrain classification of airborne LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 77, p. 21-30, 2013. DOI: 10.1016/j.isprsjprs.2012.12.002.

RODRIGUES, J. P. C. da S. **Análise comparativa de receptores de posicionamento por satélite para levantamento planimétrico de imóveis rurais**. 2016. 57 f. Trabalho de Conclusão de Curso (Graduação em Agronomia) – Universidade Federal da Paraíba, Areia, 2016.

ROCHA, A. P. et al. Levantamento topográfico perimétrico: método GNSS RTK x método polar. In: **COBRAC 2018**, 2018.

SCHIMALESKY, V.; CENTENO, J. A. S. Avaliação da qualidade da informação altimétrica derivada da varredura a laser em uma região coberta por vegetação: estudo de caso. **Floresta**, Curitiba, v. 38, n. 4, p. 597-606, 2008.

SEEBER, G. **Satellite Geodesy: foundations, methods and applications**. 2. ed. Berlin; New York: Walter de Gruyter, 2003. 588 p.

SEGANTINE, P. C. L. **GPS – Sistema de Posicionamento Global**. São Carlos: EESC/USP, 1998.

SINEGALIA, M. K. S. D.; SANTORO, G. B.; MOLIN, P. G. How have RPAS helped monitor forests and what can we apply in forest restoration monitoring? **Restoration Ecology**, v. 32, n. 1, p. e14061, 2024.

ŠTRONER, M. et al. Vegetation filtering of a steep rugged terrain: the performance of standard algorithms and a newly proposed workflow on an example of a railway ledge. **Remote Sensing**, v. 13, n. 15, p. 3050, 2021.

TEUNISSEN, P. J. G.; KLEUSBERG, A. GPS observation equations and positioning concepts. In: **GPS for Geodesy**. Berlin: Springer, 1998. p. 187-229.

TIMBÓ, M. A. **Levantamentos através do Sistema GPS**. Notas de aula do Departamento de Cartografia da UFMG. Belo Horizonte, 2000.

WEHR, A.; LOHR, U. Airborne laser scanning: an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, p. 68-82, 1999.

ZHAO, W.; CHEN, C.; WU, J. Improved progressive TIN densification filtering algorithm for ground points classification. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLI-B1, p. 313–319, 2016. DOI: 10.5194/isprs-archives-XLI-B1-313-2016.

ZHENG, J.; XIANG, M.; ZHANG, T.; ZHOU, J. An improved adaptive grid-based progressive triangulated irregular network densification algorithm for filtering airborne LiDAR data. **Remote Sensing**, v. 16, n. 20, art. 3846, 16 out. 2024. DOI: 10.3390/rs16203846.