

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS AGROVETERINÁRIAS – CAV
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL

FELIPE CANELLO DE CAMARGO

**ACURÁCIA POSICIONAL DE *DIGITAL TERRAIN MODEL* (DTM) GERADOS POR
LIDAR/UAV EM ÁREAS COM COBERTURA VEGETAL AO LONGO DE RODOVIA**

LAGES

2025

FELIPE CANELLO DE CAMARGO

ACURÁCIA POSICIONAL DE *DIGITAL TERRAIN MODEL* (DTM) GERADOS POR LIDAR/UAV EM ÁREAS COM COBERTURA VEGETAL AO LONGO DE RODOVIA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, do Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Mestre em Engenharia Florestal
Orientador: Prof. Dr. Marcos Benedito Schimalski
Co-orientador: Prof. Dr. Veraldo Liesenberg

LAGES
2025

FICHA CATALOGRÁFICA

FELIPE CANELLO DE CAMARGO

**ACURÁCIA POSICIONAL DE *DIGITAL TERRAIN MODEL* (DTM) GERADOS POR
LIDAR ALS/UAV EM ÁREAS COM COBERTURA VEGETAL AO LONGO DE
RODOVIA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, do Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Mestre em Engenharia Florestal
Orientador: Prof. Dr. Marcos Benedito Schimalski
Co-orientador: Prof. Dr. Veraldo Liesenberg

BANCA EXAMINADORA

Orientador: _____

Prof. Dr. Marcos Benedito Schimalski
Universidade Estadual de Santa Catarina - UDESC

Membros: _____

Prof. Dr. Veraldo Liesenberg
Universidade Estadual de Santa Catarina - UDESC

Dr. Eng. João Paulo Pereira
Coillte Teoranta

Prof. Dr. Leonardo Josoe Biffi
Universidade Estadual de Santa Catarina - UDESC

Lages, 28 de maio de 2025.

Ao Criador, aos meus pais, Flavio e
Carmen, e a Jocasta, minha eterna amada.

AGRADECIMENTOS

Agradeço a Deus pela oportunidade e pela força para avançar neste estudo.

Meu sincero agradecimento ao meu orientador, Dr. Marcos Benedito Schimalski, por sua dedicação e apoio incondicional. Sem você, este estudo não seria possível. Obrigado por otimizar e entender nossos esforços. O mesmo apreço tenho pelo Dr. Veraldo Lisenberg, meu coorientador.

Sou eternamente grato aos meus pais, Flávio e Carmen, educadores que sempre estiveram ao meu lado, apoiando-me ao longo de toda a minha trajetória. Agradeço à minha família pelo convívio maravilhoso e encorajador.

Um agradecimento especial à Jocasta, minha eterna amada, por me apoiar e valorizar cada momento de estudo e trabalho. Obrigado por acreditar em uma vida próspera.

Agradeço também aos meus colegas de Mestrado, com um destaque especial para meus grandes amigos Maicon Morelato, Cleveonei da Silva, Guilherme Moura, Fernando Matos e Marchant Azura.

Agradeço ao meu amigo e colega de profissão, Danilo Rosa, proprietário da empresa Aérea Topografia, e a todos os colegas de trabalho que contribuíram para as pesquisas de campo, especialmente ao Técnico Agrícola Luis Carlos Teixeira de Lima e ao auxiliar de campo Rafael Batalha.

“É impossível para um homem aprender aquilo que ele pensa que já sabe.”
(Epicteto)

RESUMO

O crescimento e desenvolvimento econômico do Brasil, especialmente nos setores industrial, agrícola e florestal, depende intrinsecamente de sua rede rodoviária. A necessidade de aprimorar e ampliar as rodovias existentes, particularmente em áreas com densa cobertura vegetal, exige estudos de viabilidade detalhados. Levantamentos topográficos tradicionais em locais íngremes ou densamente vegetados apresentam dificuldades significativas de execução. Neste contexto, o estudo teve como objetivo principal avaliar o potencial da tecnologia LiDAR (*Ligth Detection and Ranging*) embarcada em Aeronaves Remotamente Pilotadas/*Unmanned Aerial Vehicle* (ARP/UAV), também conhecidos como drones, em comparação com as técnicas clássicas de Topografia e Geodésia para a elaboração de projetos de viabilidade. A pesquisa foi conduzida em um trecho de 7,5 km da rodovia BR 116, no município de Vacaria/RS, caracterizado por uma faixa de domínio que varia de 30 a 50m a partir do eixo da rodovia em questão. Neste trecho, foram levantados oito perfis topográficos georreferenciados para comparação, abrangendo diversas condições de cobertura do solo. Para gerar os *digital terrain models* (DTM), foram utilizados três algoritmos de classificação de pontos de solo: PMF (*Progressive Morphological Filter*), CSF (*Cloth simulation Filter*) e PTIN (*Progressive Triangulated Irregular Network*). A acurácia altimétrica foi determinada comparando as elevações dos DTMs com dados de levantamentos topográficos georreferenciados. De forma geral o algoritmo PTIN foi consistente e equilibrado na análise por perfis. A análise por cobertura da terra mostra que o desempenho numérico ideal foi alcançado por diferentes algoritmos dependendo do ambiente analisado. Em suma, a tecnologia LiDAR /UAV demonstrou potencial significativo para levantamentos topográficos em áreas com cobertura vegetal ao longo de rodovias, como alternativa ou complemento às técnicas clássicas de Topografia e Geodésia. A qualidade do DTM gerado depende da escolha do algoritmo de filtragem e é influenciada pelo tipo de cobertura vegetal.

Palavras-chave: LiDAR; rodovias; modelo digital de terreno; modelo digital de superfície; topografia.

ABSTRACT

Brazil's economic growth and development, especially in the industrial, agricultural, and forestry sectors, is intrinsically dependent on its road network. The need to improve and expand existing highways, particularly in areas with dense vegetation, requires detailed feasibility studies. Traditional topographic surveys in steep or densely vegetated locations present significant execution difficulties. In this context, the main objective of this study was to evaluate the potential of LiDAR (Light Detection and Ranging) technology aboard Remotely Piloted Aircraft/Unmanned Aerial Vehicles (RPA/UAV), also known as drones, in comparison to classical Topography and Geodesy techniques for the preparation of feasibility projects. The research was conducted on a 7.5 km stretch of the BR 116 road in the municipality of Vacaria/RS, characterized by a right-of-way varying from 30 to 50m from the highway's central axis. In this section, eight georeferenced topographic profiles were surveyed for comparison, covering various ground cover conditions. To generate the Digital Terrain Models (DTM), three ground point classification algorithms were used: PMF (Progressive Morphological Filter), CSF (Cloth Simulation Filter), and PTIN (Progressive Triangulated Irregular Network). The altimetric accuracy was determined by comparing the elevations of the DTMs with georeferenced topographic survey data. Overall, the PTIN algorithm was consistent and balanced in the profile analysis. The land cover analysis shows that the optimal numerical performance was achieved by different algorithms depending on the environment analyzed. In summary, LiDAR/UAV technology demonstrated significant potential for topographic surveys in areas with vegetation cover along highways, serving as an alternative or complement to classical Topography and Geodesy techniques. The quality of the generated DTM depends on the choice of the filtering algorithm and is influenced by the type of vegetation cover.

Keywords: LiDAR; roads; digital terrain model; digital surface model; topography.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação de uma faixa de domínio de rodovias	19
Figura 2 - (a) DTM representado em 2D, (b) hillshade do DTM em 3D	20
Figura 3 - DSM da região do entorno do Ginásio Jones Minosso em Lages/SC	21
Figura 4 - Perfil representativo dos modelos DSM, CHM e DTM	22
Figura 5 – Relação entre RMSE e Densidade de Pulsos por Algoritmo e Área	23
Figura 6 – Níveis de operação do sensor LiDAR.....	25
Figura 7 - FARO Focus3D TLS.....	25
Figura 8 – (a) MLS embarcado em uma van, (b) H-PLS Leica BLK2go, (c) Spot Robot, (d) WLS LiDAR backpacking.....	26
Figura 9 – Cessna 206 com G-LiHT	27
Figura 10 – (a) DJI Matrice 200, (b) VTOL do UAV FengHu.....	28
Figura 11 – Representação dos pulsos LiDAR.....	30
Figura 12 – Sensor LiDAR e detalhe da localização do IMU.....	31
Figura 13 – Nuvens de pontos uma árvore da espécie Faia-europeia (<i>Fagus sylvatica</i>) com o modelo estrutural extraído da folhagem	33
Figura 14 – TLS sendo utilizada na caatinga.....	34
Figura 15 - Mapas de biomassa do programa <i>Somona County</i>	35
Figura 16 – Mapa de biomassa da Amazônia	36
Figura 17 – <i>Hillshade</i> com o anteprojeto de trecho da Rodovia SC-414	37
Figura 18 – Classificação de nuvem de pontos.....	37
Figura 19 – Detecção de faixas de rodovia através do sistema LiDAR	38
Figura 20 – Diferença entre Acurácia e Precisão	39
Figura 21 - Floresta Ombrófila Mista com presença de Silvicultura	42
Figura 22 – Área de estudo – (a) Brasil, (b) Estado do Rio Grande do Sul, (c) Recorte de Imagem de satélite da região de estudo (d) recorte de Carta topográfica da região de estudo.....	43
Figura 23 – Largura da faixa de domínio no trecho da rodovia analisado	44
Figura 24 – Dimensão da pista de rolagem da rodovia	44
Figura 25 - Receptor GNSS Trimble RTK R4	46
Figura 26 - GNSS Topcon GR3	47
Figura 27 - Estação Total Sanding e prisma.....	47
Figura 28 – Acessórios topográficos.....	48

Figura 29 - MATRICE 300 RTK	48
Figura 30 - Base móvel DJI D-RTK 2.....	49
Figura 31 – Fluxograma da pesquisa	50
Figura 32 – Autor e UAV/LIDAR	51
Figura 33 - UAV LIDAR sendo preparado para o voo	51
Figura 34 - Croqui de localização dos perfis levantados.	54
Figura 35 – Perfil 01 – (a) Nuvem de Pontos, (b) Coleta de pontos com ET, (c) Vista geral do local e (d) Vista do dossel das araucárias	55
Figura 36 - Perfil 02 – (a) Nuvem de Pontos, (b) Vista do dossel da floresta secundária, (c) Vista área com araucárias e (d) Vista geral da floresta secundária.	56
Figura 37 - Perfil 03 – (a) Nuvem de pontos, (b) Vista do dossel da floresta secundária, (c) Vista do dossel de pinus e (d) Vista do interior da floresta secundária	57
Figura 38 - Perfil 04 – (a) Nuvem de Pontos, (b) Vista da floresta secundária, (c) Instrumental de mensuração e (d) Vista da rodovia	58
Figura 39 – Perfil 05 – (a) Nuvem de pontos e (b) Vista da floresta secundaria inicial	58
Figura 40 - Perfil 06 – (a) Nuvem de Pontos, (b) Perspectiva da floresta secundária, (c) Estação Total e (d) Vista interior da floresta secundária.....	59
Figura 41 - Perfil 07 – (a) Nuvem de Pontos, (b) Vista da floresta secundária, (c) Vista de área com campo e (d) Vista da área com eucalipto	60
Figura 42 - Perfil 08 – (a) Nuvem de pontos, (b) Área com campo, (c) Área com floresta, (d) Dossel da floresta secundária, (e) Área com eucaliptos adultos e (f) Interior da floresta secundária.....	61
Figura 43 – Demarcação de pontos de apoio.....	62
Figura 44 – ET em levantamento de perfil.....	63
Figura 45 – Visualização 3D da nuvem de pontos	67
Figura 46 – DTMs e Ortofoto referente ao Perfil 01 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF.	68
Figura 47 – Gráficos QQ Plot e Box Plot gerados para Perfil 01	70

Figura 48 - DTMs e Ortofoto referente ao Perfil 02 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	72
Figura 49 - Gráficos QQ Plot e Box Plot gerados para Perfil 02	74
Figura 50 – DTMs e Ortofoto referente ao Perfil 03 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	76
Figura 51 - Gráficos QQ Plot e Box Plot gerados para Perfil 03	78
Figura 52 - DTMs e Ortofoto referente ao Perfil 04 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	80
Figura 53 - Gráficos QQ Plot e Box Plot gerados para Perfil 04	82
Figura 54 - DTMs e Ortofoto referente ao Perfil 05 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	84
Figura 55 - Gráficos QQ Plot e Box Plot gerados para Perfil 05	86
Figura 56 - DTMs e Ortofoto referente ao Perfil 06 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	88
Figura 57 - Gráficos QQ Plot e Box Plot gerados para Perfil 06	90
Figura 58 - DTMs e Ortofoto referente ao Perfil 07 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	92
Figura 59 - Gráficos QQ Plot e Box Plot gerados para Perfil 07	94
Figura 60 - DTMs e Ortofoto referente ao Perfil 08 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF	96

Figura 61 - Gráficos QQ Plot e Box Plot gerados para Perfil 08	98
Figura 62 - Gráficos QQ Plot e Box Plot gerados para áreas com asfalto	101
Figura 63 - Gráficos QQ Plot e Box Plot gerados para áreas com floresta secundária	104
Figura 64 - Gráficos QQ Plot e Box Plot gerados para áreas com araucária	107
Figura 65 - Gráficos QQ Plot e Box Plot gerados para áreas com pinus e eucalipto	110
Figura 66 - Gráficos QQ Plot e Box Plot gerados para áreas com grama e campo nativo	113

LISTA DE TABELAS

Tabela 1 – Aplicações de SF e LF	30
Tabela 2 – Padrões de exatidão PEC - EP	40
Tabela 3 – Lista de materiais	45
Tabela 4 – Especificações de voo e funcionamento do sensor LiDAR Zenmusse L1	52
Tabela 5 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 01	69
Tabela 6 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 02	73
Tabela 7 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 03	77
Tabela 8 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 04	81
Tabela 9 - Estatística descritiva comparativa entre os três algoritmos para o perfil 05	85
Tabela 10 - Estatística descritiva comparativa entre os três algoritmos para o perfil 06.....	89
Tabela 11 - Estatística descritiva comparativa entre os três algoritmos para o perfil 08.....	97
Tabela 12 - Estatística descritiva para os 03 algoritmos para amostras para a cobertura da terra asfalto	100
Tabela 13 - Estatística descritiva para os 03 algoritmos para classe de cobertura da terra floresta secundária.....	103
Tabela 14 - Estatística descritiva para 03 algoritmos para classe de cobertura da terra araucária	106
Tabela 15 - Estatística descritiva para 03 algoritmos para classe de cobertura da terra pinus e eucalipto	109
Tabela 16 - Estatística descritiva para os 03 algoritmos para a classe de cobertura da terra grama e campo nativo	112
Tabela 17 - Média e Desvio Padrão para os três algoritmos aplicados em cada perfil	115

Tabela 18 - RMSE e Erro Padrão para os três algoritmos aplicados em cada perfil e atendimento ao padrão Classe A da Decreto-Lei nº 89.817/84	117
Tabela 19 - Média e Desvio Padrão para os três algoritmos aplicados em cada classe de cobertura de solo	118
Tabela 20 - RMSE e Erro Padrão para os três algoritmos aplicados em cada cobertura de solo e atendimento ao padrão Classe A da Decreto-Lei nº 89.817/84.....	120
Tabela 21 – Tabela resumo de resultados para os 08 perfis.	121

LISTA DE ABREVIATURAS E SIGLAS

ALS	<i>Airborne Laser Scanning</i>
ABNT	Associação Brasileira de Normas Técnicas
ARP	Aeronaves Remotamente Pilotadas
CHM	<i>Canopy Height Model</i>
CNT	Companhia Nacional de Transportes
CSF	<i>Cloth simulation Filter</i>
DAER	<i>Departamento Autônomo de Estradas de Rodagem</i>
DAP	Diâmetro a altura do peito
DEM	<i>Digital Elevation Model</i>
DGPS	<i>Differential Global Positioning System</i>
DSGER	Diretoria do Serviço Geográfico do Exército Brasileiro
DSM	<i>Digital Surface Model</i>
DTM	<i>Digital Terrain Model</i>
ET	<i>Estação Total</i>
GEDI	<i>Global Ecosystem Dynamics Investigation LiDAR</i>
G-LiHT	<i>Goddard LiDAR Hyperespectral and Thermal Imager</i>
GNSS	<i>Global Navigations Sattelite System</i>
GCP	<i>Ground Control Points</i>
H-PLS	<i>Hand-Held Personal Laser Scanning</i>
ICESat-2	<i>Ice, Cloud, and Land Elevation Satellite 2</i>
IDW	<i>Inverse Distance Weighted</i>
IMU	<i>Inertial Measurement Unit</i>
INS	<i>Inertial Navigation System</i>
ISO	Organização Internacional de Normalização
ISRO	<i>Indian Space Research Organisation</i>
LASER	<i>Light amplification by stimulated emission of radiation</i>
LF	<i>Large Footprint</i>
LIDAR	<i>Light Detection and Ranging</i>
MLS	<i>Mobile Laser Scanning</i>
NASA	<i>National Aeronautics and Space Administration</i>
NBR	Normas Técnicas Brasileiras

NISAR	<i>NASA-ISRO Synthetic Aperture Radar</i>
OLS	<i>Orbital Laser Scanning</i>
PBA	Plano básico Ambiental
PEC	Padrão de exatidão cartográfica
PMF	<i>Progressive Morphological Filter</i>
PRF	<i>Pulse Repetition Frequency</i>
PTIN	<i>Progressive Triangulated Irregular Network</i>
RPA	<i>Remotely Piloted Aircraft</i>
RMSE	<i>Root Mean Square Error</i>
RTK	<i>Real Time Kinematic</i>
SF	<i>Small Footprint</i>
SLS	<i>Satellite Laser Scanning</i>
TLS	<i>Terrestrial Laser Scanning</i>
UAV	<i>Unmanned Aerial Vehicle</i>
UHF	<i>Ultra High Frequency</i>

SUMÁRIO

1	INTRODUÇÃO	15
2.	OBJETIVOS	17
2.1	OBJETIVO GERAL	17
2.2	OBJETIVOS ESPECÍFICO	17
3	REFERENCIAL TEÓRICO	18
3.1	RODOVIAS: CONCEITOS BÁSICOS.....	18
3.2	MODELAGEM DE DADOS ESPACIAIS: DTM, DSM E CHM	20
3.3	TECNOLOGIA LIDAR	24
3.3.1	Fundamentos do sistema LIDAR ALS/UAV	29
3.3.2	Processamento de dados LiDAR: classificação/filtragem dos pontos de solo	32
3.4	APLICAÇÕES DO SISTEMA LIDAR NA CIÊNCIA FLORESTAL	32
3.5	APLICAÇÕES DO SISTEMA LIDAR EM RODOVIAS	36
3.6	NORMAS, ACURÁCIA E PRECISÕES DE MAPEAMENTOS.....	38
4	MATERIAL E MÉTODOS	42
4.1	ÁREA DE ESTUDO	42
4.2	MATERIAIS	44
4.3	METODOLOGIA	49
4.3.1	Aquisição de dados LIDAR	50
4.3.2	Levantamento Topográfico Georreferenciado	53
4.3.3	Algoritmos empregados no Processamento de dados LiDAR	64
4.4	DELINEAMENTO EXPERIMENTAL.....	65
4.4.1	Avaliação da acurácia altimétrica	66
5	RESULTADOS	67
5.1	MODELO DSM 3D	67
5.2	RESULTADOS POR PERFIL	68
5.2.1	Perfil 01	68
5.2.2	Perfil 02	72
5.2.3	Perfil 03	76
5.2.4	Perfil 04	80
5.2.5	Perfil 05	84
5.2.6	Perfil 06	88

5.2.7	Perfil 07	92
5.2.8	Perfil 08 comparado entre os três algoritmos	96
5.3	RESULTADOS POR TIPO DE OCUPAÇÃO DE SOLO	99
5.3.1	Resultados estatísticos para região com asfalto	99
5.3.2	Resultados estatísticos para região com floresta secundária	103
5.3.3	Resultados estatísticos para região com araucárias.....	106
5.3.4	Resultados estatísticos para região com pinus e eucalipto	109
5.3.5	Resultados estatísticos para região com grama e campo nativo	112
6	DISCUSSÃO	115
6.1	RESULTADOS AGRUPADOS EM PERFIS	115
6.1.1	Avaliação da acurácia altimétrica de acordo com a Classe A do Decreto-Lei nº 89.817/84.....	116
6.2	RESULTADOS AGRUPADOS EM TIPO DE COBERTURA DA TERRA.....	118
6.2.1	Avaliação da acurácia altimétrica de acordo com a Classe A do Decreto-Lei nº 89.817/84.....	120
6.3	DISCUSSÃO DOS RESULTADOS.....	120
7	CONSIDERAÇÕES FINAIS	124
	REFERÊNCIAS.....	126

1 INTRODUÇÃO

No contexto das engenharias, a precisão e a eficiência no levantamento topográfico da faixa de domínio são cruciais para o planejamento, projeto e manutenção das infraestruturas viárias. Contudo, em muitas ocasiões, a presença de vegetação densa ao longo dessas faixas impõe desafios significativos às metodologias topográficas convencionais. A dificuldade de acesso e a obstrução da linha de visada pelos elementos vegetais frequentemente resultam em processos morosos, dispendiosos e, por vezes, com lacunas informacionais importantes. Diante desse cenário, a busca por tecnologias alternativas que superem essas limitações torna-se imperativa.

No Brasil, de acordo com o Boletim unificado da Companhia Nacional de Transportes (CNT) de agosto de 2023, 64,85% das cargas transportadas no território nacional ocorreram em rodovias (CNT, 2023). Conforme Silva, Martins e Neder (2016) a temática da infraestrutura e sua relação com o desenvolvimento econômico é importante e recorrente na literatura econômica.

Silva, Martins e Neder (2016) destacam que o debate tem se concentrado em analisar e mensurar a relação entre a infraestrutura logística e a atividade econômica, tanto em termos quantitativos quanto qualitativos. No setor florestal, a rede viária desempenha um papel crucial nos processos de produção e suprimento, sendo essencial para as atividades de silvicultura em todas as etapas, desde a produção e colheita até o transporte (Corrêa e Malinovski, 2006).

O Rio Grande do Sul foi atingido por chuvas intensas em maio de 2024, causando extensos danos à sua malha rodoviária. Milhares de quilômetros de estradas foram severamente afetados, e os custos de recuperação são substanciais. Além disso, as adaptações necessárias para tornar a infraestrutura mais resiliente frente às mudanças climáticas representam um investimento considerável para o futuro.

Em cenário oposto, recentemente, foi inaugurado o contorno viário da Grande Florianópolis, com um Plano Básico Ambiental (PBA) implementado pela concessionária responsável pela rodovia. O plano inclui 13 programas ambientais que têm como objetivo monitorar, controlar e mitigar os impactos ambientais no meio físico, biótico e socioeconômico da região onde a rodovia foi construída (ARTERIS, 2024).

Em ambos os cenários mencionados, muitos trechos destas rodovias possuem cobertura florestal que precisa ser adequadamente caracterizada, assim como o relevo devidamente mensurado, tanto para processos de reconstrução quanto para novas implantações.

A necessidade de investir na melhoria da malha rodoviária, e um planejamento eficaz é fundamental para garantir o sucesso na implementação de projetos. A manutenção e a construção de rodovias em áreas com cobertura florestal apresentam não apenas os desafios técnicos habituais da Engenharia, mas também exigem um conhecimento aprofundado sobre a vegetação e seus aspectos dendrométricos. Isso é essencial tanto para otimizar o manejo florestal quanto para identificar, conservar e mitigar danos em fragmentos florestais.

Nesse contexto, a evolução tecnológica nas técnicas para a mensuração e a representação do relevo, se torna essencial para a operação e coleta de dados em projetos rodoviários. Conforme apontado por (Giongo *et al.*, 2010) o uso de perfilamento a laser ou o uso de tecnologia *Light Detection and Ranging* (LiDAR) é eficaz na aquisição de informações geoespaciais sobre grandes áreas em um curto espaço de tempo. Diferentemente das imagens orbitais ou aéreas, a tecnologia de varredura a laser consegue mapear simultaneamente o terreno sob a cobertura das árvores e estimar suas alturas, além de fornecer inferências sobre parâmetros biofísicos

Assim, a tecnologia LiDAR se destaca como uma ferramenta eficaz, capaz de oferecer dados detalhados do relevo e a estrutura das florestas. Com sua capacidade de gerar modelos tridimensionais de alta resolução espacial, o LiDAR permite a coleta de informações de maneira eficiente, superando as limitações dos métodos tradicionais de levantamento.

2. OBJETIVOS

2.1 OBJETIVO GERAL

Avaliar a acurácia altimétrica de Digital Terrain Model (DTM) gerados por dados LiDAR/UAV em áreas com diferentes coberturas da terra ao longo de rodovias.

2.2 OBJETIVOS ESPECÍFICO

a) Avaliar a precisão da tecnologia LiDAR/UAV para uso em levantamentos topográficos em áreas com diferentes coberturas da terra.

b) Comparar a acurácia altimétrica dos DTMs obtidos com diferentes algoritmos de filtragem de dados LiDAR em relação aos levantamentos por topografia convencional.

c) Avaliar a acurácia altimétrica dos DTMs gerados dados LiDAR/UAV de acordo com as normas e padrões brasileiros vigentes para produtos cartográficos.

3 REFERENCIAL TEÓRICO

3.1 RODOVIAS: CONCEITOS BÁSICOS

De acordo com Corrêa e Malinovski (2006) cerca de 30% dos custos de um projeto de estrada estão relacionados ao planejamento e aos projetos. Um planejamento cuidadoso nessa fase inicial é crucial, pois protege as etapas subsequentes, que representam a maior parte dos custos totais. Para essa fase de planejamento e elaboração de anteprojetos, são utilizados mapas e imagens das áreas em questão, o que permite uma base sólida para a construção (implantação dos projetos em campo) e para os procedimentos de manutenção e conservação das estradas.

Durante a fase de planejamento, é realizado um levantamento geral da área, que inclui um levantamento topográfico detalhado, além da análise de diversos fatores como hidrologia, geologia, geotecnia, tipos de solo, clima, localização, dimensão da área, trafegabilidade, recursos financeiros e a rede viária existente. As informações coletadas por meio do levantamento topográfico servirão como fundamento para a elaboração do anteprojeto ou do projeto geométrico (Corrêa e Malinovski, 2006).

Por meio do levantamento topográfico, obtém-se um conjunto de coordenadas tridimensionais que serão utilizadas para representar o terreno. Esses dados servirão para a elaboração de curvas de nível e a geração de perfis do terreno (Medeiros, 1997).

O Projeto Geométrico, conforme destacado é uma das etapas mais críticas no desenvolvimento de projetos de estradas. As atividades que compõem essa fase podem ser agrupadas em quatro categorias principais:

a) Estudo do traçado da estrada: Este estudo envolve a pesquisa de diferentes corredores possíveis para a estrada, buscando minimizar a interferência no ambiente natural;

b) Projeto geométrico em planta: Nesta fase, os alinhamentos da estrada, que são entidades tridimensionais, devem ser projetados para interagir adequadamente com elementos planimétricos (horizontal) e altimétricos (vertical);

c) Projeto Geométrico em perfil: Também conhecido como greide ou projeto vertical, determina as declividades e elevações ao longo da estrada, assegurando que esses limites sejam respeitados;

d) Secções Transversais: Esta etapa define a largura da faixa de tráfego, a dimensão do acostamento, os tipos de sarjeta, e a inclinação dos taludes, tanto de cortes quanto de aterros.

O Projeto Geométrico é fundamental para viabilizar estudos subsequentes, como o planejamento de movimentação de terras (projeto de terraplanagem) e de drenagem. Além disso, ele está interligado a outros projetos essenciais para a construção de uma estrada, incluindo: projetos de sinalização, paisagismo, desapropriação, pavimentação, obras de arte especiais, interseções e obras complementares. Todos esses projetos estão inter-relacionados e dependem do projeto geométrico para sua execução eficaz (Medeiros, 1997).

Em rodovia já existentes, os limites são definidos conforme projeto executivo da rodovia, decretos de utilidade pública, ou em projetos de desapropriação. O Departamento Autônomo de Estradas de Rodagem (DAER) é responsável pela desapropriação, administração e fiscalização das Faixas de Domínio Público das rodovias estaduais.

A Faixa de Domínio é a área que abriga todos os componentes de uma rodovia, incluindo pistas de rolamento, canteiros, acostamentos, sinalização e faixas laterais de segurança, estendendo-se até o limite que separa a estrada das propriedades adjacentes. Essa faixa é de propriedade do Estado e é considerada um bem de uso comum do povo, conforme garantido pelo Art. 99 do Código Civil Brasileiro (BRASIL,2002).

Figura 1 – Representação de uma faixa de domínio de rodovias



Fonte: DAER (2025)

3.2 MODELAGEM DE DADOS ESPACIAIS: DTM, DSM E CHM

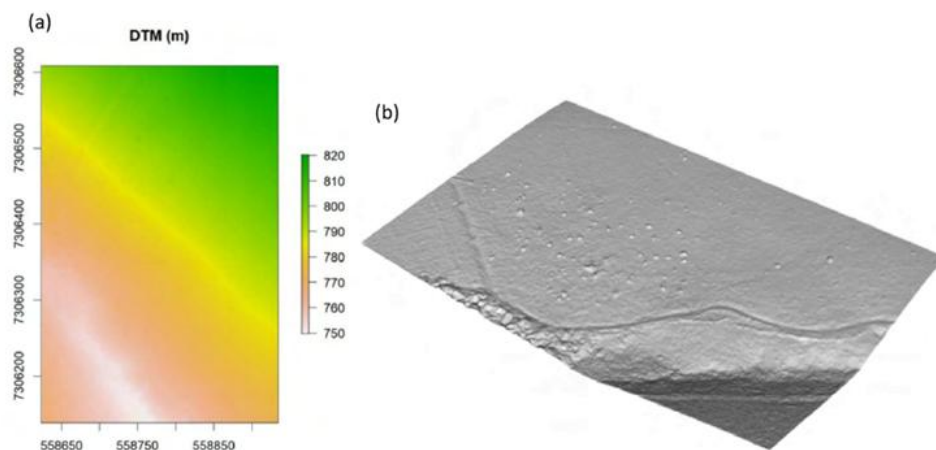
De acordo com Fitz (2008), os dados espaciais possuem características únicas que podem levar a interpretações variadas por parte dos usuários. Assim, ao utilizar modelos que seguem padrões conceituais, a compreensão do ambiente de estudo torna-se mais acessível para aqueles que os utilizam e precisam compreender a área em questão.

A conversão de informações geográficas da superfície terrestre para uma base de dados virtual envolve várias etapas de modelagem, tais como: elaboração de uma lista de aspectos fundamentais, coleta de dados, realização de levantamentos de campo para observação e coleta de informações, estruturação de um banco de dados, análise dos dados e representação do modelo resultante (Fitz, 2008).

Nesse contexto, modelos digitais são utilizados para representar informações tridimensionais. O DTM (*Digital Terrain Model*) atribui uma dimensão Z, correspondente à elevação, altura ou altitude, permitindo visualizar a distribuição espacial das características da superfície por meio de equações analíticas ou grades regulares e irregulares. Com o DTM, é possível calcular volumes, áreas, criar perfis, gerar curvas de nível e mapas de declividade e exposição, entre outros produtos (Dalla Corte *et al.*, 2022).

Os DEM (*Digital Elevation Model*) são representações digitais da configuração espacial da altitude em uma determinada área, podendo ser exibidos tanto em formato 2D quanto em 3D.

Figura 2 - (a) DTM representado em 2D, (b) hillshade do DTM em 3D




Fonte: adaptado de Dalla Corte *et al.* (2022)

No exemplo apresentado na Figura 2, as células que representam a elevação do solo são distinguidas por uma paleta de cores ou tons de cinza. Na figura (a) o MDT está representado em 2D, com elevações variando entre 750 e 820 metros; já na figura (b) o MDT está em 3D, tons de cinza mais claros indicam pontos mais altos e tons mais escuros representam áreas mais baixas.

O DSM (*Digital Surface Model*) representa a superfície do terreno, considerando a elevação de todos os elementos que se encontram acima do solo, incluindo tanto componentes naturais, como árvores, quanto artificiais, como edificações (Figura 3).

Figura 3 - DSM da região do entorno do Ginásio Jones Minosso em Lages/SC



Fonte: Elaborada pelo autor (2024)

O CHM (*Canopy Height Model*), ou Modelo de Altura de Copas, é utilizado para extrair as alturas das árvores a partir de dados de varredura a laser. Este modelo é geralmente obtido por meio de um processo matemático, que envolve a subtração entre os valores Z oriundos do DSM e DTM/DEM (Giongo et al., 2010).


O uso de sensor ALS é uma das mais recentes tecnologias para a obtenção de modelos digitais, com alta resolução espacial, em curto espaço de tempo e que competem também em custos. O uso dessa tecnologia integrada na geração de DTM constitui uma área de pesquisa bastante ativa e tem sido objeto de muitos estudos científicos recentes (Franco, 2006).

De acordo com Giongo *et al.* (2010) A qualidade dos DTMs e DSMs é crucial para a precisão das estimativas de altura derivadas de dados LiDAR, especialmente ao gerar o CHM. Em áreas com cobertura florestal, é essencial que os pulsos de laser

atingam adequadamente o solo, atravessando as folhagens e galhos para garantir a criação de modelos precisos.

Na Figura 4, o perfil da área apresenta uma seção transversal que ilustra as variações de elevação do terreno e das copas das árvores. Essa representação é fundamental para entender a estrutura da vegetação e a topografia da região, incorporando dados sobre o DSM, CHM e DTM.

Figura 4 - Perfil representativo dos modelos DSM, CHM e DTM



Fonte: Omar et al. (2015)

Nas aplicações LiDAR para obtenção de DTM, realizar a filtragem do solo é uma etapa essencial para identificar quais retornos do LiDAR correspondem à superfície do solo e quais são de elementos que não fazem parte dela. Diferenciar entre o solo e as características não pertencentes ao solo pode ser um desafio considerável em áreas com alta variabilidade da superfície. Superfícies cobertas com vegetação florestal densa são exemplos de áreas em que este desafio se torna ainda maior (Meng; Currit; Zhao, 2010).

De acordo com Andrade *et al.* (2018) para superar esses desafios, foram criados diversos algoritmos fundamentados em filtros de segmentação, filtros morfológicos, filtros baseados em contornos, filtros de redes trianguladas irregulares e filtros de interpolação

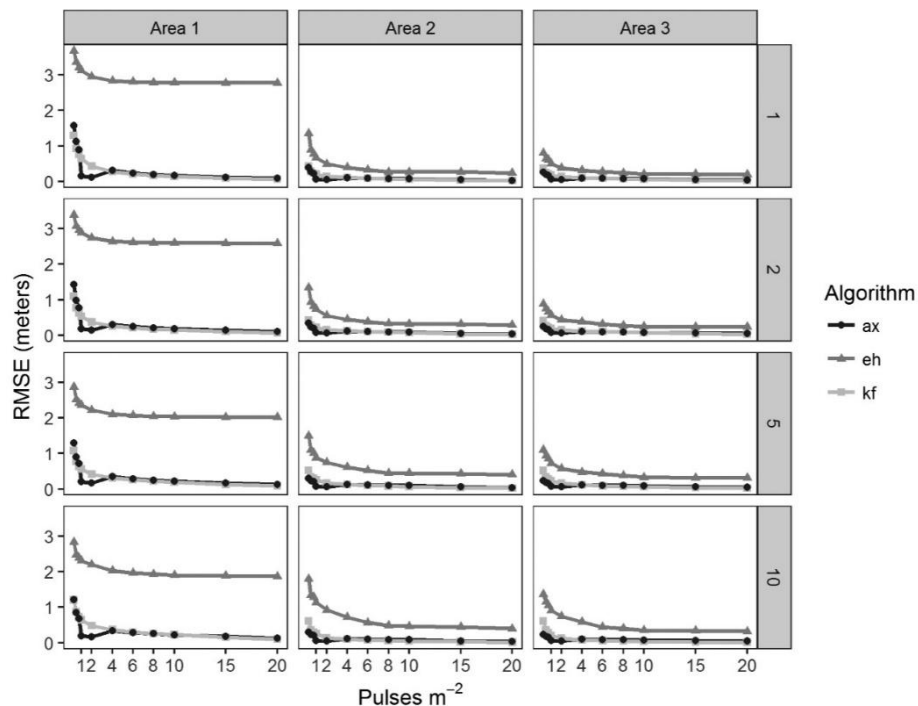
A classificação incorreta dos retornos do solo pode causar erros no DTM, sendo a precisão deste influenciada por fatores como densidade e distribuição das amostras, algoritmos de filtragem e resolução espacial. A densidade de pulsos (pontos ou pulsos por m²), pode ser aumentada através de vários ajustes nos parâmetros de voo, embora isso eleve os custos de aquisição. Os custos de levantamento LiDAR variam

bastante, e aumentar a área coberta e otimizar os parâmetros de voo pode resultar em otimização de recursos (Andrade *et al.*, 2018).

O estudo de Andrade *et al.* (2018) demonstrou que é viável criar DTMs consistentes mesmo a partir de nuvens de LiDAR de baixa densidade na floresta amazônica se combinado a determinados filtros. Embora a qualidade do MDT diminua com a redução da densidade de pulsos, ajustes na resolução horizontal podem minimizar essas diferenças. A pesquisa sugere que a otimização dos parâmetros de voo pode melhorar a precisão dos MDTs em projetos de monitoramento florestal na Amazônia.

A Figura 5 exibe o Erro Médio Quadrático da Raiz (RMSE) em metros em função da densidade de pulsos (pulsos por m²) para três algoritmos diferentes (ax, eh, kf) em três áreas da floresta amazônica brasileira: Floresta Cauaxi, no estado do Pará (Área 1), e Floresta Nacional do Jamari, no estado de Rondônia (Áreas 2 e 3) e quatro níveis diferentes. De modo geral, o RMSE diminui à medida que a densidade de pulsos aumenta para todos os algoritmos e áreas, indicando que densidades de pulsos mais altas levam a estimativas mais precisas. O algoritmo 'ax' consistentemente apresenta o menor RMSE na maioria das densidades de pulsos e áreas.

Figura 5 – Relação entre RMSE e Densidade de Pulsos por Algoritmo e Área



Fonte: Andrade *et al.* (2018)


Em 2024, Tamimi et al. conduziram um estudo utilizando o DJI Matrice 350 RTK com o sensor DJI Zenmuse L2 LiDAR para mapear um campo de golfe em Michigan, Ohio. Os resultados evidenciam as capacidades e limitações da tecnologia LiDAR em diferentes ambientes. Em áreas abertas, o sensor apresentou um RMSE de cerca de 0,07 metros, mostrando-se uma alternativa eficaz aos métodos tradicionais de levantamento para infraestrutura. No entanto, em locais ocupados por cobertura florestal, o RMSE aumentou para aproximadamente 0,21 metros, sublinhando as dificuldades na penetração da vegetação e seu impacto na precisão.

3.3 TECNOLOGIA LIDAR

O acrônimo LiDAR (*Light Detection and Ranging*), que se refere a uma técnica de sensoriamento remoto ativo, é conhecido em português como Sistema de Varredura a Laser. Essa tecnologia utiliza a amplificação da luz por emissão estimulada de radiação para medir distâncias e criar representações tridimensionais de superfícies (Dong e Chen, 2018).

O LiDAR então é um sensor que pode equipar estruturas e veículos tanto terrestres quanto aéreos. Quando equipam veículos ou estruturas terrestres recebem a nomenclatura de TLS (*Terrestrial Laser Scanning*). Com o sensor embarcado em um veículo aéreo passar a ser designado de ALS (*Airborne Laser Scanning*). O LiDAR ainda pode ser transportado em satélites recebendo a nomenclatura de OLS (*Orbital Laser Scanning*) ou SLS (*Satellite Laser Scanning*). A Figura 6 apresenta os diferentes níveis de aquisição para o sensor LiDAR.

Figura 6 – Níveis de operação do sensor LiDAR



Fonte: Beland et al. (2015)

Quando terrestres, os sistemas podem ser estáticos (TLS) e quando dinâmicos recebem a sigla MLS (*Mobile Laser Scanning*). Os modelos estáticos, conforme ilustrado na Figura 7, são amplamente utilizados em levantamentos topográficos 3D, com aplicações significativas na construção civil, na mensuração de estoques em indústrias de mineração e no mapeamento de minas. Além disso, esses sistemas têm diversas aplicações na área florestal.

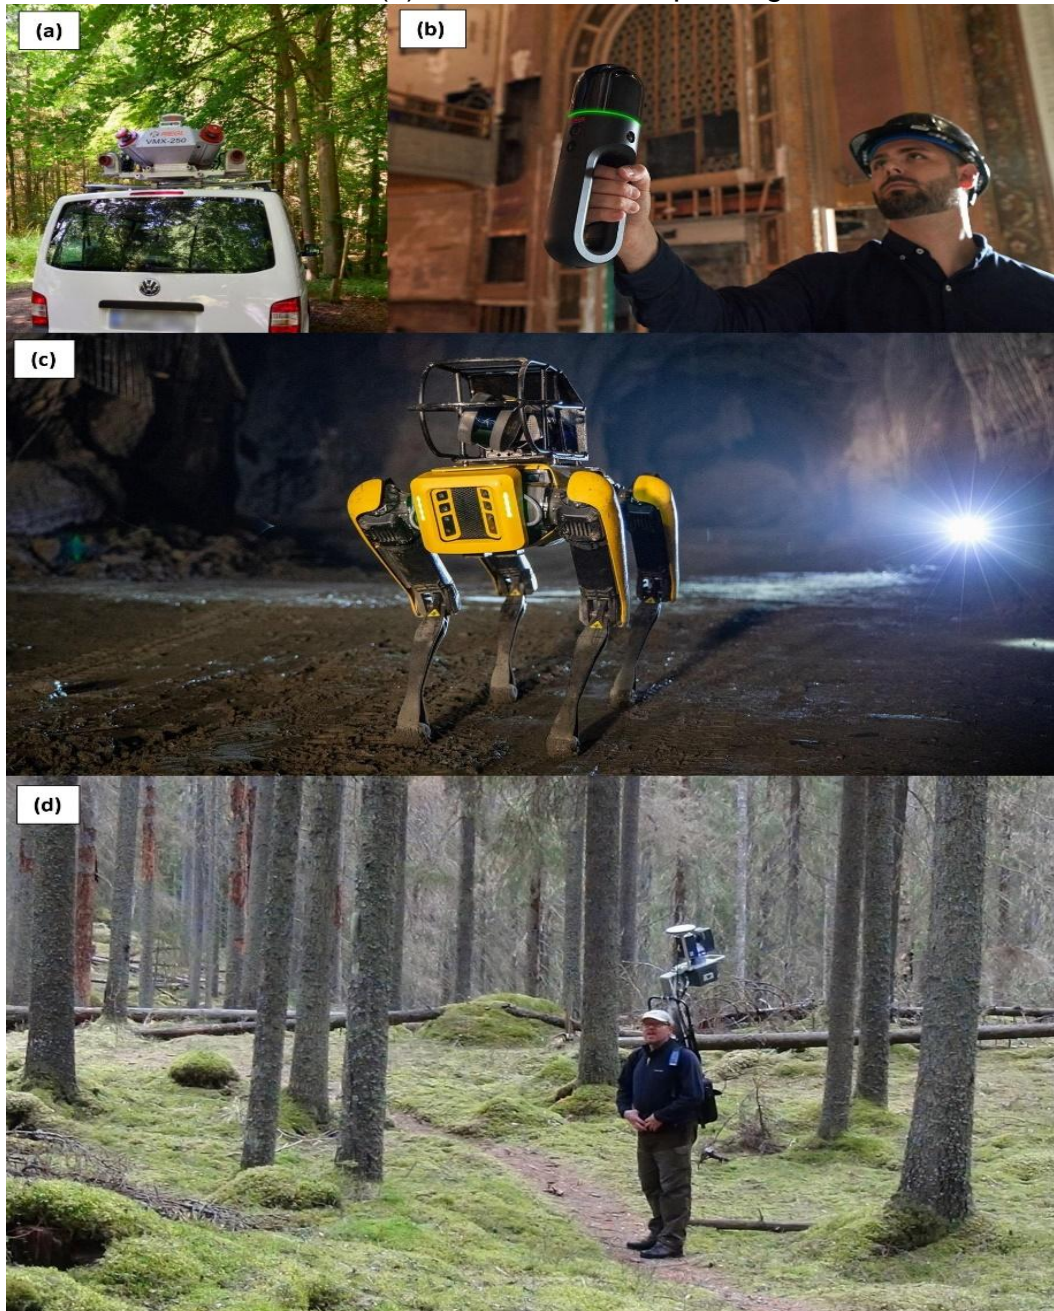
Figura 7 - FARO Focus3D TLS



Fonte: Cabo et al. (2018)

Os equipamentos dinâmicos por sua vez podem receber uma variação maior de nomenclatura como: MLS (*Mobile Laser Scanning*) embarcados em automóveis ou em um robô. Ainda podem ser WLS (*Wearable Laser Scanning*) quando utilizados em mochila (*backpacking*) ou H-PLS (*Hand-Held Personal Laser Scanning*) quando são portáteis de mão. A Figura 8 ilustra esses níveis de aquisição de dados.

Figura 8 – (a) MLS embarcado em uma van, (b) H-PLS Leica BLK2go, (c) Spot Robot, (d) WLS LiDAR backpacking



Fonte: (a) adaptado de Bienert *et al.* (2018), b) <https://leica-geosystems.com>
(c) <https://bostondynamics.com>, (d) <https://www.gim-international.com>

Os sistemas ALS são integrados a aeronaves de asa fixa ou rotativa, que operam em altitudes que variam de 500 a 3.000 metros. Esses sistemas demonstram um grande potencial para o monitoramento florestal em diversos tipos de florestas. No entanto, seu uso em larga escala tem sido restringido devido aos altos custos envolvidos na aquisição de dados e na operação dessas aeronaves

De acordo com Giongo *et al.* (2010) a tecnologia ALS apresenta um grande potencial para aplicações florestais, pois permite a obtenção de uma vasta quantidade de pontos com elevada precisão, a um custo reduzido e com rapidez na aquisição dos dados sobre a estrutura vertical e horizontal das áreas florestais.

Um exemplo notável é o sistema Goddard G-LiHT (*Goddard LiDAR Hyperespectral and thermal*), desenvolvido pela NASA (*National Aeronautics and Space Administration*). Este sistema integra sensores LiDAR, hiperspectrais e térmicos em uma única plataforma, possibilitando medições simultâneas da estrutura da vegetação, espectros e temperaturas de superfície, tudo com uma resolução espacial de cerca de 1 metro. Adicionalmente, o sistema pode ser embarcado em diversas plataformas aéreas; na Figura 9, está ilustrada uma aeronave Cessna.


Figura 9 – Cessna 206 com G-LiHT



Fonte: Adaptado de Cook *et al.* (2013)

O uso de aeronave UAV (*Unmanned Aerial Vehicle*) pode reduzir significativamente os custos operacionais além de adicionar mais mobilidade ao sistema. O sistema LiDAR pode ser instalado em UAVs de asa fixa, bem como em UAVs de asas rotativas. Esses equipamentos geralmente operam a altitudes que variam de 40 a 120 metros, o que é consideravelmente mais baixo do que os sistemas ALS. A Figura 10 ilustra alguns exemplos desses UAVs.

Figura 10 – (a) DJI Matrice 200, (b) VTOL do UAV FengHu



Fonte: (a) Elaborado pelo autor (2023), (b) Wuhan Hi-Cloud Technology Co.,Ltda (2024)

Os UAVs de baixo custo vêm se popularizando no meio das engenharias, facilitando o processo de geração de produtos cartográficos. A exemplo disso, Laporte-Fauret et al. (2019) descrevem o uso de VANTs (DJI Phantom 2 e 4 Pro) para mapear dunas costeiras na França, propondo uma abordagem fotogramétrica de baixo custo e replicável para monitoramento. Com *ground control points* (GCP) permanentes, é possível gerar DSM precisos e analisar a evolução morfológica das dunas em alta resolução temporal e espacial, sendo uma ferramenta valiosa para a pesquisa e gestão costeira.

A complexidade da regulamentação e licenciamento para o mapeamento por drones é um grande desafio. As leis variam em níveis local, estadual e nacional, exigindo licenças demoradas e um profundo conhecimento das normas para garantir a conformidade e evitar interrupções. Apesar disso, o avanço em sensores e algoritmos é promissor para o futuro da coleta de dados geoespaciais (Gomes et al., 2024).

Chicati et al. (2019) comparou o georreferenciamento de imóveis rurais em divisas de difícil acesso, utilizando UAVs em contraste com o posicionamento GNSS direto. Os resultados mostram que os UAVs são uma alternativa viável para o mapeamento de pequenas áreas, gerando cartas planimétricas com boa acurácia. Isso evidencia as vantagens do uso de drones na coleta de informações geoespaciais

em locais de difícil acesso, com todo o processo regulamentado e em conformidade com as normas vigentes para o georreferenciamento de imóveis rurais.

3.3.1 Fundamentos do sistema LIDAR ALS/UAV

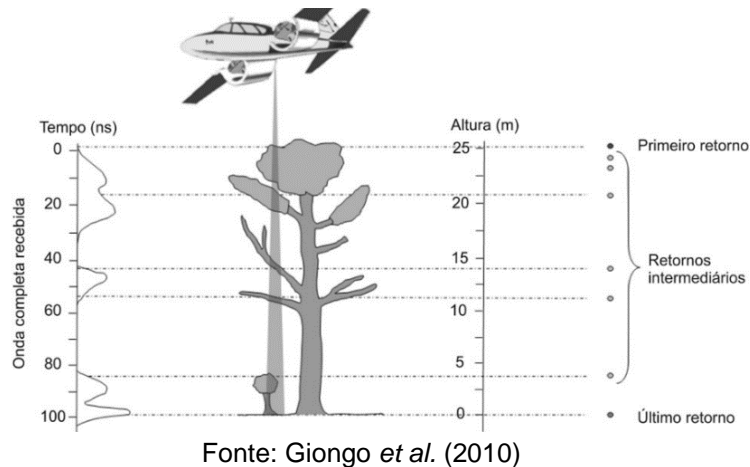
O princípio de funcionamento consiste na emissão de feixe multidirecional LASER (*light amplification by stimulated emission of radiation*) à superfície terrestre, onde estes são refletidos pelos obstáculos (construções, vegetação ou terreno) e captados pelo sensor. Para cada feixe emitido é registrado o tempo de percurso aeronave – obstáculo – aeronave, permitindo ao sistema realizar o cálculo da distância (Zandoná, Lingnau e Nakajima, 2008).

A principal característica que distingue essa tecnologia das outras é a capacidade do pulso laser multidirecional de penetrar nos espaços entre as árvores e alcançar o solo. Isso permite a geração de modelos digitais de terreno, DTM (*Digital Terrain Model*) em áreas com cobertura florestal (Dong e Chen, 2018).

Os sistemas LiDAR aerotransportados normalmente utilizam lasers com comprimentos de onda variando de 1000 a 1600 nm (Dong e Chen, 2018). A emissão de feixes multidirecionais é realizada por um sensor ativo que emite vários pulsos por meio de um espelho rotativo. A frequência de emissão de pulsos, conhecida como PRF (*Pulse Repetition Frequency*), indica o número de pulsos de laser emitidos por segundo e é medida em kHz.

Quando um pulso de laser atinge uma área florestada, a primeira reflexão normalmente corresponde às partes mais elevadas das copas das árvores. Com base nessas altitudes máximas dentro de uma área específica, é possível construir um Modelo Digital de Superfície (MDS). Em contrapartida, os últimos retornos (*last return*) tendem a se aproximar do terreno verdadeiro ou solo, embora a densidade da vegetação ainda possa introduzir dados de pontos intermediários da estrutura arbórea (Giongo *et al.*, 2010).

Figura 11 – Representação dos pulsos LiDAR



Footprints é uma unidade fundamental na tecnologia LiDAR, definido pelo diâmetro (D) do feixe de laser que ilumina a superfície terrestre. Em geral, os *Footprints* são classificados em dois tamanhos: *Small Footprint* (SF), que se refere a diâmetros de até 5 metros ($D \leq 5$ m), e *Large Footprint* (LF), para diâmetros superiores a 5 metros ($D > 5$ m). Os sistemas SF são frequentemente utilizados em aplicações de ALS e TLS (Yang *et al.*, 2021)

Means (1999) organizou em seu estudo as principais aplicações dos dois tamanhos de footprint, conforme apresentado na Tabela 1.

Tabela 1 – Aplicações de SF e LF

Small Footprint	Large Footprint
<ul style="list-style-type: none"> • DTMs (Modelos Digitais de Terreno) são utilizados em diversas aplicações, incluindo: estradas, linhas de alta-tensão, gasodutos, minas e aterros sanitários • Levantamentos urbanos/Suburbanos: Descrições quantitativas em 3D que incluem vegetação e edificações. • Detecção de Mudanças: Monitoramento de alterações nas características levantadas. • Altura de Árvores de Floresta • Volume de Estoque • Integração com Imagens Raster e Fotografias Aéreas • Agricultura de precisão, drenagem agrícola • Automatização de modelagem • Monitoramento de vida selvagem • Monitoramento de dinâmica hídrica 	<ul style="list-style-type: none"> • DTMs e Topografia: glaciares, vulcões, área de risco de erosão, área extensas • Detecção de Mudanças: Monitoramento de alterações nas características levantadas. • Altura de Árvores de Floresta • Volume de Estoque • Área basal de florestas • Topografia da cobertura global, densidade de vegetação, espessura de camada de gelo e rugosidade da superfície • Integração e correlação com imagens raster

Fonte: Means (1999)

Giongo *et al.* (2010) analisam diversos estudos na área florestal relacionados ao Modelo de Altura de Copas – CHM (*Canopy Height Model*) para footprints com diâmetros que variam de 0,11 m a 3,00 m. Estes estudos vêm demonstrando um grande potencial de aplicação para estimativas florestais.

O sistema de posicionamento de um UAV/ALS é composto por um Sistema Inercial de Navegação - INS (*Inertial Navigation System*) e um receptor GNSS (*Global Navigations Sattelite System*). Um INS utiliza uma Unidade de Medição Inercial - IMU (*Inertial Measurement Unit*).

Segundo Giongo *et al.* (2010) um IMU é constituído por uma série de acelerômetros (medição de força específica) e giroscópios (detecção de movimentos de rotação), com um circuito de digitalização e uma unidade de cálculo de posição, velocidade e orientação. O IMU deve ser posicionado o mais perto possível do sensor para representar com maior fidelidade possível o movimento do ponto de interesse (Figura 12).

Figura 12 – Sensor LiDAR e detalhe da localização do IMU



Fonte: Elaborada pelo autor (2023) e DJI (2024)

O receptor GNSS utiliza técnicas de posicionamento RTK ou DGPS que operam no modo diferencial. No método RTK (Real-Time Kinematic), as correções dos sinais GNSS são enviadas em tempo real de uma estação de referência (com coordenadas já conhecidas) para a estação móvel, que neste caso é o UAV. Geralmente, essas correções são transmitidas via rádio UHF da estação base para o

módulo GNSS/RTK instalado no UAV, permitindo que ele determine sua posição com alta precisão (Giongo *et al.*, 2010).

3.3.2 Processamento de dados LiDAR: classificação/filtragem dos pontos de solo

Segundo Pacheco *et al.* (2011) um DTM é obtido a partir da exclusão dos pontos que correspondem a objetos acima do terreno do solo ou terreno, requerendo a identificação (classificação) de tais pontos da nuvem de pontos LiDAR.

É sabido que em uma nuvem de pontos LiDAR é possível identificar e classificar os pontos em diferentes classes como solo exposto, árvores, corpos d'água, construções, veículos e outros diversos elementos conforme o ambiente de estudo. A classificação correta dos pontos de solo oriundo de uma nuvem de pontos LiDAR é a etapa fundamental para geração de uma DTM preciso.

De acordo com Zhang *et al.* (2003) existem dois erros básicos na classificação de medições LiDAR por praticamente qualquer método de filtragem. Um é o erro que classifica pontos não terrestres como medições terrestres. O outro é o erro resultante da remoção de pontos terrestres.

Diversos algoritmos de filtragem de solo surgiram nas últimas décadas, sendo categorizados principalmente em três tipos: baseados em declive, morfologia matemática e superfície. Uma premissa comum dos algoritmos baseados em declive é que o terreno apresenta uma mudança gradual na inclinação, enquanto a transição entre estruturas como edifícios ou árvores e o solo é abrupta (Zhang *et al.*, 2016).

3.4 APLICAÇÕES DO SISTEMA LIDAR NA CIÊNCIA FLORESTAL

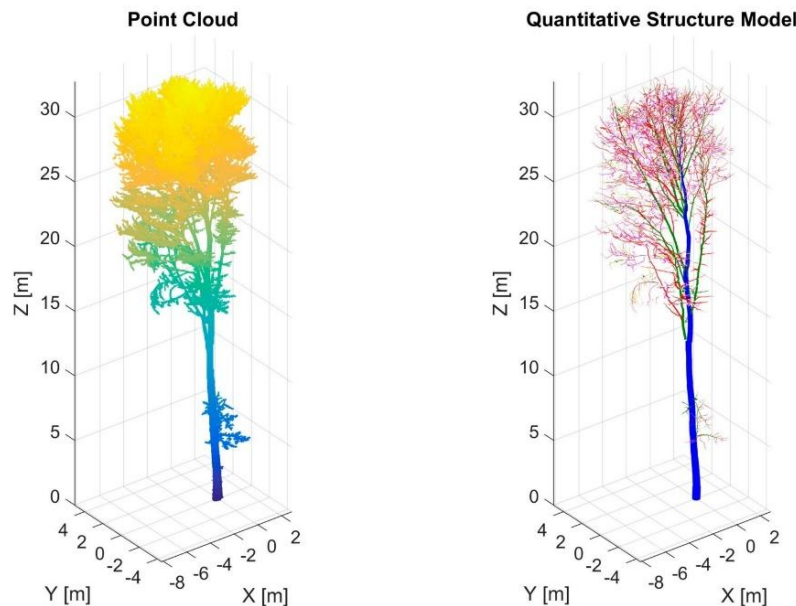
As aplicações da tecnologia LiDAR na ciência florestal são numerosas, e novas utilizações continuam a ser desenvolvidas.

Dalla Corte *et al.* (2022) destaca que o emprego do LiDAR era observado principalmente ligado a pesquisa. Porém, com o passar dos anos, as empresas do segmento florestal começaram a testar e incorporar o uso dessa tecnologia em trabalho de campo e, atualmente, algumas já incorporaram de forma efetiva o emprego dessa técnica na geração de estimativas para seus povoamentos florestais.

Estimativas de variáveis dendrométricas já vem sendo validadas como no estudo de Cabo *et al.* (2018), que comparou TLS e WLS para estimativas de DAP (diâmetros à altura do peito) e altura total de árvores individuais. Os autores concluem que ambas as tecnologias são equivalentes com algumas limitações como, por exemplo, quando avaliadas árvores muito altas a precisão tende a ser menor.

Bienert *et al.* (2018), ampliam os estudos para além das estimativas de DAP e altura total utilizando TLS ou MLS, aprimorando estudos de posicionamento, projeção de copa das árvores, projeção das árvores com folha e sem folha, além de quantificação do volume de biomassa (Figura 13).


Figura 13 – Nuvens de pontos uma árvore da espécie Faia-europeia (*Fagus sylvatica*) com o modelo estrutural extraído da folhagem



Fonte: Bienert *et al.* (2018)

Na caatinga, Nishiwaki *et al.* (2023) tem aplicado o LiDAR na contabilização de árvores e na determinação de sua altura e do diâmetro da copa, e por conseguinte, aplicando em equações alométricas para estimativa dos estoques de carbono na vegetação. A Figura 14 mostra o ambiente utilizando o TLS, assim como referências artificiais de área e volume (esferas) posicionadas na cena.

Figura 14 – TLS sendo utilizada na caatinga



Fonte: Nishiwaki et al. (2023)

Ainda envolvendo atributos florestais Balenović *et al.* (2021) alerta para problemas com posicionamento e mapeamento de árvores isoladas levando em consideração a degradação do sinal GNSS no interior de um ambiente florestal. Tal problema não é enfrentado quando se utiliza ALS.

Os resultados do uso de ALS em áreas de floresta primária sujeitas a manejo florestal na Amazônia apresentam grandes vantagens, considerando os altos custos e esforços realizados para realizar um inventário tradicional em campo. Além disso, o sensor ALS gera informações estratégicas para o planejamento da exploração madeireira e conservação da paisagem florestal (Papa *et al.*, 2020). Os mesmos autores ainda afirmam que o uso do ALS na diferenciação de padrões florestais está associado com estimativas melhoradas, redução de erros de previsão e otimização do esforço amostral de inventários florestais tradicionais.

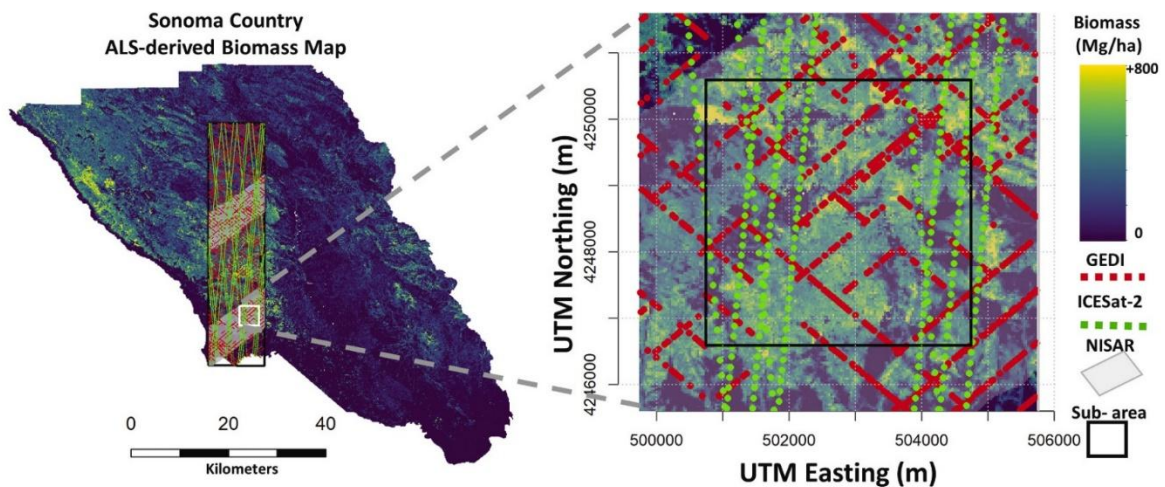
Lin *et al.* (2024) apresentam um potencial promissor para a estimativa de volume de material combustível, como a vegetação morta, por meio da tecnologia LiDAR. Essa abordagem aprimora as condições de pesquisa e a previsibilidade de incêndios florestais na Europa.

A nível orbital, em 2019, a NASA lançou uma missão, chamada GEDI (*Global Ecosystem Dynamics Investigation LiDAR*), objetivando a obtenção de dados de altura de dossel florestal e estrutura vertical da vegetação e elevação da superfície, a fim de aumentar a capacidade de caracterizar processos de ciclo do carbono e da água, biodiversidade e *habitat* (Dalla Corte *et al.*, 2022).

Duncanson *et al.* (2020) concentram seus estudos em três missões espaciais: GEDI, ICESat-2 (Ice, Cloud, and Land Elevation Satellite 2) e NISAR (*Synthetic Aperture Radar*) da NASA em colaboração com a Organização de Pesquisa Espacial da Índia – ISRO (Indian Space Research Organisation). A finalidade é simular três conjuntos de dados para avaliar e comparar métodos de estimativa de biomassa, destacando como cada um contribui (ou limita) o mapeamento da estrutura florestal.

Silva *et al.* (2021) criaram modelos digitais que combinam dados do GEDI, ICESat-2 e NISAR com mapas de biomassa gerados pelo sistema de sensoriamento LiDAR (ALS) no programa de Sonoma County, na Califórnia (Figura 15).

Figura 15 - Mapas de biomassa do programa *Sonoma County*

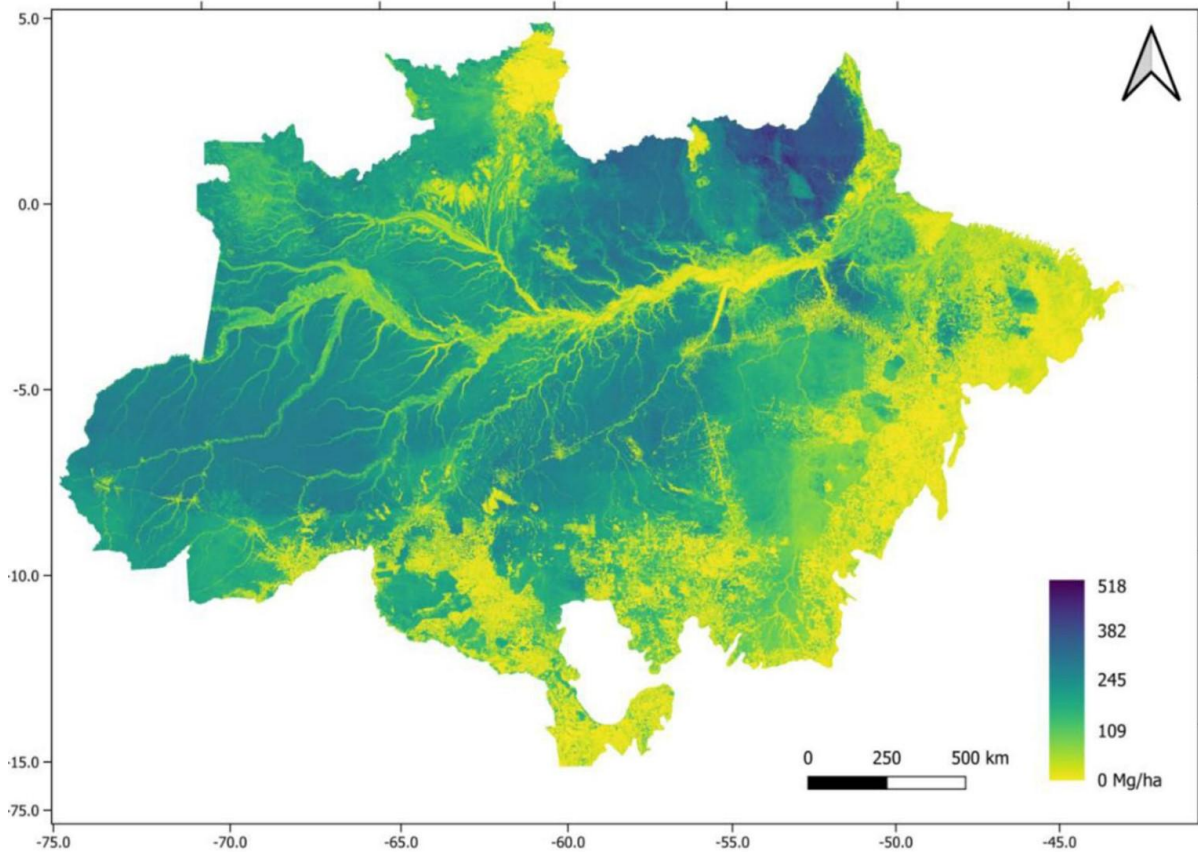


Fonte: Silva *et al.* (2021)

Mapas de biomassa para grandes áreas podem ser gerados utilizando dados LiDAR de ALS, como demonstrado no estudo de Ometto *et al.* (2023) que emprega o maior banco de dados de LiDAR aerotransportado já coletado na Amazônia, mapeando 360 mil km² por meio de transectos distribuídos em todas as categorias de vegetação da região. O mapa é elaborado com dados ALS, calibrados por inventários florestais de campo e extrapolados para a região utilizando informações do Radar de Abertura Sintética (PALSAR).

A Figura 16 apresenta o mapa de biomassa da região amazônica, elaborado a partir de dados obtidos por sensoriamento remoto, especificamente utilizando informações de LiDAR e Radar, conforme relatado por Ometto *et al.* (2023).

Figura 16 – Mapa de biomassa da Amazônia



Fonte: Ometto et al. (2023).


3.5 APLICAÇÕES DO SISTEMA LIDAR EM RODOVIAS

A utilização da tecnologia LiDAR em projetos de estradas florestais transcende o simples levantamento topográfico básico, oferecendo uma gama de aplicações que potencializam a eficácia e a sustentabilidade dos projetos.

Em 2005, Schafer et al. comprovaram a utilidade da tecnologia LiDAR em projetos de rodovias. Eles realizaram um voo com um sistema ALS a 1000 metros de altura para auxiliar na concepção e no anteprojeto da rodovia SC-414, cobrindo uma área de 1,02 km². O objetivo desse voo era gerar DTMs e integrar o projeto geométrico da rodovia. A densidade dos pontos coletados variou entre 0,021 e 0,099 pontos/m² para a superfície terrestre, sendo que esses dados foram filtrados manualmente. A Figura 17 mostra os resultados do trabalho de (Schäfer e Loch, 2004). Na Figura 17a,

temos o *Hillshade* em representação 2D, enquanto na Figura 17b, a representação em 3D, ambas incorporando o anteprojeito geométrico da Rodovia SC-414.

Figura 17 – *Hillshade* com o anteprojeito de trecho da Rodovia SC-414



Fonte: Schafer *et al.* (2005)

Azizi, Najafi e Sadeghian (2014) desenvolveram um método de três fases para extrair leitos de estradas a partir de dados LiDAR. O processo inicia com a interpolação dos dados da nuvem de pontos (primeiro e último pulsos) utilizando o método IDW, gerando as camadas DSM e DTM. Na segunda fase, a nuvem de pontos é classificada em duas categorias distintas: "rodoviário" e "não rodoviário". Por fim, a terceira etapa consiste na definição das bordas da estrada a partir das camadas extraídas. Essa abordagem se mostrou eficaz ao fornecer informações rodoviárias completas e precisas, sendo um valioso suporte para dados de inventário e manejo florestal.

Um método semelhante é descrito em Soilán *et al.* (2019) conforme Figura 18 que classifica a nuvem de pontos em pontos de solo, pontos de não solo e pontos de borda de rodovias.

Figura 18 – Classificação de nuvem de pontos




Fonte: Soilán *et al.* (2019)

As condições e a localização das estradas florestais podem ser rapidamente analisadas em ambientes com cobertura florestal utilizando dados LiDAR. De acordo com o estudo de Matinnia *et al.* (2018) que comparou levantamentos topográficos realizados com Estação Total (ET) e LiDAR, foi possível alcançar acurácias de até 0,23 m em projetos de terraplanagem.

Atualmente, bancos de dados baseados em LiDAR têm sido utilizados para detectar e extrair automaticamente não apenas a superfície das estradas, mas também diversos elementos e características associadas, como marcações viárias, faixas de rodagem, placas de sinalização, além de rachaduras e buracos na via, como pode ser visto da Figura 19 (Soilán *et al.*, 2019).

Figura 19 – Detecção de faixas de rodovia através do sistema LiDAR



Fonte: Soilán *et al.* (2019)


3.6 NORMAS, ACURÁCIA E PRECISÕES DE MAPEAMENTOS

É crescente o aumento da utilização de UAV, por ser uma tecnologia economicamente viável e de simples manuseio, logo, se faz necessário o conhecimento da confiabilidade e acurácia dos seus produtos, especialmente na aplicação cartográfica (Barbosa *et al.*, 2021).

A medição de uma grandeza seja ela qual for a natureza exige um conjunto de atividades executados com cuidado para se obter qualidade e precisão almejada (Menzoni, 2017).

Monico *et al.* (2009) em seu artigo utiliza as definições de Mikhail e Ackermann (1982), onde apresentam acurácia como sendo o grau de proximidade de uma estimativa com seu valor real (parâmetro de campo). Já a precisão é definida como o grau de consistência da grandeza medida com sua média, ou seja, alta precisão é sinônimo de baixa dispersão dos dados.

Figura 20 – Diferença entre Acurácia e Precisão



Fonte: Monico *et al.* (2009)

O Brasil estabelece, por meio da NBR 13133, elaborada pela ABNT (Associação Brasileira de Normas Técnicas), diretrizes e requisitos essenciais para a realização de levantamentos topográficos.

O padrão de acurácia posicional brasileira é fundamentado primeiramente no DECRETO Nº 89.817, de 20 de junho de 1984, que regulamenta as Normas Técnicas da Cartografia Nacional. Esse decreto determina as normas que devem ser seguidas por entidades públicas e privadas envolvidas na produção e utilização de serviços cartográficos, abrangendo atividades correlatas, sendo conhecido como "Instruções Reguladoras das Normas Técnicas da Cartografia Nacional" (Decreto 89.817, BRASIL, 1984).

Antes dessa regulamentação, o Decreto-Lei nº 243/1967 estabeleceu as diretrizes e bases para a Cartografia Brasileira. O Decreto 89.817/1984 introduziu critérios para a classificação cartográfica em relação à exatidão e à distribuição de erros, utilizando indicadores estatísticos de qualidade posicional, chamados de Padrão de Exatidão Cartográfica (PEC) e Erro Padrão (EP). As tolerâncias referentes à exatidão são definidas com base na escala de avaliação dos dados espaciais e nas respectivas classes (A, B ou C).

Em 2010, a Diretoria do Serviço Geográfico do Exército Brasileiro (DSG) publicou as Especificações Técnicas de Aquisição de Dados Geoespaciais Vetoriais (ET-ADGV), vinculadas à Infraestrutura Nacional de Dados Espaciais (INDE), criada

em 2008 pelo Decreto-lei nº 6.666. A INDE tem como objetivo catalogar, integrar e harmonizar dados geoespaciais produzidos, mantidos e geridos por instituições públicas brasileiras. Em 2016, a ET-CQDG foi elaborada pelo DSG para fortalecer o que foi estabelecido pelo Decreto nº 6.666, de 27 de novembro de 2008.

A ET-ADGV detalha a aplicação do Decreto-lei nº 89.817 e introduz uma classe restritiva destinada a produtos cartográficos digitais (PEC-PCD). Para enquadrar um dado espacial dentro de uma determinada escala e classe, conforme o padrão de acurácia posicional do Decreto-lei 89.817/ET-ADGV, devem ser atendidas duas condições (Brasil, 1984; Santos *et al.*, 2016):

- a) Noventa por cento (90%) dos pontos coletados no dado espacial, quando as suas coordenadas forem comparadas com as levantadas em campo, por método de alta precisão, ou levantadas em outro dado espacial de maior acurácia, deverão apresentar os valores de discrepâncias posicionais iguais ou inferiores ao valor da tolerância “PEC” em relação à escala e classe testada;
- b) O RMS (*Root Mean Square*) da amostra de discrepâncias posicionais deve ser igual ou inferior à tolerância “EP” definido pela norma, para a escala e classe testada.

A Tabela 2 apresenta um resumo dos valores de PEC e EP definidos pelo padrão Decreto-lei 89.817/ET-ADGV (Santos *et al.*, 2016).

Tabela 2 – Padrões de exatidão PEC - EP

Classe (PEC)	Classe (PEC-PCD)	Planimetria		Altimetria	
		PEC	EP	PEC	EP
-	A	0,28 mm	0,17 mm	0,27 eq.	1/6 eq.
A	B	0,5 mm	0,3 mm	1/2 eq.	1/3 eq.
B	C	0,8 mm	0,5 mm	3/5 eq.	2/5 eq.
C	D	1,0 mm	0,6 mm	3/4 eq.	1/2 eq.

*Onde eq. Significa equidistância da curva de nível

Fonte: (Santos *et al.*, 2016)

A ET-CQDG de 2016, em conjunto com o Decreto 89.817, concretiza os preceitos do Decreto nº 6.666, de 27 de novembro de 2008. Esta especificação, que

atende à norma ISO 19157:2013 (ISO 2013), assegura que os procedimentos de avaliação sejam realizados conforme as diretrizes descritas pela ISO (Organização Internacional de Normalização), além de estabelecer métodos padronizados para relatar a qualidade dos produtos (Brasil, 2016).

Considera-se que um dado espacial possui acurácia posicional quando está classificado conforme o padrão do Decreto-lei 89.817/ET-ADGV para uma determinada escala e classe, além de não apresentar efeitos sistemáticos em suas coordenadas, ou seja, sem evidência de tendência (Santos *et al.*, 2016).

4 MATERIAL E MÉTODOS

4.1 ÁREA DE ESTUDO

A área de estudo é um trecho da faixa de domínio da Rodovia Federal BR 116, no município de Vacaria/RS, abrangendo o trecho que vai do km 00, localizado em latitude $28^{\circ}12'38.06''\text{S}$ e longitude $50^{\circ}45'35.29''\text{O}$, até o km 7,5, em latitude $28^{\circ}16'44.23''\text{S}$ e longitude $50^{\circ}47'57.41''\text{O}$ (coordenadas geodésicas referidas ao SIRGAS 2000). Este trecho, pertencente à Serra do Rio Pelotas, marca a divisa entre os estados do Rio Grande do Sul e Santa Catarina (Figura 22). A área de recobrimento aéreo abrange a largura da faixa de domínio e sua borda, com 60 metros para cada lado do eixo da rodovia, totalizando aproximadamente 90 hectares para o trecho selecionado.

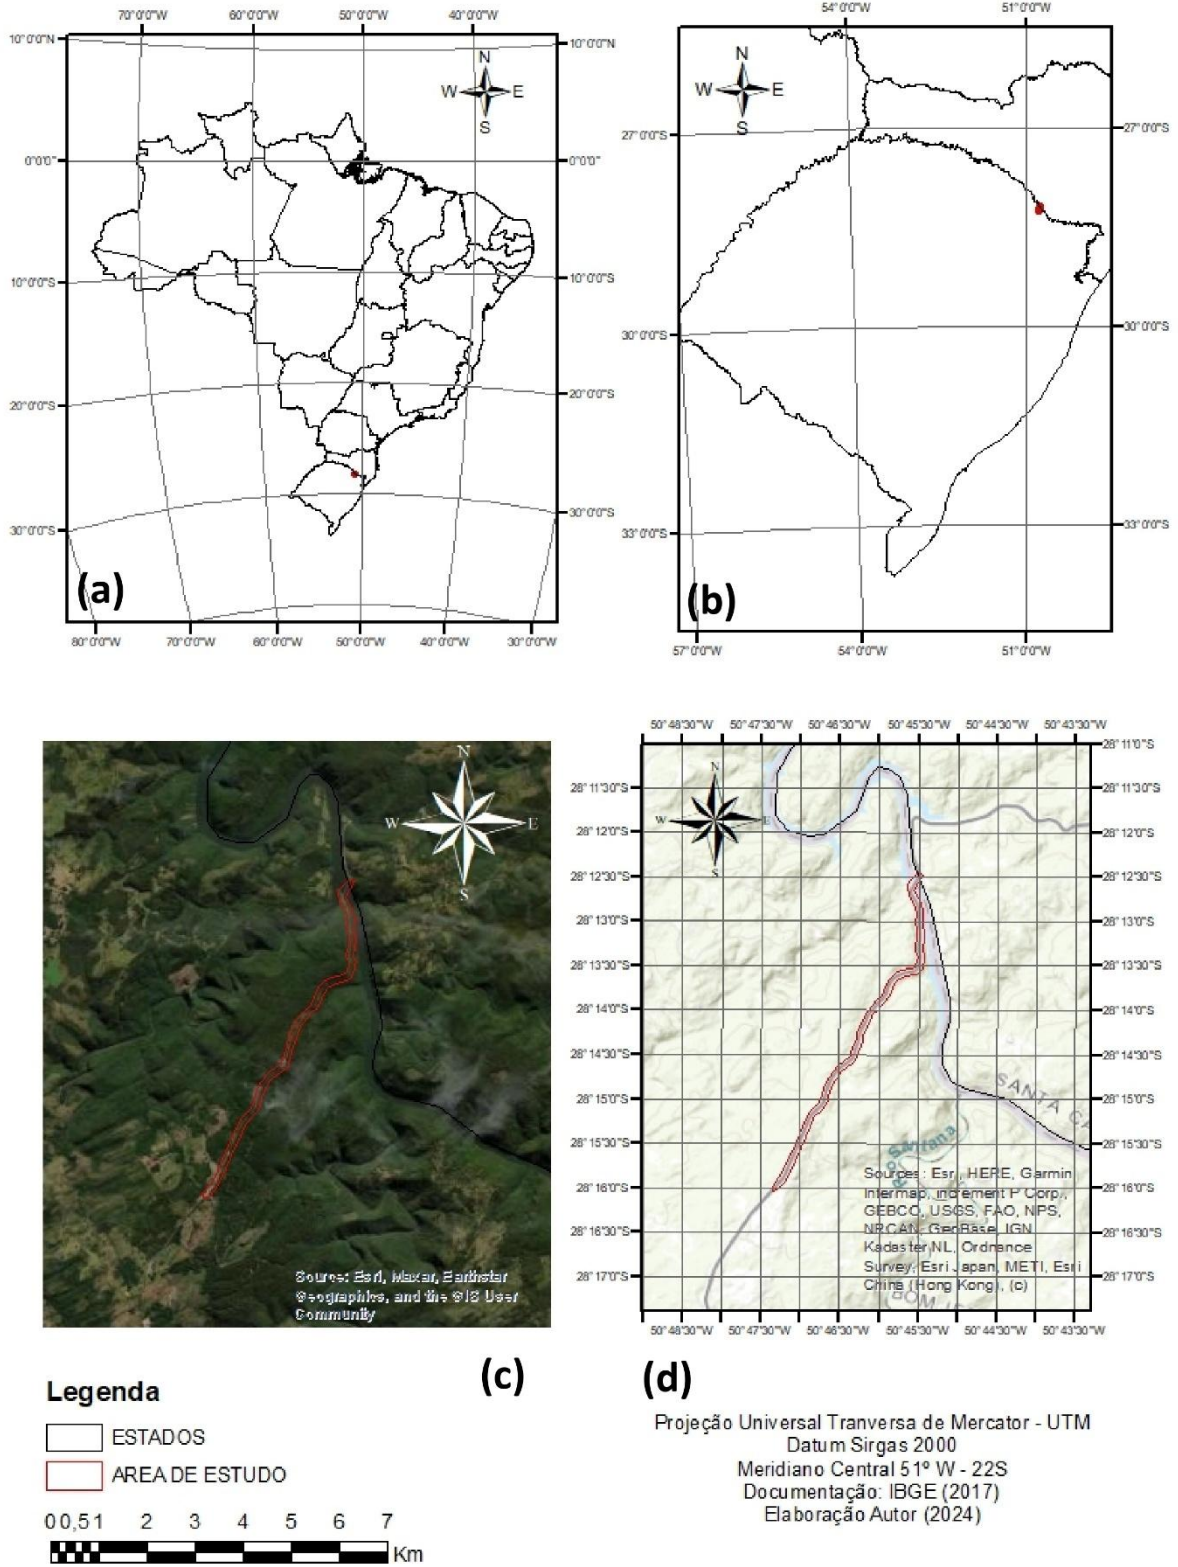
A área é caracterizada pela Floresta Ombrófila Mista e abriga diversos estágios de sucessão florestal, além de incluir áreas dedicadas à silvicultura. Este trecho compreende o leito da rodovia e, quando presente, uma parte da faixa de acostamento (Figura 21).

Figura 21 - Floresta Ombrófila Mista com presença de Silvicultura



Fonte: Elaborada pelo autor (2023)

Figura 22 – Área de estudo – (a) Brasil, (b) Estado do Rio Grande do Sul, (c) Recorte de Imagem de satélite da região de estudo (d) recorte de Carta topográfica da região de estudo



Fonte: Elaborada pelo autor (2025)

Neste trecho da Rodovia Federal BR-116, a faixa de domínio se estende por 35 metros a partir do eixo para ambos os lados, totalizando uma largura de 70 metros, conforme ilustrado na Figura 23. Ao final da faixa de domínio, deve ser mantida uma largura de 15 metros, destinada como faixa não edificante

Figura 23 – Largura da faixa de domínio no trecho da rodovia analisado



Fonte: Elaborada pelo autor (2025)

A largura da pista é de aproximadamente 11 metros, dos quais 7 metros são destinados à pista de rolagem, enquanto os acostamentos possuem 2 metros de largura em cada lado.

Figura 24 – Dimensão da pista de rolagem da rodovia



Fonte: Elaborada pelo autor (2025)

Para o desenvolvimento da pesquisa, foram utilizados os seguintes materiais: equipamentos topográficos, UAVs e notebooks; programas de computador; e materiais de apoio, como acessórios de topografia e trenas, conforme apresentado na Tabela 3.

Tabela 3 – Lista de materiais

<i>Hardware</i>
UAV multirrotor MATRICE 300 RTK
Sensor Zenmuse L1 – Solução com sistema RGB integrada com LIDAR
Base DJI D-RTK 2 GNSS Estação Móvel
Par de receptores GNSS Trimble RTK R4
Coletor de dados Trimble Juno T41
Par de receptores GNSS Topcon GR3
Coletor de dados Topcon FC-2500
Estação total Sanding Arc5pro
<i>Software</i>
Esri ArcMap 10.8
Sanding PC Tools
Google Eart Pro 7.3.4.8642 (64-bit)
Topcon Tools 8.2.3
Metrica Topo
Redtoolbox
DJI Terra
R Studio com a biblioteca LidR
Trimble busines center
<i>Acessórios</i>
Bastão de topografia GNSS e ET
Trena
Prancheta
Prisma para estação total
Piquetes de madeira
Tripés universal e bipés
Baterias externas para receptores GNSS
Rádio comunicador

Fonte: Elaborada pelo autor (2025)

A figura 25 apresenta o receptor GNSS Trimble RTK R4 ligado a uma bateria externa. Este receptor já vem por padrão habilitado para o rastreamento de sinais com GPS

L1, L2, L2C e QZSS. Além desse suporte GNSS padrão, o Trimble R4 oferece atualizações para GLONASS, Galileo e BeiDou (COMPASS).

Figura 25 - Receptor GNSS Trimble RTK R4



Fonte: Elaborada pelo autor (2025)

A figura 26 mostra o receptor GNSS Topcon GR3 e sua coletora FC-2500 instalado no marco base de todo levantamento e estudo.

Figura 26 - GNSS Topcon GR3



Fonte: Elaborada pelo autor (2025)

A figura 27 mostra a Estação total modelo Arc5pro da marca Sanding e o prisma instalado no bastão de topografia.

Figura 27 - Estação Total Sanding e prisma



Fonte: Elaborada pelo autor (2024)

A Figura 28 o instrumental e acessórios utilizados para o apoio terrestre com topografia convencional.

Figura 28 – Acessórios topográficos



Fonte: Elaborada pelo autor (2025)

O UAV multirotor MATRICE 300 RTK, equipado com o sensor Zenmuse L1 – Solução com sistema RGB integrada com LIDAR é apresentado na Figura 29.

Figura 29 - MATRICE 300 RTK



Fonte: Elaborada pelo autor (2025)

A Figura 30 mostra o receptor GNSS marca DJI modelo D-RTK 2 instalado sobre a base para a transmissão da correção RTK para o UAV.

Figura 30 - Base móvel DJI D-RTK 2

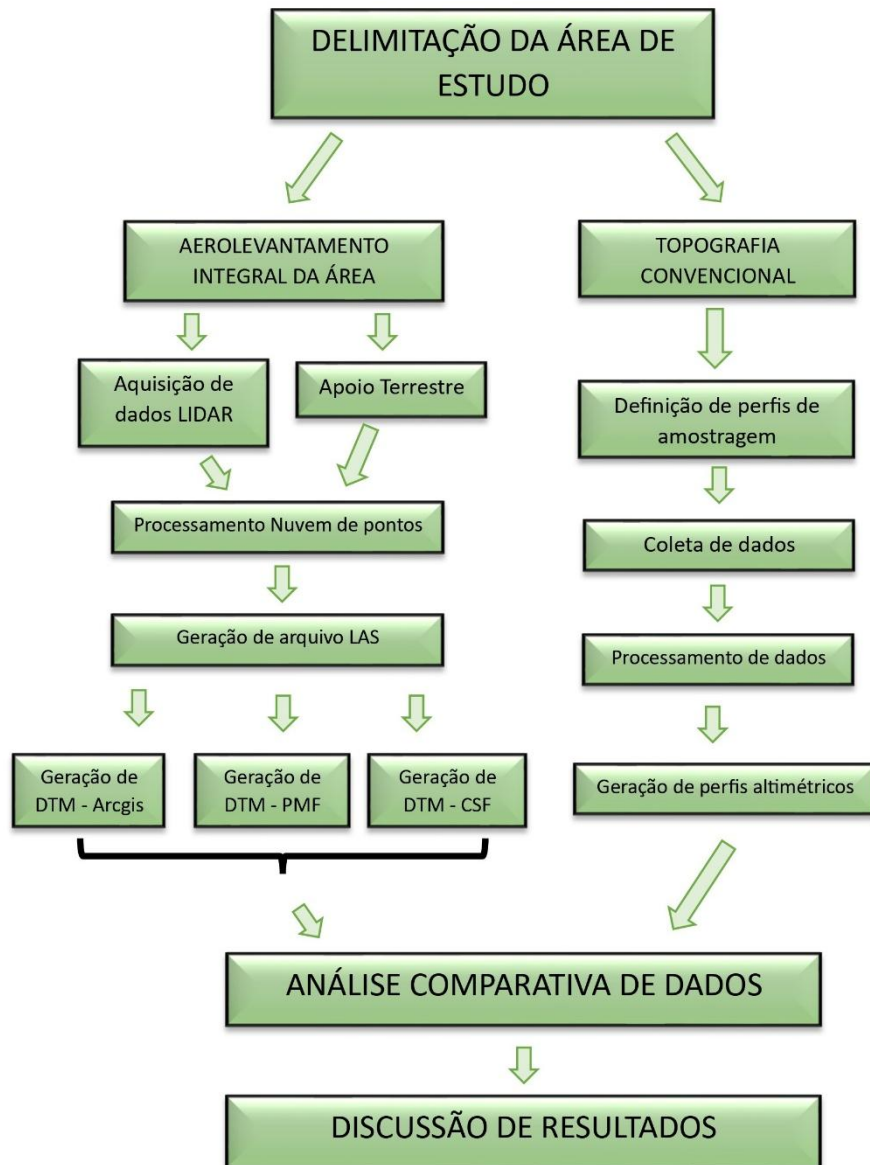


Fonte: Elaborada pelo autor (2025)

4.3 METODOLOGIA

A metodologia desta pesquisa é detalhada em um fluxograma que ilustra as etapas do processo, como mostrado na Figura 31. Essas etapas incluem desde o planejamento das atividades de campo e a coleta de dados até o processamento e a análise das informações obtidas.

Figura 31 – Fluxograma da pesquisa



Fonte: Elaborada pelo autor (2025)

4.3.1 Aquisição de dados LIDAR

A execução do recobrimento aéreo ocorreu no dia 11/09/2023, sob a responsabilidade do autor.

Figura 32 – Autor e UAV/LIDAR



Fonte: Elaborada pelo autor (2025)

Figura 33 - UAV LIDAR sendo preparado para o voo



Fonte: Elaborada pelo autor (2025)

4.3.1.1 Apoio Terrestre para Aerolevantamento LIDAR

O UAV/LIDAR é equipado com sistema GNSS RTK. O sistema RTK é composto por um receptor GNSS base que emite uma onda de rádio na frequência UHF que

permite a correção em tempo real do posicionamento (aquisição de coordenada precisa em determinado momento) do UAV/LIDAR.

O apoio terrestre para o aerolevante realizado em duas etapas simultâneas, sendo elas:

- a) Etapa 01 – Transporte de coordenadas: O transporte de coordenadas foi realizado com um rastreamento de base contínuo realizado durante toda operação de voo utilizando um receptor de sinais GNSS Trimble R4 estacionado junto do Posto Fiscal da Receita Estadual localizada as margens da BR 116 km 07 (Figura 25).
- b) Etapa 02 – Levantamentos de Pontos de Apoio: A partir desta base foram transportados os pontos de apoio e os pontos de verificação utilizando um receptor de sinais GNSS RTK Trimble R4. Ao longo do percurso foram instalados 05 pontos de apoio. Nesses pontos de apoio foi posicionada a base móvel DJI-D RTK 2.

4.3.1.2 Parâmetros de funcionamento de voo e Sensor LIDAR

A Tabela 4 apresenta os principais parâmetros de recobrimento aéreo.

Tabela 4 – Especificações de voo e funcionamento do sensor LiDAR Zenmuse L1

Especificações de voo (Matrice 300 e zenmuse L1)	
Altura de voo	80m
Velocidade de voo	1,5 m/s
Sobreposição lateral da faixa de voo	75%
Sobreposição frontal da faixa de voo	85%
PRF (<i>pulse frequency repetition</i>)	Max 360 KHZ
Nº de retornos pulso laser	2
Taxa de gravação RTK	1s
Ângulo de varredura	70 °
Densidade de pontos	219 pontos/m ²

Fonte: Elaborada pelo autor (2025)

4.3.2 Levantamento Topográfico Georreferenciado

Para a comparação e validação dos resultados obtidos com o LiDAR foi realizado um levantamento topográfico convencional e georreferenciado em sessões transversais (perfis) utilizando o receptor GNSS e a Estação Total.

4.3.2.1 Definição de perfil longitudinal de amostragem


O estudo selecionou 08 perfis transversais distribuídos ao longo da rodovia para analisar a variabilidade da cobertura vegetal. Perfis transversais são linhas imaginárias que permitem a coleta sistemática de dados em ambientes diversos, possibilitando amostragens de pontos de elevação do solo com diferentes tipos de cobertura vegetal.

Com a distribuição estratégica dos perfis, foi possível coletar pontos amostrais em ambientes como: asfalto, brita, grama de acostamento, campo nativo "envassourado", floresta secundária em estágio médio de regeneração, silvicultura de eucalipto, silvicultura de pinus e bosque de araucária.

Nestes 08 perfis, foi possível coletar ao todo 343 pontos. Para determinar a localização dos perfis, foi feito um estudo prévio *in loco*, procurando os locais que apresentassem a variabilidade de ambientes desejada e que permitissem o acesso da equipe de campo para a realização dos levantamentos com a estação total e equipamentos GNSS.

A Figura 34 mostra a ortofoto do recobrimento aéreo. Nota-se que os perfis se concentram no terço final do trecho de 7 km sobrevoado, pois neste local foi possível encontrar a variabilidade de ambientes e o fácil acesso para a equipe de campo. Diferente dos trechos mais próximos da serra do Rio Pelotas, onde a declividade traz, além de dificuldades, riscos de acidentes para a topografia.

Figura 34 - Croqui de localização dos perfis levantados.



Fonte: Elaborada pelo autor (2025)

4.3.2.1.1 Caracterização do Perfil 01

A área do perfil 01 é coberto por araucárias adultas, conforme apresentado na Figura 35.

Figura 35 – Perfil 01 – (a) Nuvem de Pontos, (b) Coleta de pontos com ET, (c) Vista geral do local e (d) Vista do dossel das araucárias



Fonte: Elaborada pelo autor (2025)

4.3.2.1.2 Caracterização do Perfil 02

Na área do perfil 02 foi possível coletar pontos em áreas cobertas por asfalto, grama, araucárias, pinus e floresta secundária em estágio médio de sucessão, conforme ilustrado na Figura 36.

Figura 36 - Perfil 02 – (a) Nuvem de Pontos, (b) Vista do dossel da floresta secundária, (c) Vista área com araucárias e (d) Vista geral da floresta secundária.



Fonte: Elaborada pelo autor (2025)

4.3.2.1.3 Caracterização do Perfil 03

Na região do Perfil 03 foram mensurados pontos em asfalto, floresta secundária e pinus, conforme apresentado na Figura 37.

Figura 37 - Perfil 03 – (a) Nuvem de pontos, (b) Vista do dossel da floresta secundária, (c) Vista do dossel de pinus e (d) Vista do interior da floresta secundária



Fonte: Elaborada pelo autor (2025)

4.3.2.1.4 Caracterização do Perfil 04

Para a região do Perfil 04 foram mensurados pontos em asfalto e em floresta secundária, conforme Figura 38.

Figura 38 - Perfil 04 – (a) Nuvem de Pontos, (b) Vista da floresta secundária, (c) Instrumental de mensuração e (d) Vista da rodovia



Fonte: Elaborada pelo autor (2025)

4.3.2.1.5 Caracterização do Perfil 05

Na região do Perfil 05 foram mensurados pontos em asfalto e em floresta secundária em estágio inicial de sucessão, conforme Figura 39.

Figura 39 – Perfil 05 – (a) Nuvem de pontos e (b) Vista da floresta secundaria inicial



Fonte: Elaborada pelo autor (2025)

4.3.2.1.6 Caracterização do Perfil 06

Para a região do Perfil 06 foram mensurados pontos em asfalto e floresta secundária, conforme apresentado na Figura 40.

Figura 40 - Perfil 06 – (a) Nuvem de Pontos, (b) Perspectiva da floresta secundária, (c) Estação Total e (d) Vista interior da floresta secundária



Fonte: Elaborada pelo autor (2025)

4.3.2.1.7 Caracterização do Perfil 07

Na região do Perfil 07 foram mensurados pontos em asfalto, floresta secundária, grama, campo, floresta secundária em estágio inicial de sucessão e eucalipto. A figura 41 ilustra essas classes de cobertura do solo.

Figura 41 - Perfil 07 – (a) Nuvem de Pontos, (b) Vista da floresta secundária, (c) Vista de área com campo e (d) Vista da área com eucalipto



Fonte: Elaborada pelo autor (2025)

4.3.2.1.8 Caracterização do Perfil 08

Para a região do Perfil 08 foram mensurados pontos em asfalto, grama, floresta secundária e também em povoamento com eucaliptos adultos. A Figura 42 ilustra essas classes.

Figura 42 - Perfil 08 – (a) Nuvem de pontos, (b) Área com campo, (c) Área com floresta, (d) Dossel da floresta secundária, (e) Área com eucaliptos adultos e (f) Interior da floresta secundária



Fonte: Elaborada pelo autor (2025)

4.3.2.2 Aquisição de dados

A aquisição de dados aconteceu em duas etapas distintas.

A primeira etapa foi realizada para materialização dos pontos de apoio georreferenciados, utilizando receptores GNSS RTK Topcon GR3. Um dos receptores estacionado sobre a base já implantada no posto fiscal (base do aerolevante) e o receptor móvel mensurando as locações e ocupações dos pontos de interesse para os perfis de estudo. Essa etapa foi implementada nos meses de julho até novembro de 2024.

A Figura 43 mostra o receptor móvel realizando a mensuração e a locação dos pontos de apoio que servirá de apoio geodésico para o levantamento topográfico com estação total.

Figura 43 – Demarcação de pontos de apoio



Fonte: Elaborada pelo autor (2025)

A segunda etapa consistiu em mensurar o levantamento topográfico do perfil com o uso da estação total, realizados nos meses de julho até novembro de 2024 (Figura 44).

Figura 44 – ET em levantamento de perfil



Fonte: Elaborada pelo autor (2025)

4.3.2.3 *Processamento de dados topográficos*

As observações do apoio georreferenciados foram processados no programa Topcon Tools para determinação das coordenadas dos pontos de apoio.

As mensurações obtidas com a estação total não requerem tratamento ou processamento adicionais. Para isso, utiliza-se apenas o software de importação de dados, o Sanding PC Tools, que permite transferir as informações diretamente da estação total para análise e uso posterior.

4.3.2.4 *Geração de perfis altimétricos*

Os perfis altimétricos foram elaborados a partir de pontos georreferenciados utilizando o software de desenho Metrica Topo, facilitando a geração de perfis altimétricos, que representam as variações de elevação ao longo de uma linha específica no terreno. Este programa tem a capacidade de importar os dados vindos de campo e exportar arquivos em formato vetorial.

4.3.3 Algoritmos empregados no Processamento de dados LiDAR

Três algoritmos diferentes de filtragem de solo foram selecionados para gerar DTM neste estudo são descritos a seguir:

4.3.3.1 *Progressive Triangulated Irregular Network (PTIN)*:

O algoritmo disponível na biblioteca para o processamento de nuvem de pontos LiDAR no ambiente do ArcMap 10.8 através da ferramenta *lassground*

O algoritmo PTIN segmenta os dados LiDAR em blocos menores. Inicialmente, ele identifica os pontos de menor altitude em cada bloco para dar início ao processo de filtragem. Subsequentemente, uma Rede Irregular Triangulada (TIN) é gerada a partir desses pontos escolhidos. Após essa etapa, um ponto virtual é incorporado à nuvem de pontos, promovendo uma densificação da TIN. Por fim, a TIN passa por uma densificação progressiva até que cada ponto seja categorizado como pertencente ao terreno ou como um objeto situado sobre ele (Axelsson, 2000).

4.3.3.2 *PMF (Progressive Morphological Filter) e CSF (Cloth simulation Filter)*

A execução destes dois algoritmos ocorre no ambiente R, utilizando o pacote *LiDR*. Este pacote é dedicado à manipulação e visualização de dados LiDAR com especial atenção às aplicações florestais.

4.3.3.2.1 PMF

Este filtro é uma implementação do método descrito em Zhang *et al.* (2003). A ideia principal do PMF é aplicar repetidamente uma operação de "abertura" morfológica (uma erosão seguida de uma dilatação) com janelas de tamanho progressivamente crescente comparando as diferenças de elevação das superfícies original e morfológicamente abertas com tamanhos de janela crescentes. A lógica por trás disso é que objetos não terrestres tendem a ser removidos com janelas maiores, enquanto o terreno, sendo mais contínuo, é preservado.

No estudo feito por Zhang *et al.* (2003), fica demonstrado que filtros morfológicos podem remover pontos sobre edifícios e árvores de dados LiDAR, mas

é difícil detectar todos os objetos não terrestres de vários tamanhos usando um tamanho de janela de filtragem fixo. Este problema pode ser resolvido aumentando gradualmente os tamanhos das janelas dos filtros morfológicos.

4.3.3.2.2 CSF

Este método é baseado na simulação de um processo físico simples. Imagine um pedaço de tecido colocado acima de um terreno, e então este tecido cai devido à gravidade. Assumindo que o tecido é macio o suficiente para aderir à superfície, a forma final do tecido é o DSM. No entanto, se o terreno for primeiramente invertido e o tecido for definido com rigidez, então a forma final do tecido é o DTM (Zhang *et al.*, 2016).

Em comparação com métodos tradicionais, o algoritmo CSF possui menos parâmetros, que são simples de ajustar e mantêm alta precisão em diversos testes, necessitando apenas de dois parâmetros definidos pelo usuário. Adicionalmente, em certos casos, a saída do CSF pode ser utilizada diretamente como DTM, dispensando interpolação e permitindo preencher lacunas nos dados (Zhang *et al.*, 2016).

4.4 DELINEAMENTO EXPERIMENTAL

O presente estudo foi estruturado em duas etapas principais para avaliar a acuidade de DTM. Inicialmente, realizou-se uma comparação direta entre dados de elevação coletados em campo e modelos interpolados a partir dados LiDAR. Para a interpolação espacial realizada no ArcMap, selecionou-se o método do IDW com uma potência de 2. Esta etapa envolveu a análise de 08 perfis topográficos, com a aplicação e comparação de três métodos distintos de filtragem de pontos LiDAR, visando identificar o método de filtragem que proporciona a representação mais fiel da superfície.

O método de interpolação IDW estima o valor de um ponto desconhecido utilizando os valores de pontos vizinhos conhecidos. A premissa fundamental é que pontos mais próximos ao local de estimativa têm uma influência maior (peso maior) do que pontos mais distantes. Em resumo, o IDW assume que os valores desconhecidos são mais semelhantes aos valores próximos do que aos valores

distantes, e essa semelhança diminui com a distância de acordo com a potência escolhida.

Na segunda etapa, a análise se concentrou na influência do tipo de cobertura e ocupação do solo na acuidade dos DTM comparando aos três métodos distintos de filtragem de pontos LiDAR. Para isso, os valores de elevação obtidos por ET foram agrupados de acordo com a cobertura e uso do solo, permitindo avaliar qual algoritmo apresenta o melhor desempenho em diferentes contextos de cobertura e uso do solo.

4.4.1 Avaliação da acurácia altimétrica

As avaliações da acurácia posicional fundamentam-se na comparação entre os dados obtidos por meio da tecnologia LiDAR e os valores coletados em campo. Neste estudo, os dados obtidos pela ET são considerados referências precisas, ou seja, valores para fins de validação.

Dessa forma, o cálculo das diferenças entre as coordenadas de cada ponto de perfil é realizado conforme a Equação 1. Esse procedimento envolve a comparação entre o posicionamento obtido pelo LiDAR, que está sendo avaliado, e o posicionamento referente à ET, considerado como referência ou verdade de campo

$$\delta p = \sqrt{(Z_T - Z_R)^2} \quad (1)$$

Sendo:

δp : Discrepância altimétrica;

Z_R : altimetria Real - ET;

Z_T : Coordenadas Teste - LiDAR.

Para avaliar a acurácia selecionou-se a métrica RMS (*Root Mean Square*) que refere-se as discrepâncias das coordenadas (Equação 2).

$$RMS\delta p = \sqrt{\frac{\sum_{j=1}^n (\delta p)^2}{n}} \quad (2)$$

Em que:

$RMS\delta p$: RMS da amostra de discrepâncias altimétricas;

n : número de pontos de checagem.

5 RESULTADOS

5.1 MODELO DSM 3D

A Figura 45 apresenta os recortes das nuvens de pontos utilizados para análise.

Figura 45 – Visualização 3D da nuvem de pontos



Fonte: Elaborada pelo autor (2025)

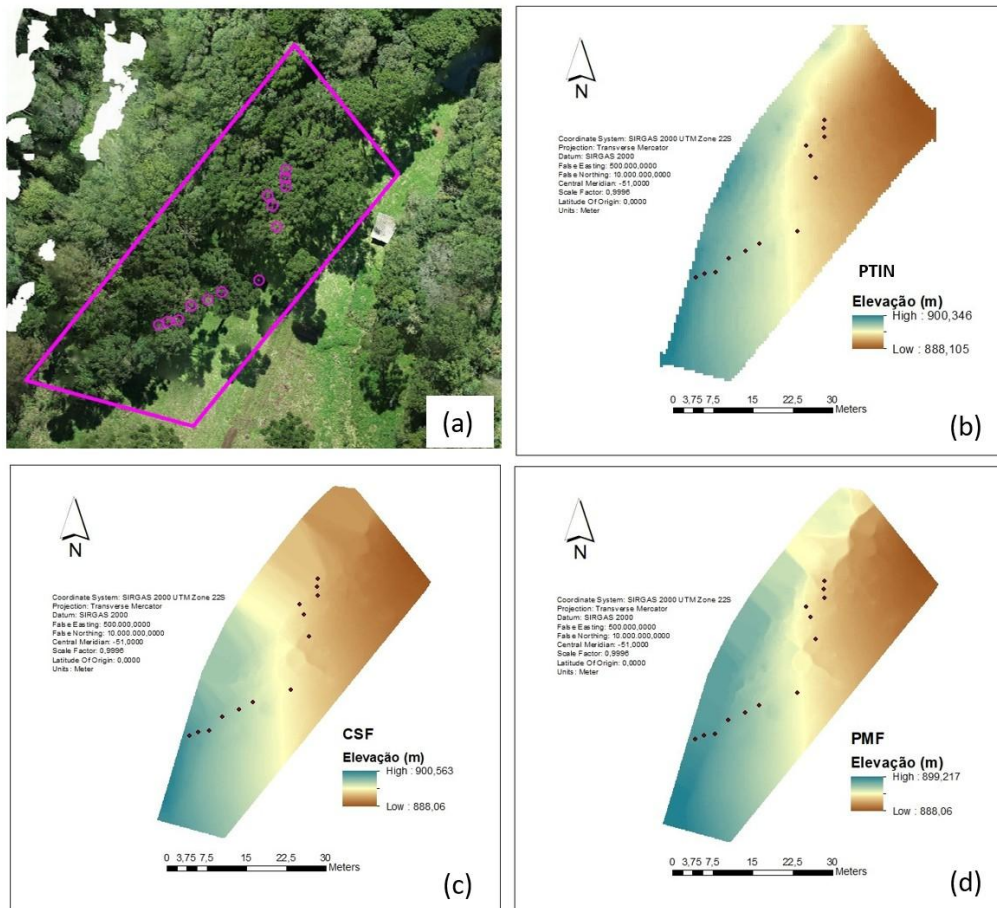
5.2 RESULTADOS POR PERFIL

A seguir são mostrados os produtos gráficos resultantes da aplicação dos três algoritmos utilizados na classificação de pontos do solo e na interpolação do DTM interpolado com os pontos amostrados para cada algoritmo, acompanhado por um recorte da ortoimagem que corresponde à área de cada DTM. Posteriormente, detalharemos as estatísticas associadas a cada perfil gerado.

5.2.1 Perfil 01

A figura 46 apresenta a ortoimagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 01.

Figura 46 – DTMs e Ortofoto referente ao Perfil 01 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF.



Fonte: Elaborada pelo autor (2025)

A Tabela 5 apresenta a estatística para as diferenças observadas para a comparação das observações de campo com o modelo interpolado PTIN, PMF e CSF para o local do Perfil 01.

Tabela 5 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 01

	Resultados com algoritmo PMF (m)	Resultados com algoritmo CSF (m)	Resultados com algoritmo PTIN (m)
Média	0,028	-0,109	0,017
Erro Padrão	0,102	0,030	0,038
Mediana	-0,032	-0,082	0,053
Desvio Padrão	0,368	0,108	0,137
Variância Amostral	0,136	0,012	0,019
Curtose	5,105	-0,379	-1,320
Assimetria	2,159	-0,995	-0,428
Amplitude	1,384	0,330	0,397
Maximo	1,059	0,005	0,194
Minimo	-0,325	-0,325	-0,203
Soma	0,369	-1,412	0,220
Contagem (n)	13	13	13
AAD	0,230	0,089	0,117
MAD	0,037	0,058	0,100
IQR	0,157	0,141	0,252
Teste Shapiro-Wilk			
W-estatística	0,721	0,847	0,913
p-valor	0,001	0,026	0,201
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	sim
Teste d'Agostino-Pearson			
DA-estatística	16,909	2,665	2,546
p-valor	0,000	0,264	0,280
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	sim	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	1,059	-0,325	-0,203
G	2,798	1,995	1,599
G-crit	2,331	2,331	2,331
sigificativo	sim	não	não
RMSE	0,355	0,151	0,133

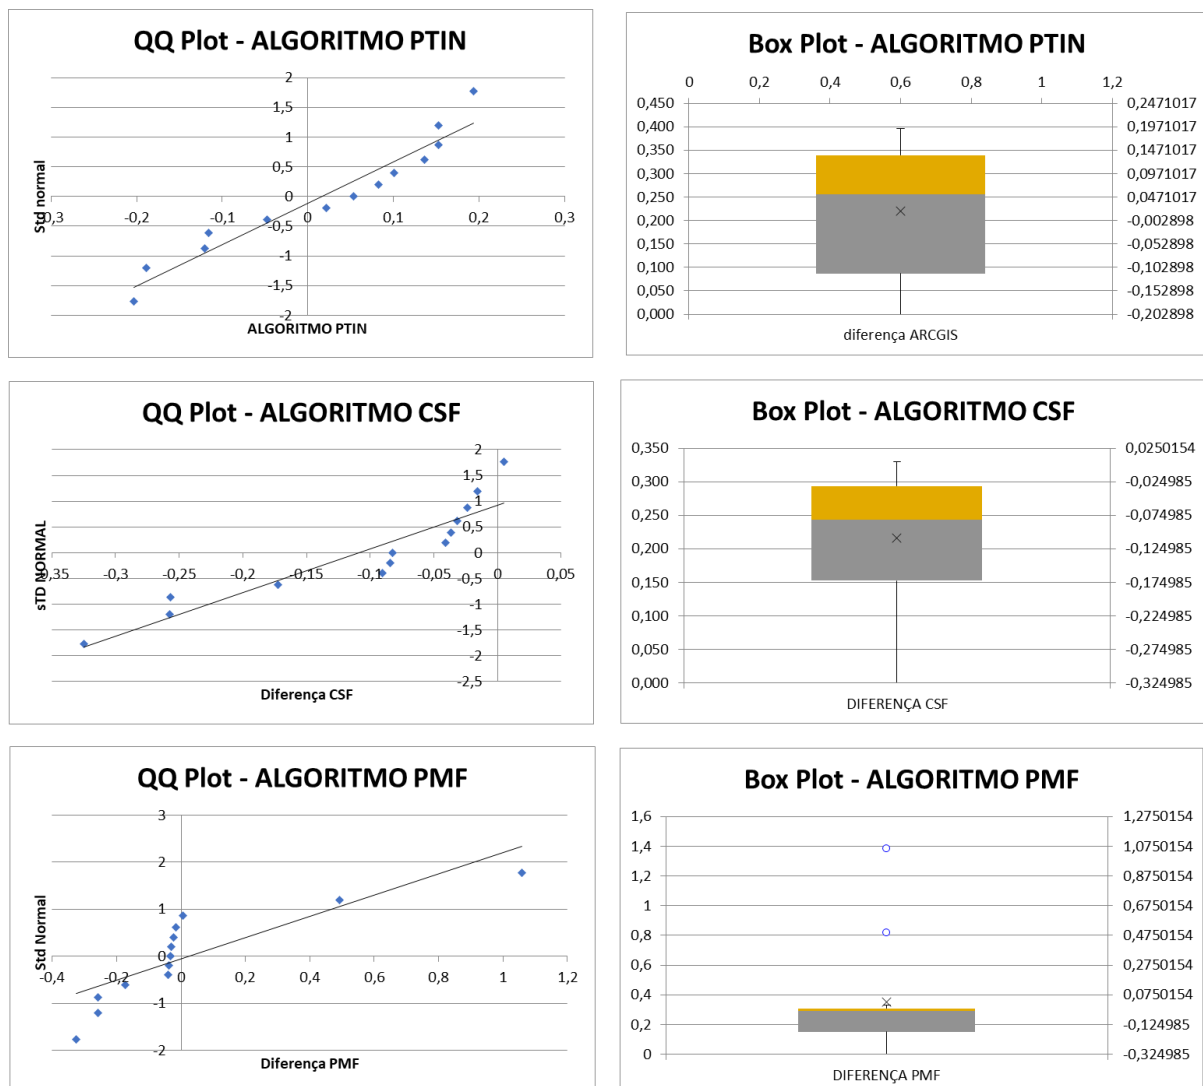
Fonte: Elaborada pelo autor (2025)

Observando as medidas de tendência central, a algoritmo PTIN se destaca por apresentar a menor média (0,017 m), indicando que as diferenças geradas essa técnica de filtragem são as menores em magnitude e as mais próximas de zero. A

algoritmo PMF apresenta uma média de 0,028 m, evidenciando uma subestimativa do DTM. O algoritmo PMF apresenta uma média negativa maior (-0,109 m), sugerindo superestimativa da superfície interpolada. A mediana segue uma tendência semelhante, com a algoritmo PTIN tendo o valor mais próximo de zero (0,053 m).

Foram criados os gráficos de Box-plot e QQ plot para as diferenças observadas com os três algoritmos, conforme Figura 47.

Figura 47 – Gráficos QQ Plot e Box Plot gerados para Perfil 01



Fonte: Elaborada pelo autor (2025)

Ao avaliarmos a dispersão dos resultados, notamos que o algoritmo PMF apresenta o menor desvio padrão (0,108 m), o que sugere menor variabilidade nos seus resultados em comparação com o algoritmo PTIN (0,137 m) e, especialmente, a

diferença observada com o emprego do algoritmo PMF (0,368 m), que apresenta uma maior dispersão.

A análise da distribuição dos dados por meio dos testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson revela algumas inconsistências entre os testes para diferença observada com o algoritmo CSF. O teste de Shapiro-Wilk indica que essas diferenças não seguem uma distribuição normal ($p\text{-valor} = 0,026 < \alpha = 0,05$), enquanto o teste de D'Agostino-Pearson sugere o contrário ($p\text{-valor} = 0,264 > \alpha = 0,05$). Já para a algoritmo PTIN, ambos os testes apontam para uma distribuição normal ($p\text{-valores} > \alpha = 0,05$), o que é uma propriedade desejável para muitas análises estatísticas. Por outro lado, as diferenças observadas com o algoritmo PMF não apresenta normalidade em nenhum dos testes.

Finalmente, a avaliação da presença de outliers através do teste de Grubbs indica um outlier significativo nos dados para o algoritmo PMF, enquanto as algoritmo CSF e PTIN não apresentaram outliers significativos de acordo com este teste.

Em resumo, a superfície interpolada com o algoritmo PTIN demonstra um bom desempenho em termos de tendência central (menor média), e seus erros parecem seguir uma distribuição normal. A superfície obtida com a interpolação dos pontos de solo obtidos com o algoritmo CSF apresenta a menor variabilidade, mas uma maior média e resultados conflitantes nos testes de normalidade. O algoritmo PMF mostra maior variabilidade, não tem distribuição normal dos erros e possui um outlier significativo.

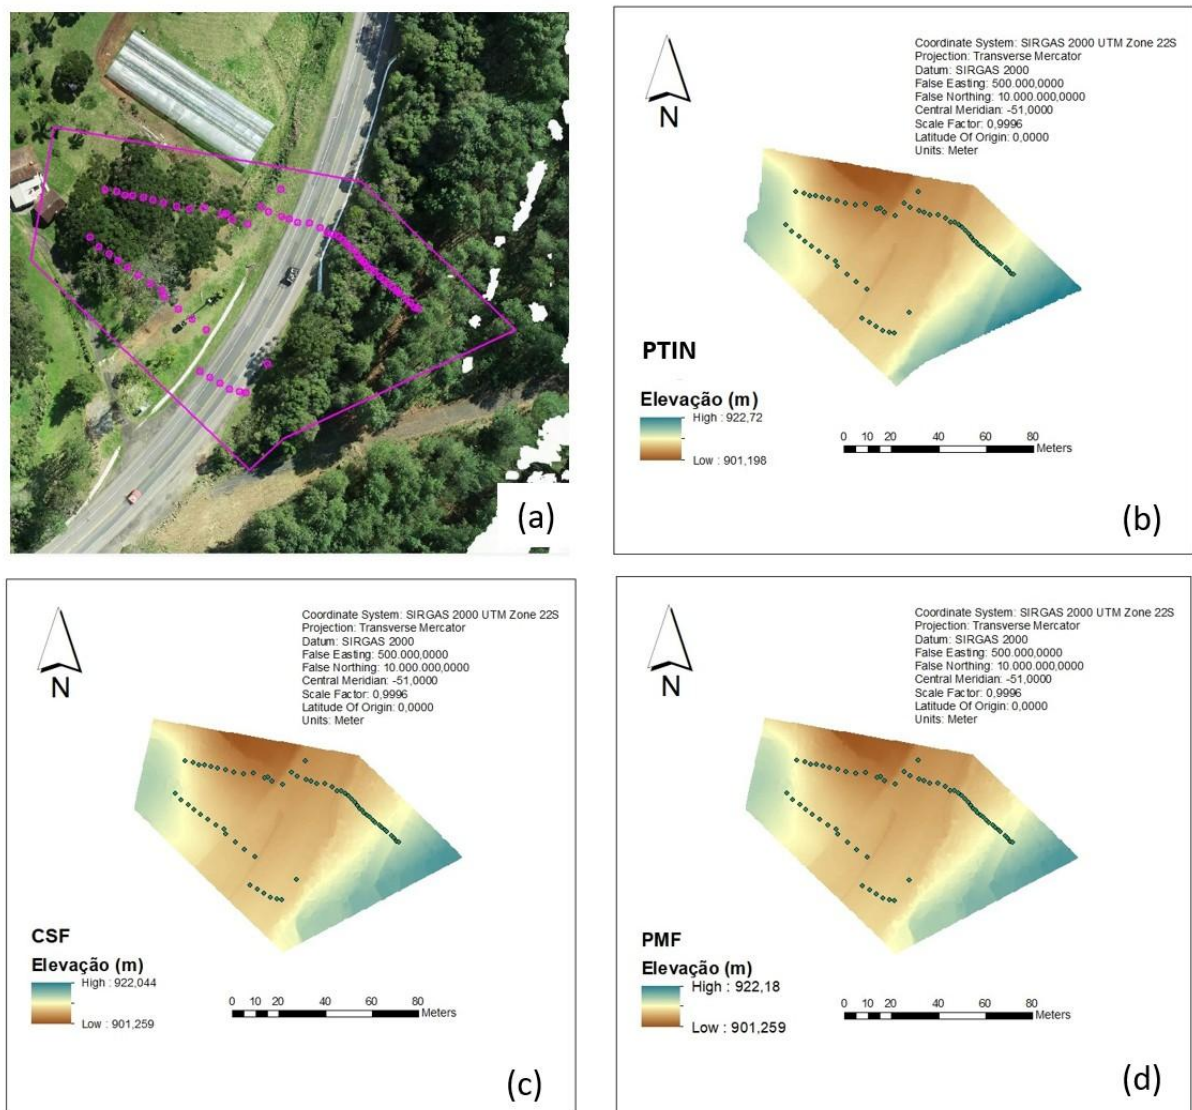
Neste perfil, o algoritmo PTIN demonstrou a maior acurácia, registrando o menor RMSE de 0,133 m. O algoritmo CSF apresentou um resultado muito próximo, com 0,151 m. Contudo, o algoritmo PMF exibiu um erro significativamente superior, atingindo 0,355 m.

Considerando esses resultados, e sem uma prioridade específica definida, a interpolação obtida com os pontos classificados pelo algoritmo PTIN parece oferecer um resultado mais equilibrado, combinando uma menor diferença sistemática com uma distribuição dos erros que se ajusta à normalidade.

5.2.2 Perfil 02

A Figura 48 apresenta a ortofotomagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 02.

Figura 48 - DTMs e Ortofoto referente ao Perfil 02 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF



Fonte: Elaborada pelo autor (2025)

A Tabela 6 apresenta a estatística para as diferenças observadas para a comparação das observações de campo com o modelo interpolado PTIN, PMF e CSF para o local do Perfil 02.

Tabela 6 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 02

	Resultados com o algoritmo PMF (m)	Resultados com o algoritmo CSF (m)	Resultados com o algoritmo PTIN (m)
Média	0,009	0,057	0,1427
Erro Padrão	0,016	0,025	0,0166
Mediana	0,045	0,051	0,1597
Desvio Padrão	0,131	0,197	0,1319
Variância Amostral	0,017	0,039	0,0174
Curtose	1,789	26,924	1,4058
Assimetria	-1,196	4,108	-0,9800
Amplitude	0,688	1,584	0,6734
Maximo	0,236	1,316	0,3374
Minimo	-0,453	-0,268	-0,3360
Soma	0,540	3,575	8,9909
Contagem (n)	63	63	63
AAD	0,100	0,103	0,105
MAD	0,068	0,061	0,096
IQR	0,139	0,140	0,188
Teste Shapiro-Wilk			
W-estatística	0,911	0,641	0,933
p-valor	0,000	0,000	0,002
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste d'Agostino-Pearson			
DA-estatística	17,079	89,64	12,605
p-valor	0,000	0,00	0,002
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-0,453	1,316	-0,336
G	3,531	6,387	3,629
G-crit	3,045	3,045	3,045
significativo	sim	sim	sim
RMSE	0,130	0,204	0,194

Fonte: Elaborada pelo autor (2025)

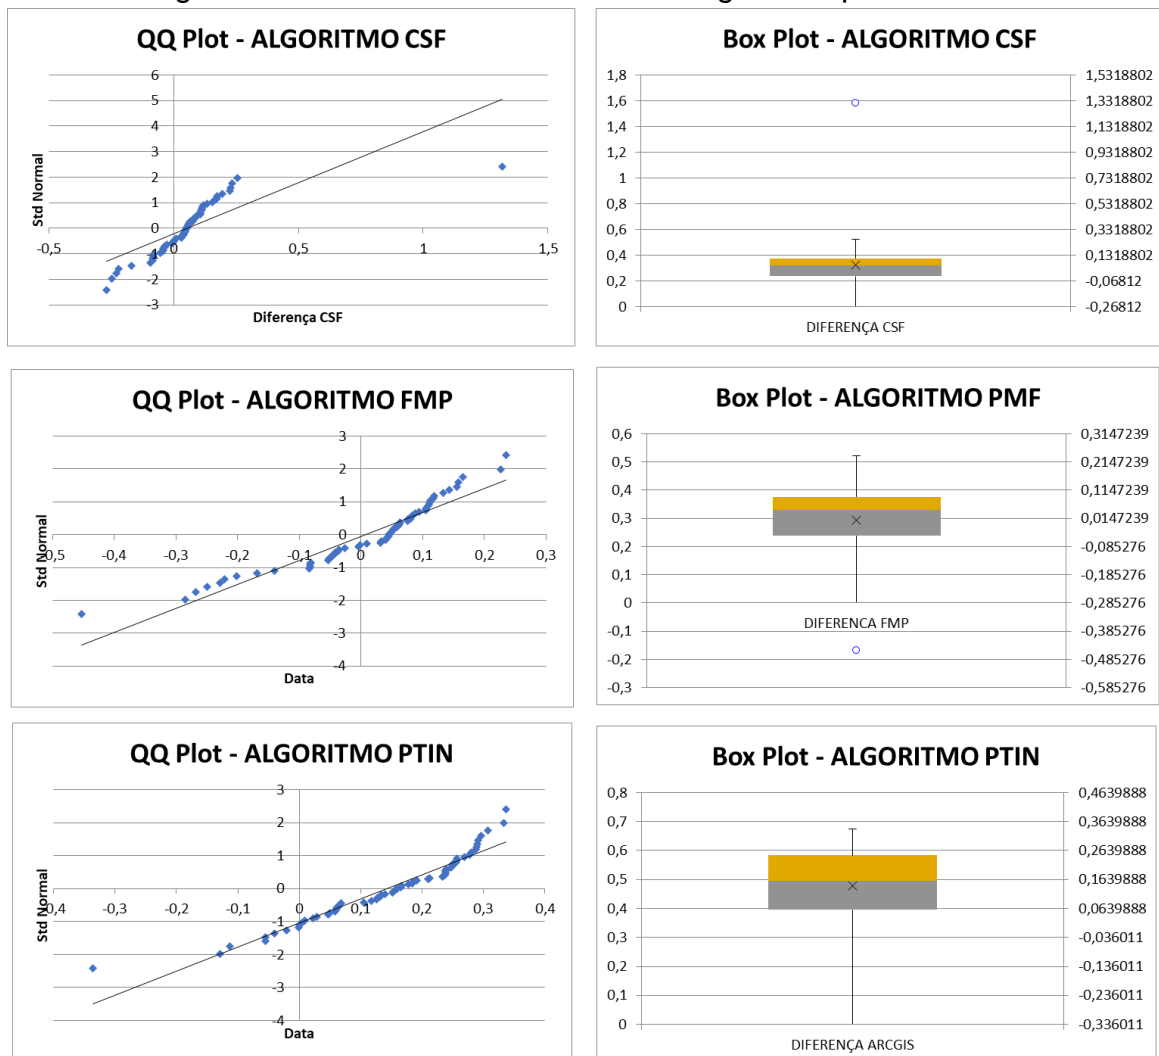
Ao observarmos as medidas de tendência central, o algoritmo PMF se destaca novamente por apresentar a média mais próxima de zero (0,009 m), o que sugere o menor erro sistemático entre os três métodos. O algoritmo PTIN mostrou uma média

de 0,14 m, enquanto a algoritmo CSF exibe uma média de 0,057 m. A mediana segue uma tendência semelhante, com o Algoritmo PMF tendo o valor mais próximo de zero (0,045 m).

No que diz respeito à dispersão dos resultados, avaliada pelo desvio padrão, o algoritmo PMF e e algoritmo PTIN apresentam valores bastante próximos (0,131 m e 0,1319 m, respectivamente), ambos menores do que a dispersão observada no algoritmo CSF (0,197 m). Isso indica que os erros gerados pelo algoritmo CSF tendem a ter uma maior variabilidade em comparação com os outros dois métodos.

Foram criados os gráficos de Box-plot e QQ plot para os 03 algoritmos, conforme Figura 49.

Figura 49 - Gráficos QQ Plot e Box Plot gerados para Perfil 02



Fonte: Elaborada pelo autor (2025)

A análise da distribuição dos erros através dos testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson revela que, de maneira geral, os erros não seguem uma distribuição normal para a maioria dos casos. O Teste de Shapiro-Wilk indica que nenhum dos conjuntos de diferenças é normalmente distribuído. O Teste de D'Agostino-Pearson sugere normalidade apenas para o algoritmo PTIN, o que entra em conflito com o resultado do Shapiro-Wilk para o mesmo conjunto de dados. Para o Algoritmo PMF e CSF, ambos os testes rejeitam a hipótese de normalidade.

A avaliação de outliers pelo Teste de Grubbs aponta para a presença de outliers significativos em todos os três conjuntos de diferenças.

Considerando a prioridade que demos anteriormente à menor média como indicativo de menor deslocamento sistemático, o algoritmo PMF volta a se apresentar como uma opção interessante devido à sua média muito próxima de zero. Embora todos os métodos apresentem problemas com a normalidade dos erros e a presença de outliers, a magnitude do erro sistemático (representada pela média) é um fator crucial em muitas aplicações.

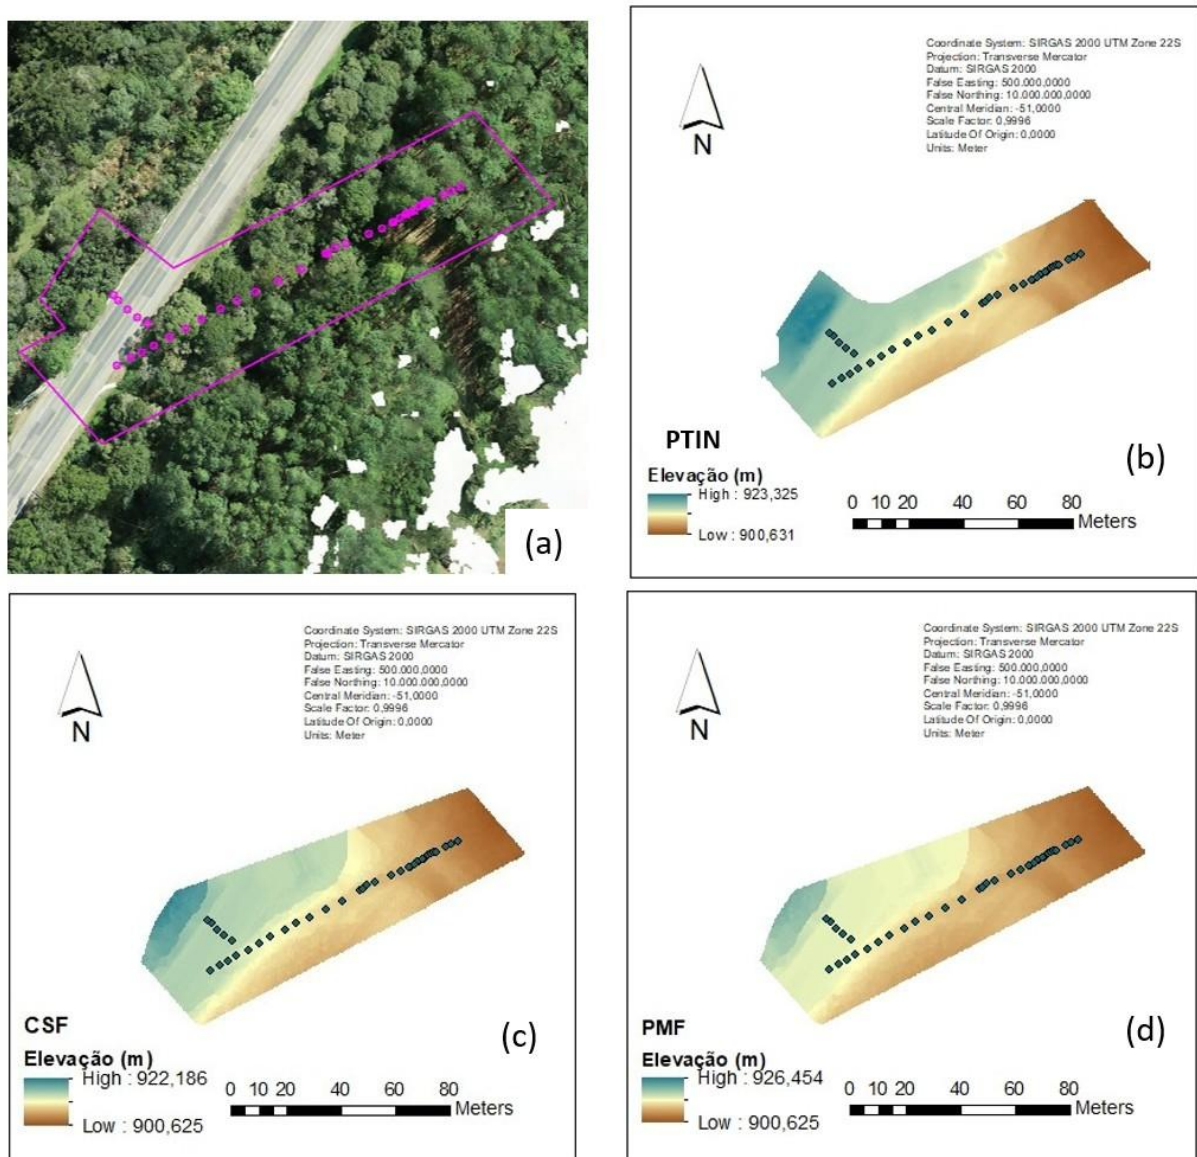
Para este perfil, o algoritmo PMF demonstrou a melhor acurácia, apresentando o menor RMSE de 0,130 m. Em contrapartida, tanto o PTIN (0,194 m) quanto o CSF (0,204 m) tiveram desempenhos menos precisos.

Portanto, levando em conta a análise prévia e focando na minimização do erro sistemático, a superfície interpolada com os pontos classificados com o algoritmo PMF parece ser o resultado mais promissor neste perfil.

5.2.3 Perfil 03

A Figura 50 apresenta a ortofotagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 03.

Figura 50 – DTMs e Ortofoto referente ao Perfil 03 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado



Fonte: Elaborada pelo autor (2025)

Tabela 7 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 03

	Resultados para o algoritmo PMF (m)	Resultados para o algoritmo CSF (m)	Resultados para o algoritmo PTIN (m)
Média	-0,090	-0,091	0,0448
Erro Padrão	0,021	0,020	0,0246
Mediana	-0,063	-0,068	0,0610
Desvio Padrão	0,129	0,124	0,1497
Variância Amostral	0,017	0,015	0,0224
Curtose	3,890	3,492	4,6865
Assimetria	-1,002	-1,485	-1,0924
Amplitude	0,760	0,629	0,9202
Maximo	0,256	0,125	0,4306
Minimo	-0,504	-0,504	-0,4897
Soma	-3,324	-3,363	1,6594
Contagem (n)	37	37	37
AAD	0,085	0,085	0,095
MAD	0,052	0,052	0,039
IQR	0,124	0,124	0,078
Teste Shapiro-Wilk			
W-estatística	0,864	0,873	0,881
p-valor	0,000	0,001	0,001
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste d'Agostino-Pearson			
DA-estatística	14,271	18,530	16,717
p-valor	0,001	0,000	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-0,504	-0,504	-0,490
G	3,208	3,324	3,570
G-crit	2,835	2,835	2,835
significativo	sim	sim	sim
RMSE	0,156	0,153	0,154

Fonte: Elaborada pelo autor (2025)

Os resultados estatísticos estão organizados na Tabela 7 trazendo os principais valores de comparação entre os três algoritmos.

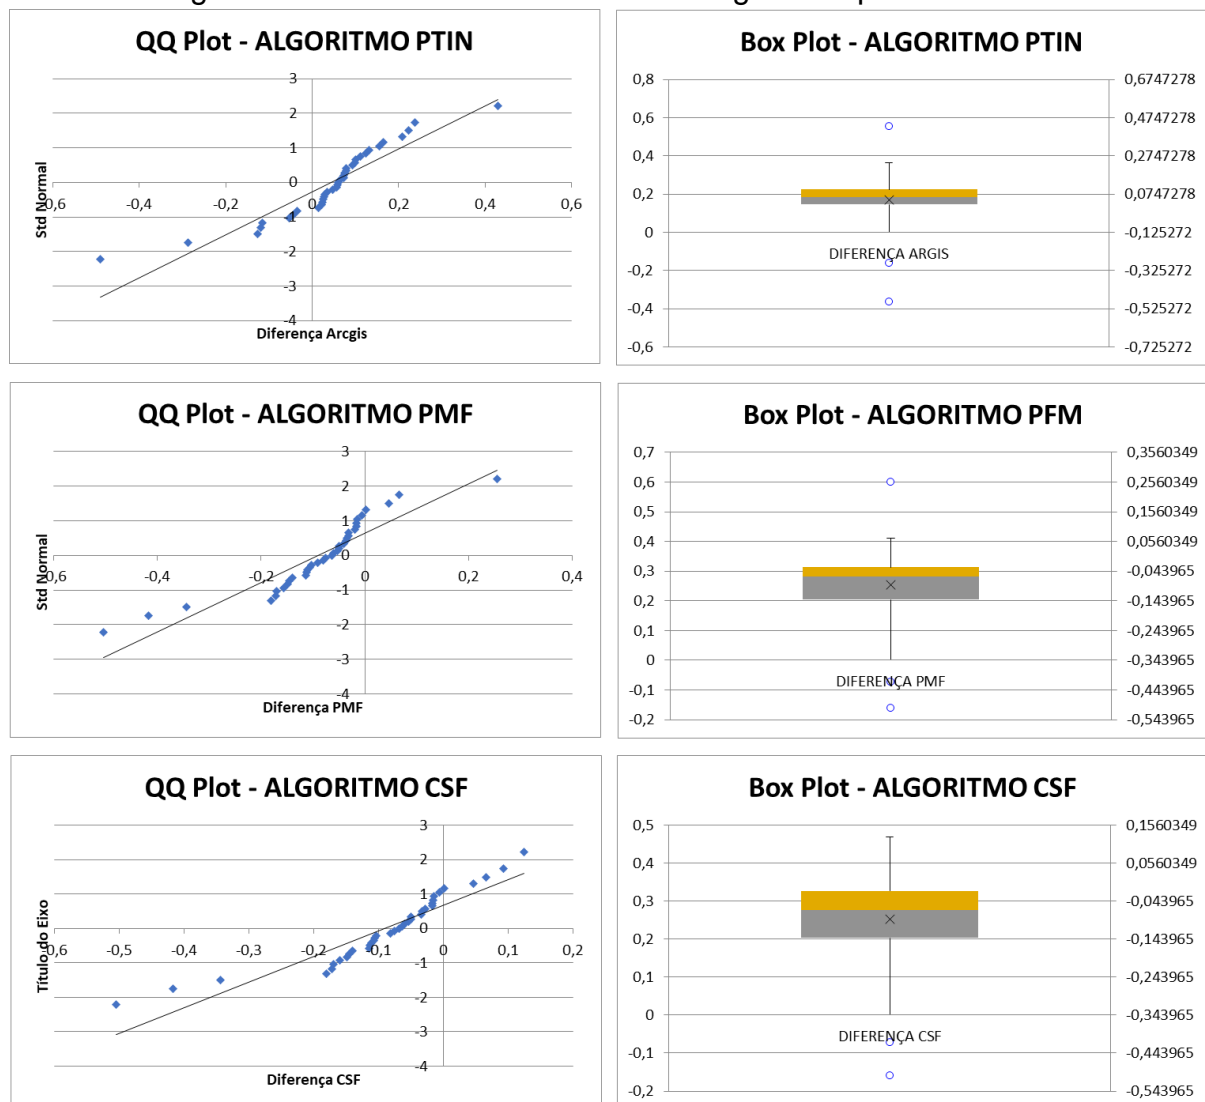
Na análise comparativa dos três conjuntos de diferenças (PMF, CSF e PTIN), observamos algumas características distintas em cada um. Ao examinarmos as médias, percebemos que a algoritmo PTIN apresenta o valor mais próximo de zero (0,0448 m), sugerindo um menor viés sistemático em comparação com o algoritmo PMF (-0,090 m) e o algoritmo CSF (-0,091 m), que indicam uma tendência de

subestimação. A mediana segue uma tendência semelhante, com o valor para algoritmo PTIN (0,0610 m) sendo o mais próximo de zero.

Ao avaliarmos a consistência ou variabilidade dos resultados através do desvio padrão, notamos que o algoritmo CSF demonstra a menor dispersão (0,124 m), seguido de perto pelo algoritmo PMF (0,129 m), enquanto o algoritmo PTIN exibe uma dispersão ligeiramente maior (0,1497 m). Isso sugere que o algoritmo CSF pode gerar erros mais agrupados em torno de sua média.

Foram criados os gráficos de Box-plot e QQ plot para os 03 algoritmos, conforme Figura 51.

Figura 51 - Gráficos QQ Plot e Box Plot gerados para Perfil 03



Fonte: Elaborada pelo autor (2025)

No que diz respeito à distribuição dos erros, os testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson indicam que nenhum dos três conjuntos de diferenças segue uma distribuição normal, com p-valores significativamente baixos em todos os casos. Além disso, o teste de Grubbs revela a presença de outliers significativos em todos os três conjuntos de dados, o que pode influenciar as estatísticas descritivas.

Considerando esses pontos, a escolha do "melhor" resultado depende da prioridade da análise. Se o foco principal for minimizar o deslocamento sistemático, o algoritmo PTIN se destaca por ter a média e a mediana mais próximas de zero. Por outro lado, se a consistência e a menor variabilidade dos erros forem mais importantes, o algoritmo CSF seria preferível devido ao seu menor desvio padrão.

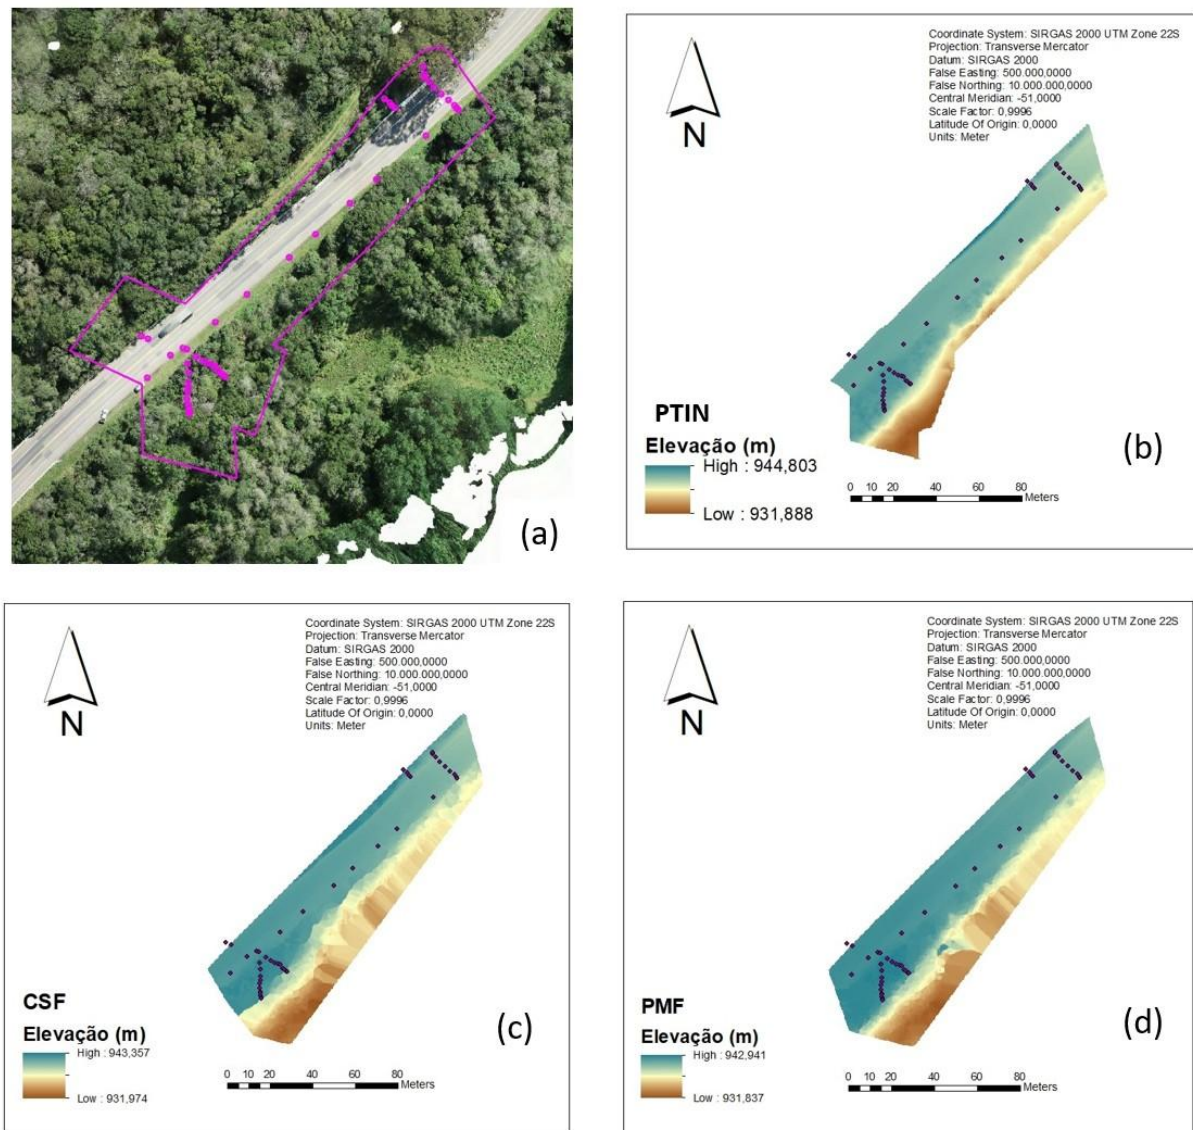
Os três algoritmos apresentaram resultados muito similares para RMSE, contudo, o algoritmo CSF demonstrou uma pequena vantagem com um RMSE de 0,153 m, seguido de perto pelo algoritmo PTIN (0,154 m) e PMF (0,156 m).

No entanto, ao ponderarmos ambos os aspectos, um menor deslocamento geralmente é mais desejável em muitas aplicações, pois indica que o modelo, em média, está mais alinhado com os valores de referência. Portanto, a superfície interpolada com os dados do algoritmo a Algoritmo PTIN pode ser considerado o resultado ligeiramente melhor ou mais equilibrado nesta comparação, apesar de ter uma dispersão um pouco maior.

5.2.4 Perfil 04

A Figura 52 apresenta a ortofotagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 04.

Figura 52 - DTMs e Ortofoto referente ao Perfil 04 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os



Fonte: Elaborada pelo autor (2025)

Os resultados estatísticos para o perfil 04 estão organizados na Tabela 8 trazendo os principais valores de comparação entre os três algoritmos.

Tabela 8 - Estatística descritiva comparativa entre os três algoritmos para o Perfil 04

	Resultados com o algoritmo PMF (m)	Resultados com o algoritmo CSF (m)	Resultados com o algoritmo PTIN (m)
Média	-0,112	0,0120	0,015
Erro Padrão	0,037	0,0869	0,029
Mediana	-0,057	-0,0243	0,030
Desvio Padrão	0,244	0,5768	0,193
Variância Amostral	0,059	0,3326	0,037
Curtose	1,657	14,6845	-1,010
Assimetria	-0,915	3,4934	-0,126
Amplitude	1,254	3,3882	0,719
Maximo	0,364	2,8668	0,342
Minimo	-0,891	-0,5214	-0,377
Soma	-4,929	0,5301	0,679
Contagem (n)	44	44	44
AAD	0,190	0,295	0,169
MAD	0,135	0,175	0,164
IQR	0,291	0,323	0,314
Teste Shapiro-Wilk			
W-estatística	0,941	0,601	0,956
p-valor	0,026	0,000	0,095
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	sim
Teste d'Agostino-Pearson			
DA-estatística	9,565	59,078	5,149
p-valor	0,008	0,000	0,076
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-0,891	2,867	-0,377
G	3,197	4,950	2,033
G-crit	2,906	2,906	2,906
sigificativo	sim	sim	não
RMSE	0,266	0,570	0,191

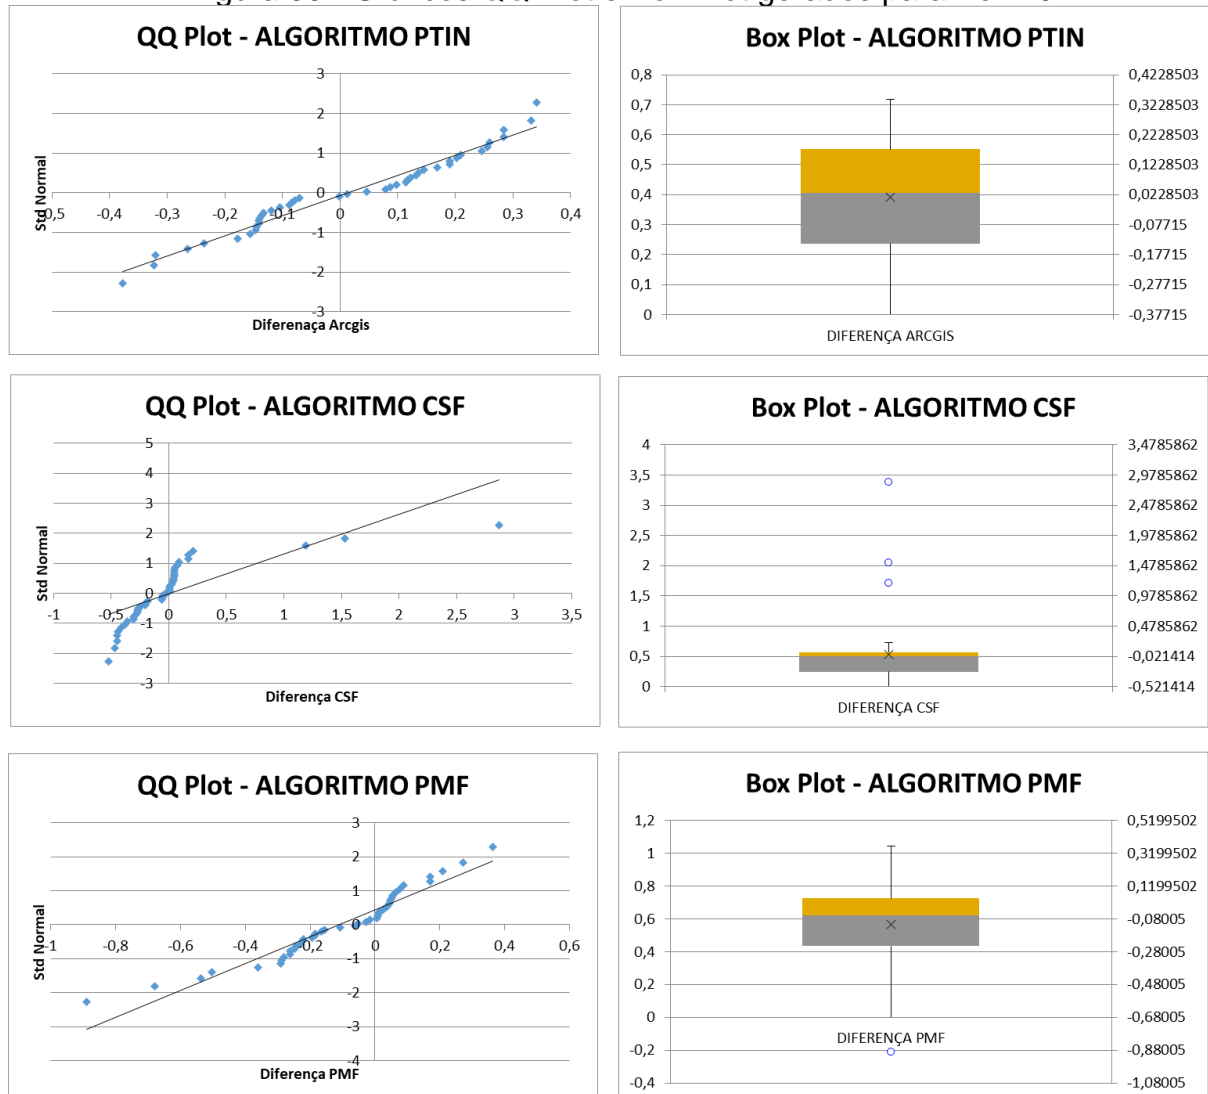
Fonte: Elaborada pelo autor (2025)

Observando as médias, o Algoritmo CSF apresenta o valor mais próximo de zero (0,0120 m), o que, como discutimos, sugere uma maior acurácia em termos de erro sistemático central. O algoritmo PTIN também tem uma média relativamente baixa (0,015 m), enquanto o algoritmo PMF mostra um maior deslocamento (-0,112 m).

No que diz respeito à precisão, avaliada pelo desvio padrão, o algoritmo PTIN demonstra a menor dispersão dos erros (0,193 m), indicando uma maior consistência em seus resultados em comparação com a algoritmo PMF (0,244 m) e, notavelmente, a algoritmo CSF (0,578 m), que exibe uma variabilidade muito maior.

Para o Perfil 04 foram criados os gráficos conforme Figura 53.

Figura 53 - Gráficos QQ Plot e Box Plot gerados para Perfil 04



Fonte: Elaborada pelo autor (2025)

A análise da distribuição dos erros através dos testes de normalidade revela que apenas o algoritmo PTIN sugere uma distribuição normal, de acordo com ambos os testes de Shapiro-Wilk ($p\text{-valor} = 0,095 > 0,05$) e D'Agostino-Pearson ($p\text{-valor} = 0,076 > 0,05$). Para o algoritmo PMF e CSF, os testes indicam que os erros não seguem uma distribuição normal. A normalidade é frequentemente desejável, pois muitas técnicas estatísticas assumem essa propriedade.

A avaliação de outliers pelo Teste de Grubbs aponta para a presença de outliers significativos nos resultados do algoritmo PMF e do algoritmo CSF, enquanto o algoritmo PTIN não apresenta outliers significativos de acordo com este teste. A ausência de outliers pode ser um indicativo de maior estabilidade do modelo.

Considerando todos esses aspectos, o algoritmo PTIN parece oferecer o resultado mais equilibrado de uma maneira geral para esta tabela. Embora sua média não seja a mais próxima de zero, ela demonstra a menor dispersão dos erros, sugere uma distribuição normal e não apresenta outliers significativos. Essa combinação de precisão, aderência a uma distribuição estatística comum e ausência de valores atípicos pode torná-la a opção mais robusta e confiável para muitas aplicações, mesmo que seu deslocamento médio seja ligeiramente maior que o do algoritmo CSF.

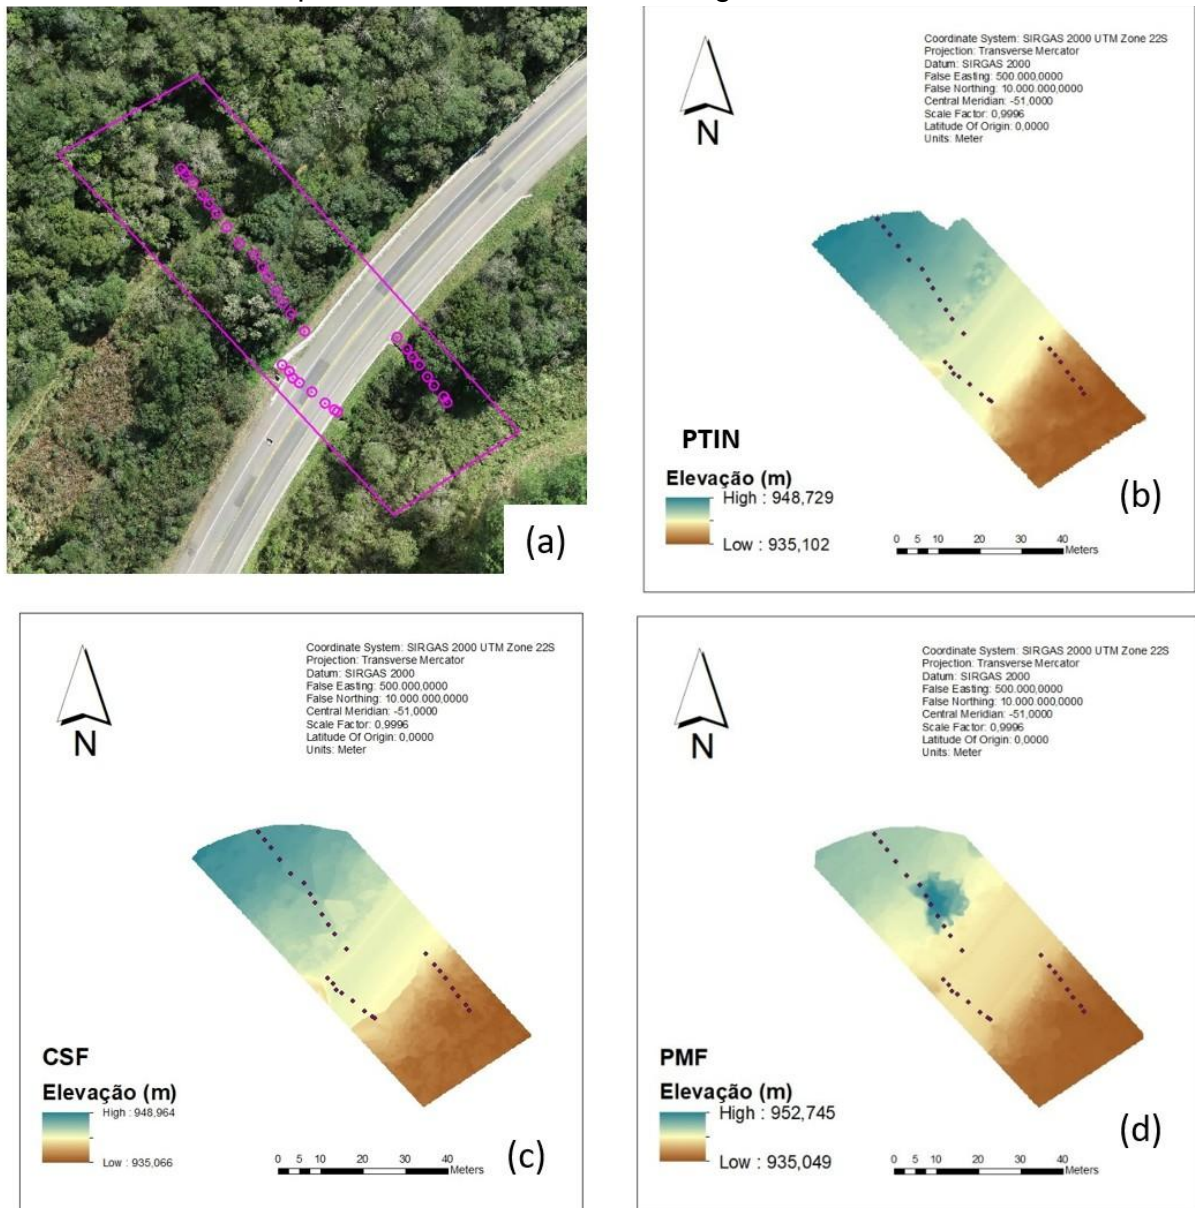
Neste perfil, o PTIN demonstrou a maior acurácia, com um RMSE de 0,191 m. Embora o PMF tenha apresentado um resultado razoável (0,266 m), o CSF exibiu um RMSE consideravelmente alto de 0,570 m.

Portanto, levando em conta a acurácia (proximidade ao valor verdadeiro), a precisão (variabilidade), a distribuição dos erros e a presença de outliers, a superfície interpolada com os dados do algoritmo PTIN se destaca como o melhor resultado de uma maneira geral nesta análise.

5.2.5 Perfil 05

A Figura 54 apresenta a ortofotomagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 05.

Figura 54 - DTMs e Ortofoto referente ao Perfil 05 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF



Fonte: Elaborada pelo autor (2025)

A Tabela 9 traz os resultados estatísticos para o perfil 05 comparando os três algoritmos.

Tabela 9 - Estatística descritiva comparativa entre os três algoritmos para o perfil 05

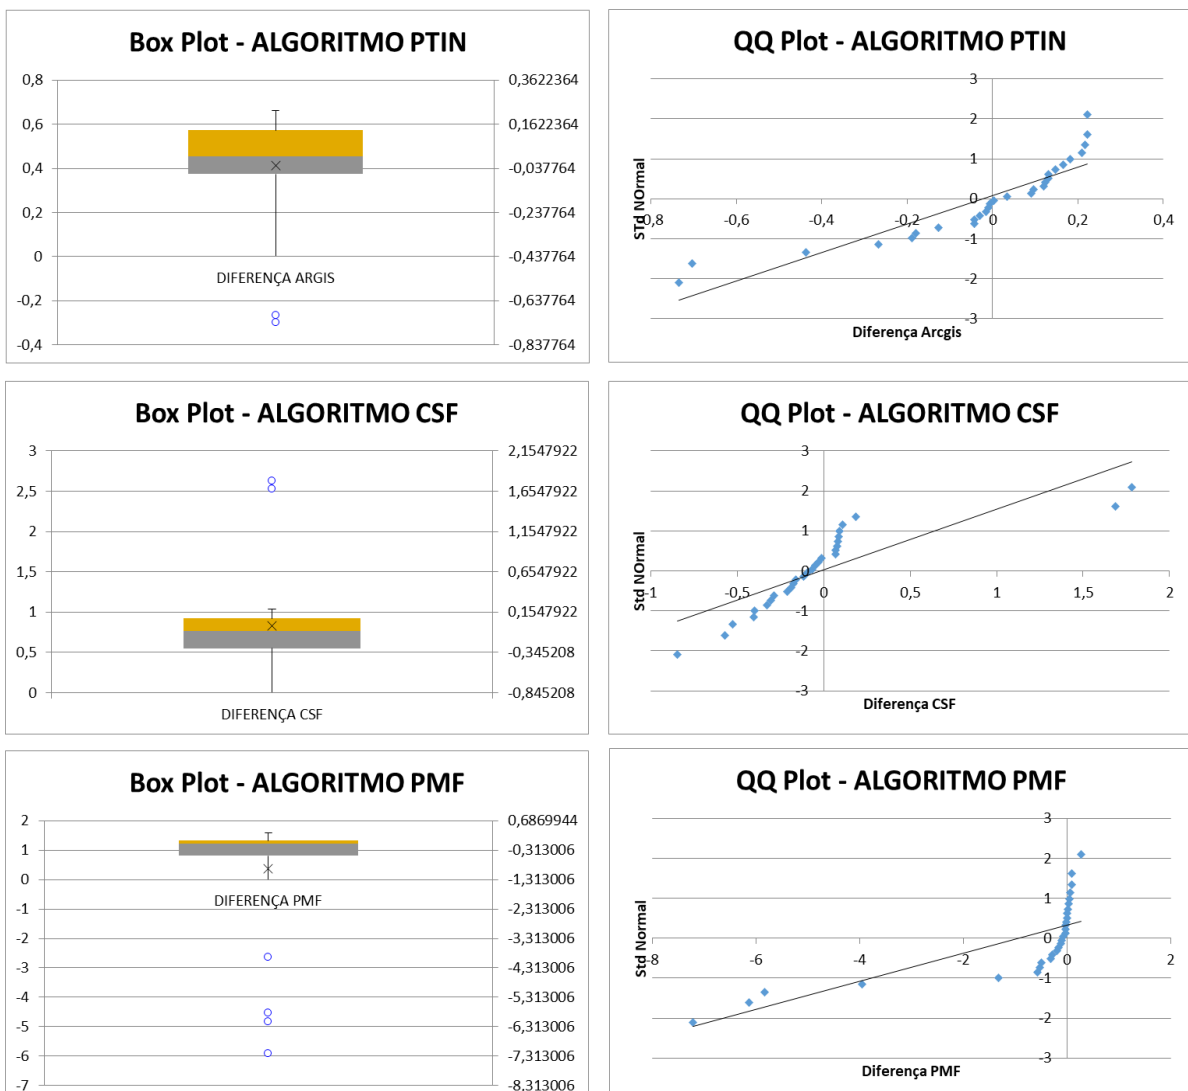
	Resultados com o algoritmo PMF (m)	Resultados com o algoritmo CSF (m)	Resultados com o algoritmo PTIN (m)
Média	-0,954	-0,020	-0,0245
Erro Padrão	0,393	0,104	0,0478
Mediana	-0,082	-0,082	0,0181
Desvio Padrão	2,079	0,551	0,2528
Variância Amostral	4,323	0,304	0,0639
Curtose	3,860	6,539	2,5580
Assimetria	-2,265	2,330	-1,6585
Amplitude	7,486	2,628	0,9581
Maximo	0,270	1,783	0,2230
Minimo	-7,216	-0,845	-0,7351
Soma	-26,707	-0,557	-0,6860
Contagem (n)	28	28	28
AAD	1,405	0,317	0,179
MAD	0,144	0,164	0,121
IQR	0,516	0,371	0,199
Teste Shapiro-Wilk			
W-estatística	0,549	0,714	0,814
p-valor	0,000	0,000	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste d'Agostino-Pearson			
DA-estatística	23,477	28,406	15,350
p-valor	0,000	0,000	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-7,216	1,783	-0,735
G	3,012	3,272	2,811
G-crit	2,714	2,714	2,714
sigificativo	sim	sim	sim
RMSE	2,254	0,542	0,249

Fonte: Elaborada pelo autor (2025)

Começando pelas medidas de tendência central, observamos as médias: o algoritmo PTIN apresenta a média mais próxima de zero (-0,0245 m), seguida pelo algoritmo CSF (-0,020 m) e, por fim, o algoritmo PMF (-0,954 m), que demonstra um erro sistemático consideravelmente maior. A mediana segue uma tendência semelhante, com a algoritmo PTIN (-0,0181 m) e a algoritmo CSF (-0,082 m) mais próximas de zero do que a algoritmo PMF (-0,082 m).

Ao avaliarmos a dispersão dos resultados através do desvio padrão, notamos que o algoritmo PTIN exibe o menor valor (0,2528 m), indicando uma menor variabilidade ou maior consistência dos erros. O algoritmo CSF apresenta um desvio padrão intermediário (0,551 m), enquanto o algoritmo PMF demonstra a maior dispersão (2,079 m). Para o Perfil 05 foram criados os gráficos conforme Figura 55.

Figura 55 - Gráficos QQ Plot e Box Plot gerados para Perfil 05



Fonte: Elaborada pelo autor (2025)

A análise da distribuição dos erros por meio dos testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson revela que nenhum dos três conjuntos de diferenças segue uma distribuição normal, pois os p-valores de ambos os testes são significativamente menores que o nível de significância α de 0,05 para todos os métodos.

A avaliação da presença de outliers utilizando o teste de Grubbs indica a detecção de outliers significativos em todos os três conjuntos de dados.

Considerando todos esses aspectos, a escolha do "melhor" resultado envolve um equilíbrio entre a proximidade da média a zero (indicando menor erro sistemático) e a precisão (menor dispersão). O algoritmo PMF, apesar de ter uma mediana relativamente próxima de zero, apresenta um erro sistemático médio muito grande e uma dispersão significativamente maior do que os outros dois métodos, além de não apresentar normalidade e ter um outlier.

Entre o algoritmo CSF e o algoritmo PTIN, ambas têm médias relativamente próximas de zero, embora o algoritmo PTIN seja ligeiramente melhor. No entanto, o algoritmo PTIN se destaca por ter um desvio padrão consideravelmente menor, indicando maior precisão. Embora nenhum dos dois apresente normalidade e ambos tenham outliers, a menor dispersão do algoritmo PTIN sugere uma maior confiabilidade e consistência dos resultados.

Portanto, ponderando a proximidade da média a zero (indicando menor erro sistemático) e a precisão (desvio padrão), e considerando que ambos os algoritmos CSF e PTIN falham nos testes de normalidade e apresentam outliers, o algoritmo PTIN parece ser o resultado mais promissor de uma maneira geral, devido ao seu menor erro sistemático médio e, principalmente, à sua significativamente menor dispersão dos erros. Essa menor variabilidade sugere que o algoritmo PTIN é mais consistente em suas estimativas.

Neste perfil, o PTIN obteve o menor RMSE (0,249 m), destacando-se positivamente. Em contraste, o CSF (0,542 m) e, notavelmente, o PMF (2,254 m) apresentaram erros altimétricos muito elevados, indicando um desempenho extremamente insatisfatório para o PMF neste cenário.

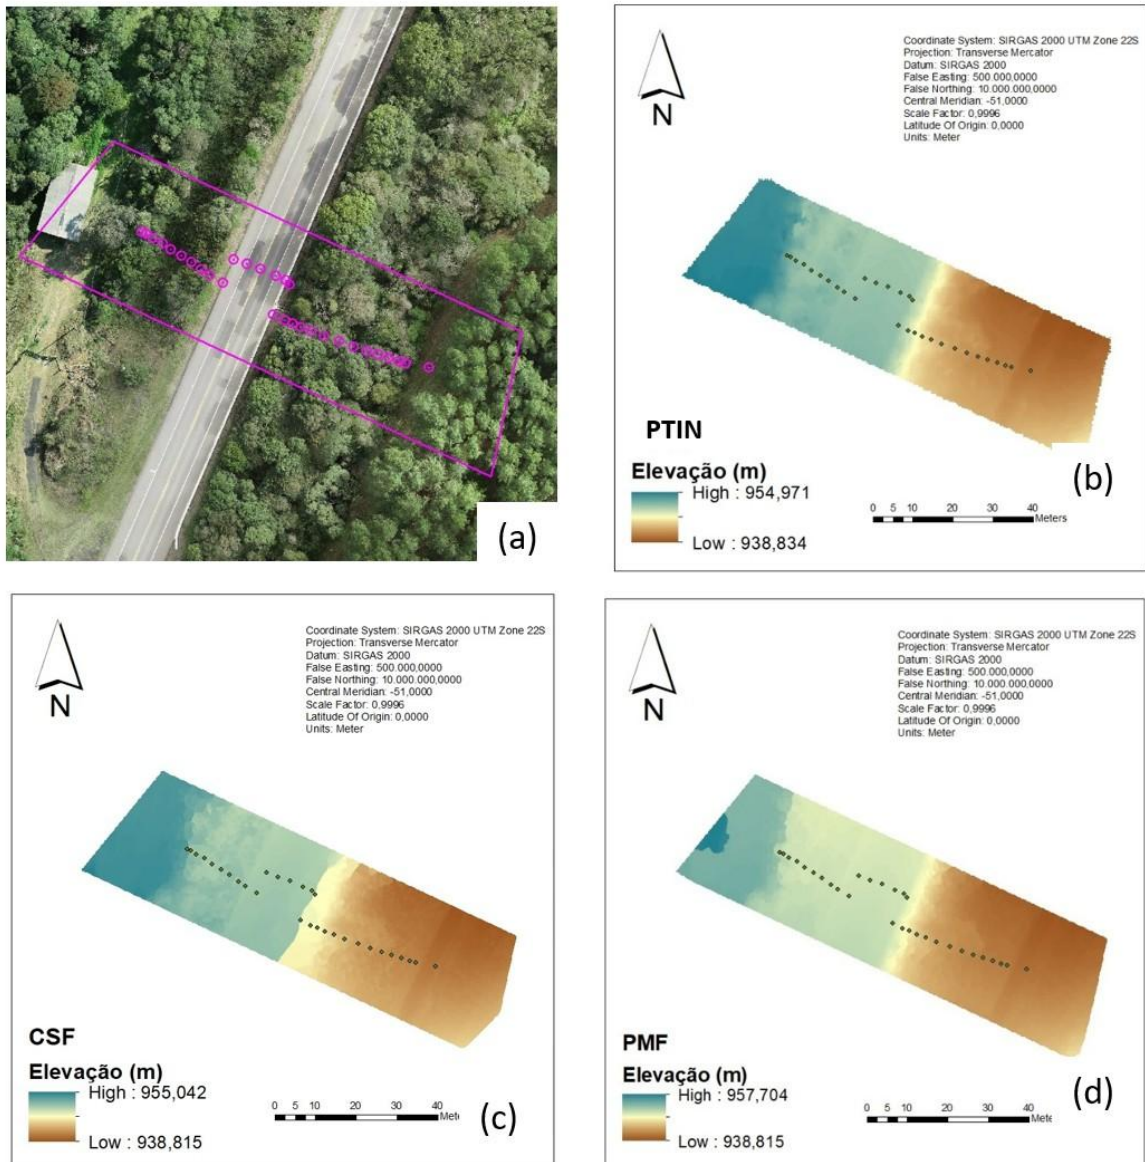
Em conclusão, levando em consideração a acurácia (através da média) e a precisão (através do desvio padrão), e apesar das limitações quanto à normalidade e presença de outliers em todos os casos, a superfície interpolada com os dados do

algoritmo PTIN se destaca como o mais equilibrado e, portanto, o melhor resultado geral nesta análise.

5.2.6 Perfil 06

A Figura 56 apresenta a ortofotagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 06.

Figura 56 - DTMs e Ortofoto referente ao Perfil 06 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF



Fonte: Elaborada pelo autor (2025)

Tabela 10 - Estatística descritiva comparativa entre os três algoritmos para o perfil 06

	Resultados para o algoritmo PMF (m)	Resultados para o algoritmo CSF (m)	Resultados para o algoritmo PTIN (m)
Média	-0,134	0,018	-0,043
Erro Padrão	0,034	0,172	0,047
Mediana	-0,119	-0,083	-0,036
Desvio Padrão	0,184	0,943	0,257
Variância Amostral	0,034	0,889	0,066
Curtose	-0,945	5,520	-0,857
Assimetria	-0,361	1,876	0,022
Amplitude	0,616	4,976	0,949
Maximo	0,111	3,026	0,514
Minimo	-0,505	-1,950	-0,435
Soma	-4,009	0,534	-1,282
Contagem (n)	30	30	30
AAD	0,156	0,536	0,218
MAD	0,149	0,221	0,191
IQR	0,291	0,412	0,368
Teste Shapiro-Wilk			
W-estatística	0,935	0,740	0,950
p-valor	0,069	0,000	0,173
alpha (α)	0,05	0,05	0,05
Distribuição normal	sim	não	sim
Teste d'Agostino-Pearson			
DA-estatística	3,117	23,578	1,693
p-valor	0,210	0,000	0,429
alpha (α)	0,05	0,05	0,05
Distribuição normal	sim	não	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-0,505	3,026	0,514
G	2,020	3,190	2,168
G-crit	2,745	2,745	2,745
sigificativo	não	sim	não
RMSE	0,225	0,927	0,256

Fonte: Elaborada pelo autor (2025)

Após os cálculos estatísticos foi criada a Tabela 10 comparando os três algoritmos para o perfil 06.

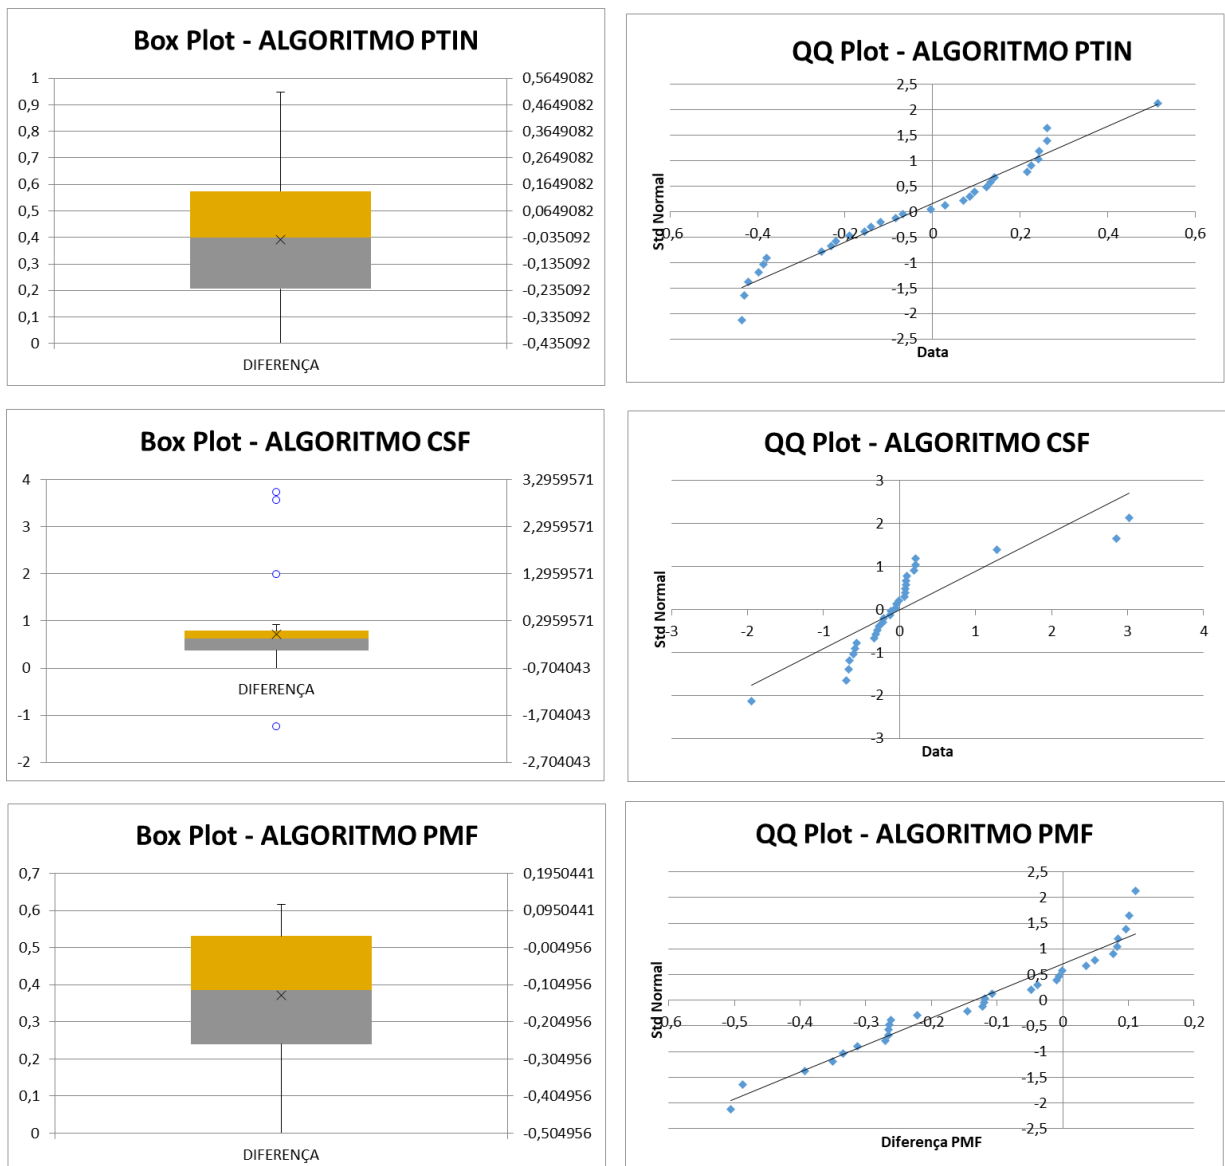
Começando pela tendência central, avaliada pela média, o algoritmo CSF apresenta o valor mais próximo de zero (0,0178 m), seguida pelo algoritmo PTIN (-0,043 m) e, por fim, pelo algoritmo PMF (-0,134 m), que demonstra o maior desvio

sistemático. A mediana segue uma tendência semelhante, com o algoritmo CSF (-0,0834 m) e o algoritmo PTIN (-0,036 m) mais próximas de zero do que o algoritmo PMF (-0,119 m).

Ao avaliarmos a dispersão através do desvio padrão, o algoritmo PMF exibe o menor valor (0,184 m), sugerindo a maior consistência ou menor variabilidade dos erros. O algoritmo PTIN apresenta um desvio padrão intermediário (0,257 m), enquanto o algoritmo CSF demonstra a maior dispersão (0,9431 m).

A Figura 57 mostra os gráficos gerados para o Perfil 06.

Figura 57 - Gráficos QQ Plot e Box Plot gerados para Perfil 06



Fonte: Elaborada pelo autor (2025)

A normalidade dos erros, avaliada pelos testes de Shapiro-Wilk e D'Agostino-Pearson, indica que o algoritmo PMF e a algoritmo PTIN sugerem distribuição normal em ambos os testes (p -valores $> 0,05$). Já o algoritmo CSF não apresenta indícios de distribuição normal em nenhum dos testes (p -valores $< 0,05$). A normalidade é uma propriedade desejável para muitas análises estatísticas.

A respeito de outliers, o teste de Grubbs não identificou um outlier significativo para a algoritmo PMF e para a algoritmo PTIN. No entanto, um outlier significativo foi detectado para a algoritmo CSF. A ausência de outliers sugere maior estabilidade dos resultados.

Considerando todos esses pontos, o resultado encontrado com o algoritmo PTIN parece apresentar o conjunto de características mais favorável de uma maneira geral. Ela demonstra um baixo desvio sistemático (média próxima de zero), uma dispersão razoável (menor que a do algoritmo CSF), sugere distribuição normal dos erros e não possui outliers significativos.

Embora os resultados do algoritmo CSF tenha a média mais próxima de zero, sua dispersão é muito alta e os erros não parecem seguir uma distribuição normal, além da presença de um outlier. O algoritmo PMF tem a menor dispersão e sugere normalidade, mas apresenta um maior desvio sistemático do que o algoritmo PTIN e CSF.

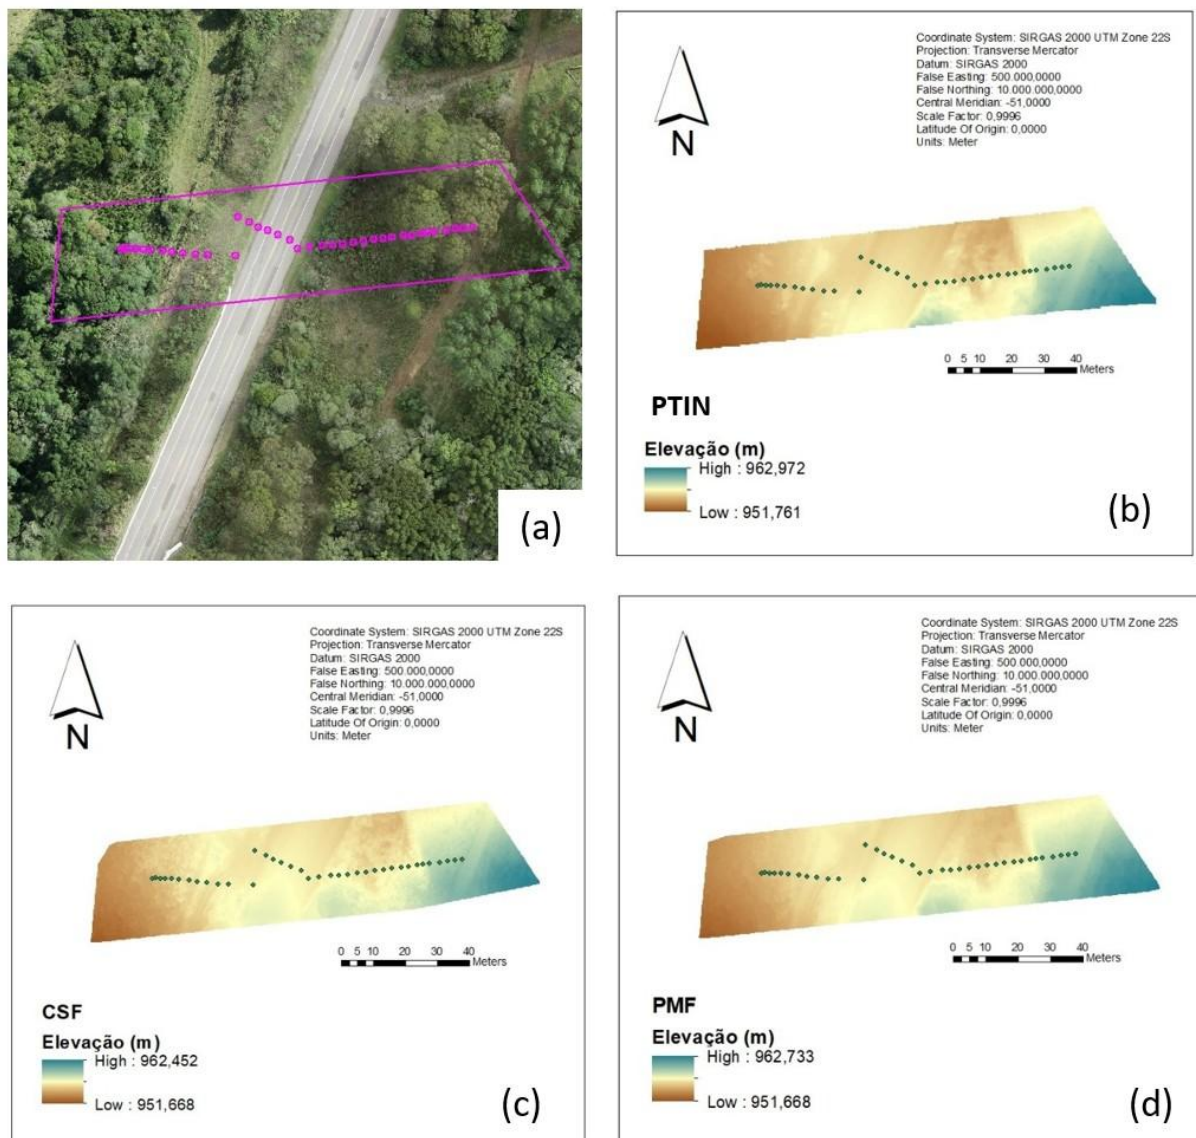
Para este perfil, o PMF demonstrou a maior acurácia, com um RMSE de 0,225 m, sendo seguido de perto pelo PTIN (0,256 m). O CSF, por sua vez, registrou um erro consideravelmente elevado de 0,9274 m.

Portanto, ponderando o desvio sistemático, a precisão, a normalidade e a presença de outliers, o melhor resultado de uma maneira geral para esta tabela seria a superfície interpolada com os dados do algoritmo PTIN.

5.2.7 Perfil 07

A Figura 58 apresenta a ortofoto e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 07.

Figura 58 - DTMs e Ortofoto referente ao Perfil 07 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado



Fonte: Elaborada pelo autor (2025)

Os resultados estatísticos para o perfil 07 estão organizados na tabela 15 trazendo os principais valores de comparação entre os três algoritmos.

Tabela 15 - Estatística descritiva comparativa entre os três algoritmos para o perfil 07

	Resultados para o algoritmo PMF (m)	Resultados para o algoritmo CSF (m)	Resultados para o algoritmo PTIN (m)
Média	-0,196	-0,270	-0,138
Erro Padrão	0,035	0,043	0,043
Mediana	-0,176	-0,273	-0,126
Desvio Padrão	0,212	0,262	0,264
Variância Amostral	0,045	0,069	0,070
Curtose	3,075	1,250	2,586
Assimetria	-1,140	-0,848	-1,167
Amplitude	1,119	1,241	1,272
Maximo	0,172	0,172	0,253
Minimo	-0,948	-1,069	-1,019
Soma	-7,260	-10,006	-5,109
Contagem (n)	37	37	37
AAD	0,154	0,199	0,188
MAD	0,123	0,158	0,139
IQR	0,205	0,278	0,258
Teste Shapiro-Wilk			
W-estatística	0,925	0,952	0,909
p-valor	0,015	0,110	0,005
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	sim	não
Teste d'Agostino-Pearson			
DA-estatística	13,963	6,863	13,154
p-valor	0,001	0,032	0,001
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-0,948	-1,069	-1,019
G	3,546	3,043	3,333
G-crit	2,835	2,835	2,835
significativo	sim	sim	sim
RMSE	0,287	0,374	0,294

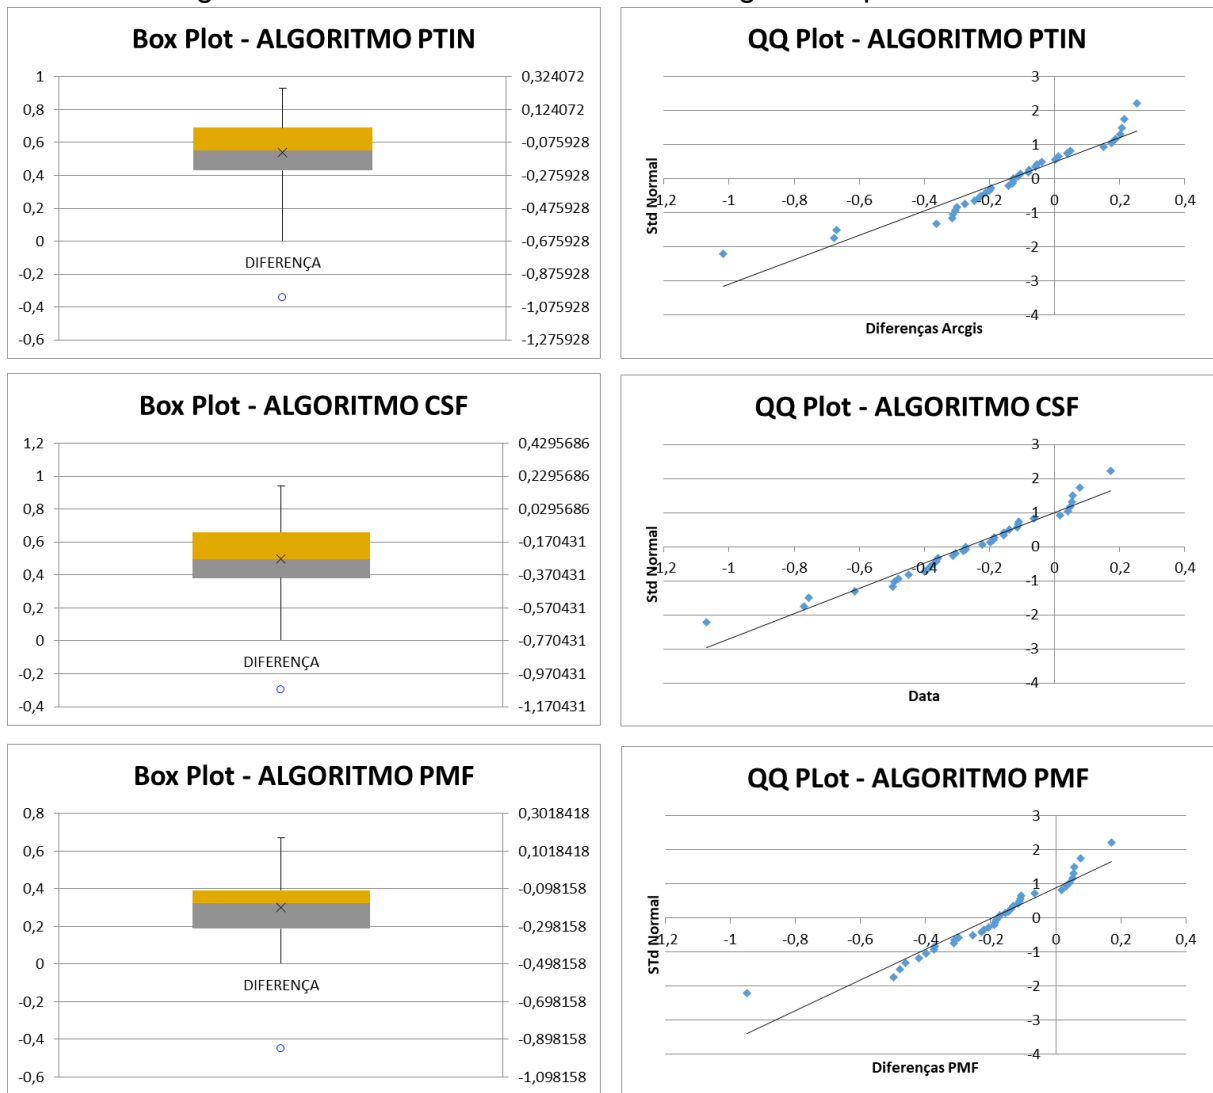
Fonte: Elaborada pelo autor (2025)

Começando pela média, que nos indica a tendência central dos erros, observamos que o algoritmo PTIN apresenta o valor mais próximo de zero (-0,138 m), sugerindo o menor deslocamento sistemático em relação ao valor de referência. O algoritmo PMF também mostra uma média relativamente baixa (-0,196 m), enquanto os resultados obtidos com o algoritmo CSF exibe uma média mais distante de zero (-

0,270 m). A mediana, outro indicador de tendência central, segue uma ordem semelhante, com o algoritmo PTIN (-0,126 m) mais próxima de zero, seguida pelo algoritmo PMF (-0,176 m) e, por fim, a algoritmo CSF (-0,273 m).

Para o Perfil 07 foram criados os gráficos conforme Figura 59.

Figura 59 - Gráficos QQ Plot e Box Plot gerados para Perfil 07



Fonte: Elaborada pelo autor (2025)

Ao avaliarmos a dispersão dos resultados através do desvio padrão, notamos que o algoritmo PMF demonstra a menor variabilidade (0,212 m), indicando uma maior consistência dos erros gerados por este método. O algoritmo PTIN apresenta um desvio padrão ligeiramente maior (0,264 m), enquanto o algoritmo CSF exibe a maior dispersão (0,262 m).

A análise da normalidade da distribuição dos erros, utilizando os testes de Shapiro-Wilk e D'Agostino-Pearson, revela que nenhum dos três conjuntos de diferenças segue uma distribuição normal, pois os p-valores obtidos em ambos os testes são geralmente menores que o nível de significância de 0,05. Apenas o teste de Shapiro-Wilk para a algoritmo CSF sugere uma distribuição normal (p-valor = 0,110 > 0,05), mas o teste de D'Agostino-Pearson para o mesmo conjunto de dados rejeita essa hipótese (p-valor = 0,032 < 0,05).

A avaliação da presença de outliers através do teste de Grubbs indica a detecção de outliers significativos em todos os três conjuntos de diferenças.

Considerando todos esses aspectos, a escolha do "melhor" resultado envolve ponderar a proximidade da média a zero (menor deslocamento sistemático) e a menor dispersão dos erros (maior precisão). O algoritmo PTIN apresenta o menor deslocamento sistemático médio, enquanto o algoritmo PMF demonstra a menor dispersão. Nenhum dos métodos apresenta uma distribuição de erros consistentemente normal, e todos possuem outliers significativos.

Em um balanço geral, o algoritmo PTIN parece oferecer um resultado mais equilibrado, com o menor deslocamento sistemático médio e uma dispersão razoavelmente baixa. Embora o algoritmo PMF tenha a menor dispersão, seu deslocamento sistemático é maior que o do algoritmo PTIN.

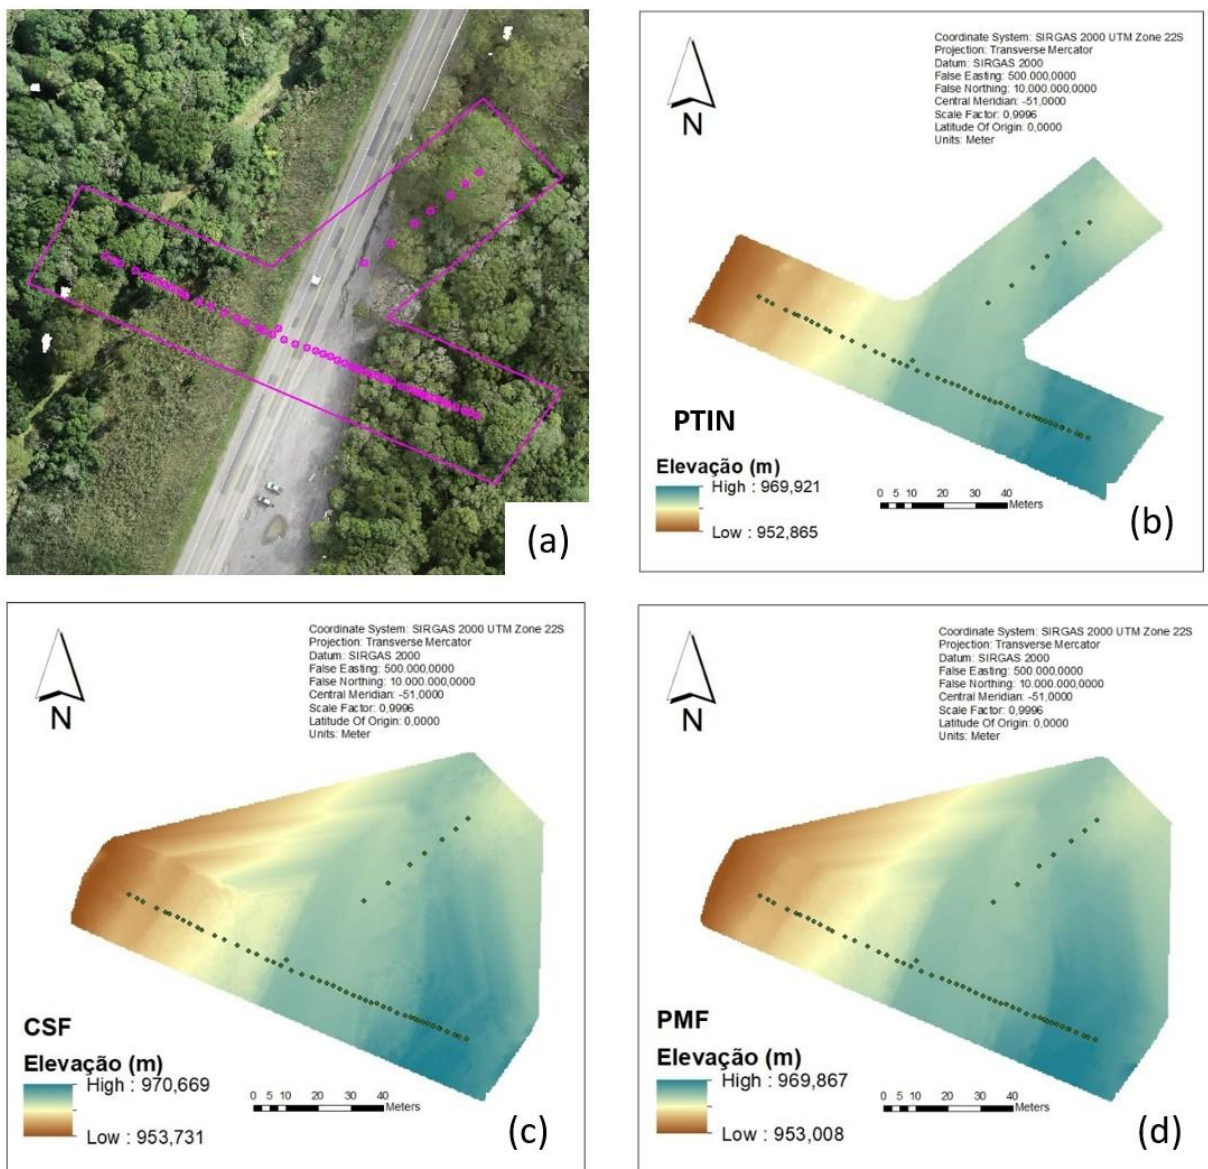
O PMF alcançou a melhor acurácia para este perfil, registrando um RMSE de 0,287 m, com o PTIN apresentando um resultado bastante similar de 0,295 m. O CSF, por sua vez, mostrou um erro um pouco maior, de 0,374 m.

Portanto, considerando a busca por um resultado com menor erro sistemático e uma dispersão aceitável, a superfície interpolada com os dados do algoritmo PTIN se destaca como o melhor resultado geral nesta análise.

5.2.8 Perfil 08 comparado entre os três algoritmos

A Figura 60 apresenta a ortofotomagem e o modelo DTM interpolado com os pontos classificados pelos três algoritmos para o local do Perfil 08.

Figura 60 - DTMs e Ortofoto referente ao Perfil 08 - (a) Ortofoto para o local, (b) DTM interpolado com os pontos classificados com o algoritmo PTIN, (c) DTM interpolado com os pontos classificados com o algoritmo CSF, (d) DTM interpolado com os pontos classificados com o algoritmo PMF



Fonte: Elaborada pelo autor (2025)

As análises estatísticas referentes ao perfil 08 comparando os resultados entre os 03 algoritmos estão apresentados na Tabela 11.

Tabela 11 - Estatística descritiva comparativa entre os três algoritmos para o perfil 08

	Resultados com algoritmo PMF (m)	Resultados com algoritmo CSF (m)	Resultados com algoritmo PTIN (m)
Média	-0,086	-0,155	0,001
Erro Padrão	0,024	0,026	0,022
Mediana	-0,085	-0,123	-0,003
Desvio Padrão	0,177	0,189	0,161
Variância Amostral	0,031	0,036	0,026
Curtose	1,098	2,283	-0,693
Assimetria	0,584	-1,277	0,005
Amplitude	0,918	0,952	0,662
Maximo	0,454	0,187	0,342
Minimo	-0,464	-0,765	-0,320
Soma	-4,728	-8,510	0,069
Contagem (n)	55	55	55
AAD	0,134	0,143	0,131
MAD	0,111	0,106	0,116
IQR	0,208	0,216	0,235
Teste Shapiro-Wilk			
W-estatística	0,965	0,907	0,986
p-valor	0,113	0,000	0,775
alpha (α)	0,05	0,05	0,05
Distribuição normal	sim	não	sim
Teste d'Agostino-Pearson			
DA-estatística	5,740	17,984	1,893
p-valor	0,057	0,000	0,388
alpha (α)	0,05	0,05	0,05
Distribuição normal	sim	não	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	0,454	-0,765	0,342
G	3,057	3,220	2,122
G-crit	2,994	2,994	2,994
significativo	sim	sim	não
RMSE	0,195	0,243	0,159

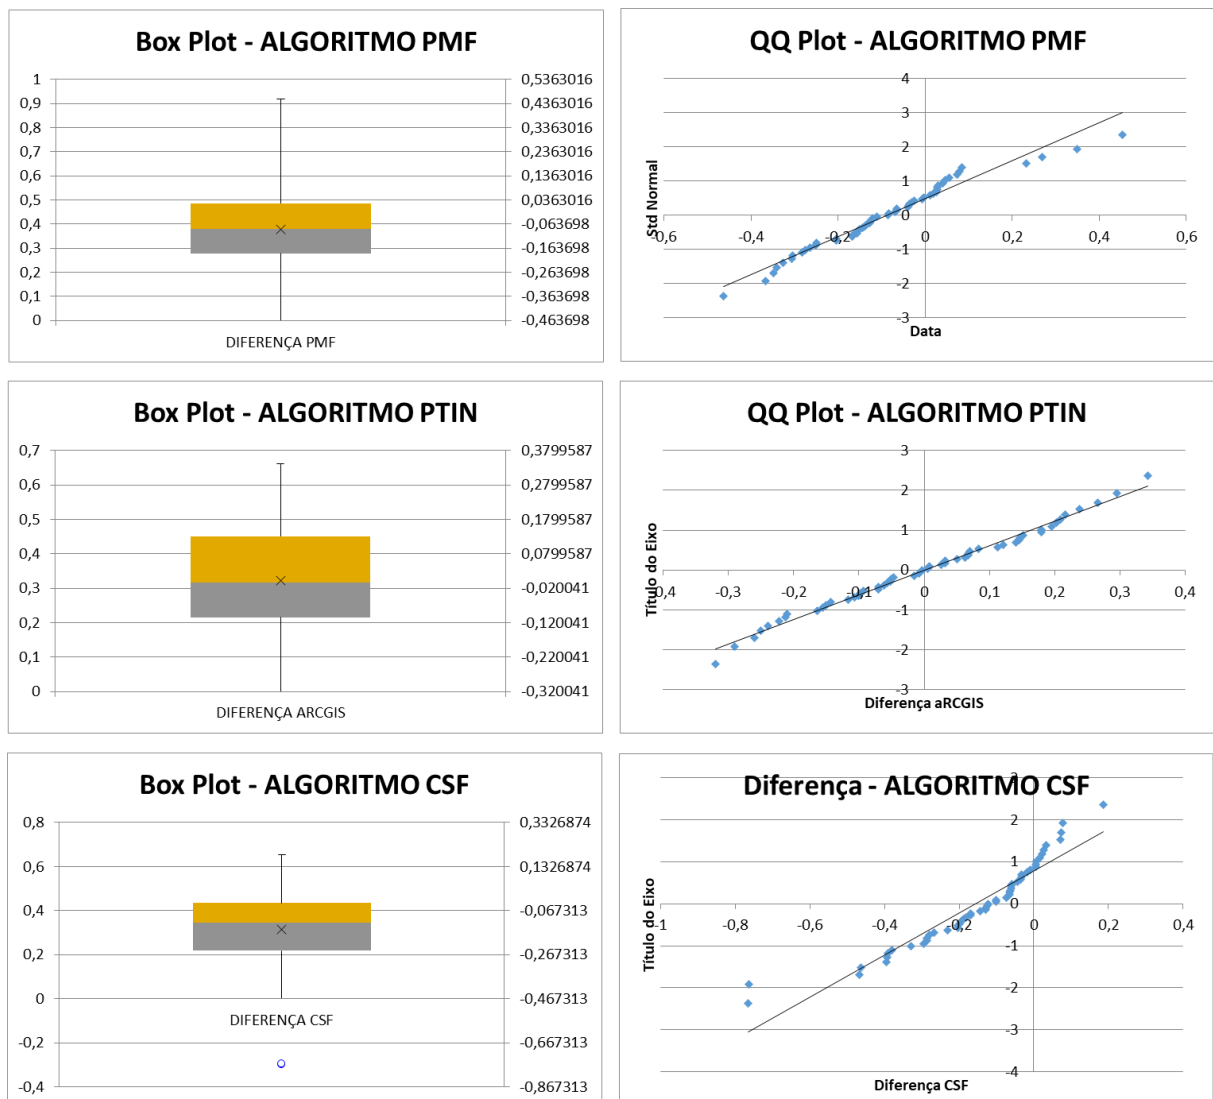
Fonte: Elaborada pelo autor (2025)

Observando as estatísticas descritivas, podemos analisar a centralidade e a dispersão dos resultados de cada método. O algoritmo PTIN apresenta uma média muito próxima de zero (0,001 m), indicando que, em média, seus resultados estão

muito próximos do valor de referência. A mediana também é bastante próxima de zero (-0,003 m). Em termos de dispersão, o desvio padrão (0,161 m) e a variância amostral (0,026 m) do algoritmo PTIN são relativamente menores em comparação com os outros dois métodos, sugerindo uma menor variabilidade em seus resultados.

A Figura 61 mostra os gráficos gerados para o Perfil 08.

Figura 61- Gráficos QQ Plot e Box Plot gerados para Perfil 08



Fonte: Elaborada pelo autor (2025)

Ao avaliar a forma da distribuição dos erros, o algoritmo PTIN também se destaca. Os testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson indicam que os dados dessa diferença seguem uma distribuição normal (p-valores de 0,775 m e 0,388 m, respectivamente, são maiores que o nível de significância de 0,05). Para os outros dois métodos, ao menos um dos testes rejeita a hipótese de normalidade. A

curtose o algoritmo PTIN (-0,693 m) está mais próxima de zero. A assimetria (0,005 m) próxima de zero indica uma distribuição mais simétrica.

A análise de outliers pelo Teste de Grubbs não identificou nenhum outlier significativo no algoritmo PTIN (o valor de G calculado, 2,122 m, é menor que o valor crítico de G, 2,994 m, e o resultado "significativo" é "não"). Isso sugere que os resultados do algoritmo PTIN são mais consistentes e menos influenciados por valores extremos.

Para o Perfil 8, o algoritmo PTIN se destacou como o mais acurado, registrando um RMSE de 0,159 m. Os algoritmos PMF e CSF obtiveram resultados menos precisos, com RMSEs de 0,195 m e 0,243 m, respectivamente.

Considerando todas essas análises, a superfície interpolada com os dados do algoritmo PTIN apresenta um comportamento estatístico mais desejável. Seus resultados demonstram uma maior proximidade ao valor de referência em média, menor dispersão, uma distribuição que se assemelha à normal e ausência de outliers significativos. Portanto, com base nos dados apresentados, o método algoritmo PTIN parece fornecer os resultados mais consistentes e alinhados com o valor de referência entre os três avaliados.

5.3 RESULTADOS POR TIPO DE OCUPAÇÃO DE SOLO

As diferenças encontradas entre os 03 algoritmos foram analisadas levando em consideração os diferentes tipos de cobertura vegetal e ocupação de solo. Sendo separados e agrupados em amostras de asfalto, floresta secundária, pinus/eucalipto, araucária e campo nativo/grama.

5.3.1 Resultados estatísticos para região com asfalto

A Tabela 12 apresenta os resultados na análise estatísticas comparando os três algoritmos para a cobertura da terra asfalto.

Ao observarmos as médias, a superfície interpolada com os dados do algoritmo PMF apresenta o valor mais próximo de zero (0,063 m), sugerindo a menor magnitude de desvio médio em comparação com a algoritmo CSF (0,075 m) e, principalmente, a algoritmo PTIN (0,239 m).

Em relação à dispersão dos dados, as diferenças observadas para a algoritmo PMF também demonstra a menor variabilidade (0,054 m), seguida pelo algoritmo CSF (0,061 m) e, com uma dispersão consideravelmente maior, para o algoritmo PTIN (0,261 m).

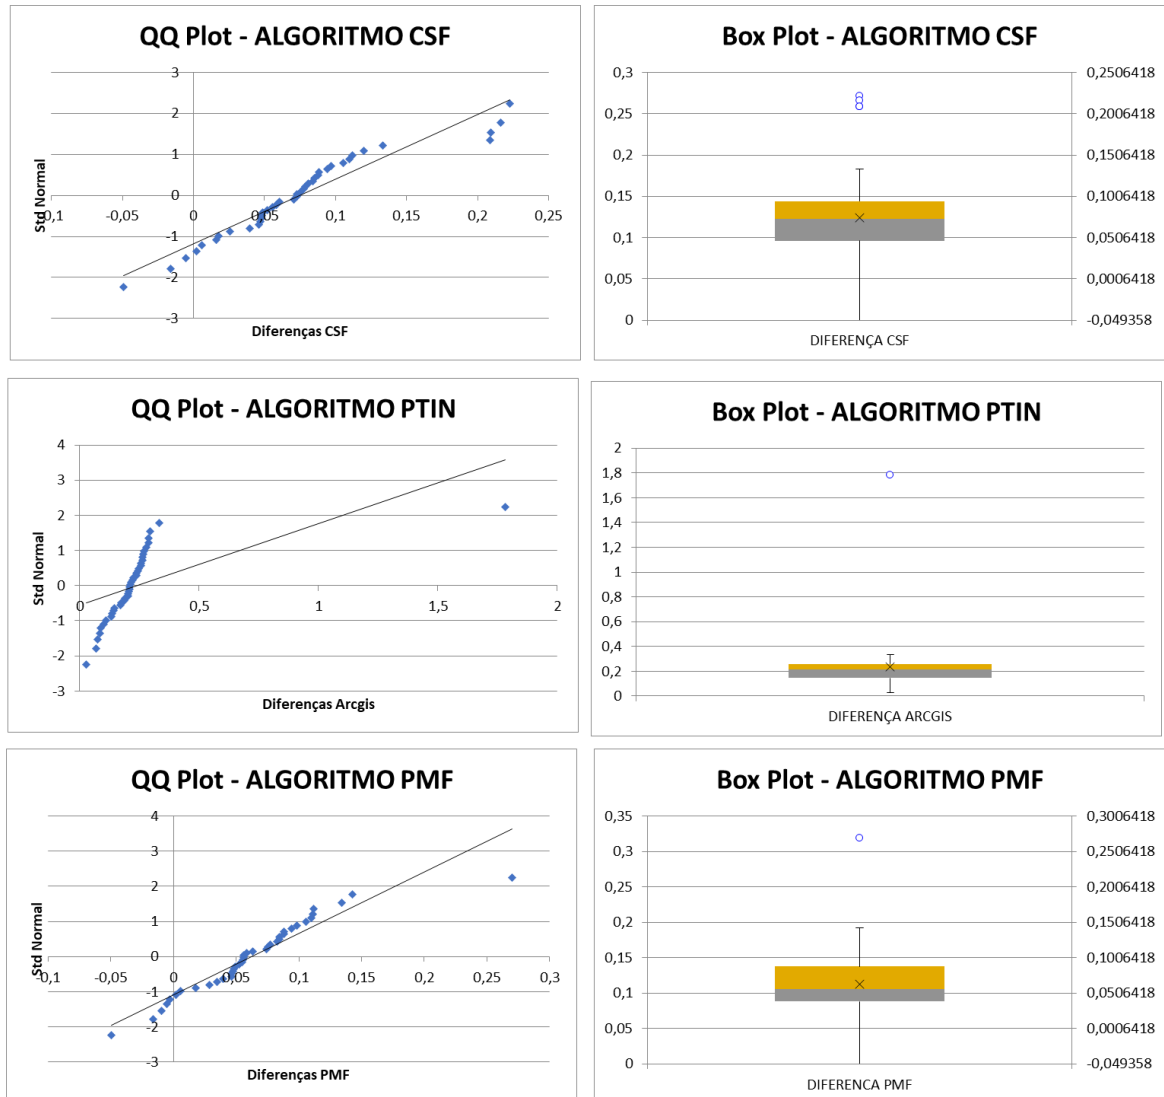
Tabela 12 - Estatística descritiva para os 03 algoritmos para amostras para a cobertura da terra asfalto

	Resultado com o algoritmo PMF (m)	Resultado com o algoritmo CSF (m)	Resultado com o algoritmo PTIN (m)
Média	0,063	0,075	0,239
Erro Padrão	0,009	0,010	0,041
Mediana	0,056	0,073	0,212
Desvio Padrão	0,054	0,061	0,261
Variância Amostral	0,003	0,004	0,068
Curtose	4,503	1,083	33,625
Assimetria	1,167	0,800	5,559
Amplitude	0,319	0,272	1,756
Maximo	0,270	0,222	1,783
Minimo	-0,049	-0,049	0,027
Soma	2,510	3,003	9,543
Contagem (n)	40	40	40
AAD	0,038	0,043	0,100
MAD	0,028	0,025	0,050
IQR	0,050	0,048	0,114
Teste Shapiro-Wilk			
W-estatística	0,916	0,924	0,386
p-valor	0,006	0,010	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste d'Agostino-Pearson			
DA-estatística	17,984	6,404	84,370
p-valor	0,000	0,041	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	0,270	0,222	1,783
G	3,827	2,427	5,924
G-crit	2,868	2,868	2,868
significativo	sim	não	sim
RMSE	0,082	0,096	0,351

Fonte: Elaborada pelo autor (2025)

Os gráficos obtidos para as diferenças observadas na classe asfalto são mostrados Figura 62.

Figura 62 - Gráficos QQ Plot e Box Plot gerados para áreas com asfalto



Fonte: Elaborada pelo autor (2025)

Os testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson indicam consistentemente que os dados de nenhuma das três diferenças seguem uma distribuição normal, uma vez que os p-valores são inferiores ao nível de significância de 0,05 em todos os casos. Essa rejeição da normalidade é importante para a escolha de testes estatísticos subsequentes.

O Teste de Grubbs identificou outliers significativos para a algoritmo PMF (o valor máximo de 0,270 m) e para a algoritmo PTIN (o valor máximo de 1,783 m). Para o algoritmo CSF, nenhum outlier foi considerado significativo. A presença desses outliers pode influenciar as estatísticas descritivas, especialmente para algoritmo PTIN, que apresenta um outlier com magnitude bem superior aos demais valores.

Considerando-se a média e o desvio padrão dos resultados, algoritmo PMF parece apresentar o melhor desempenho para a classe de cobertura de terra asfalto. Já a superfície interpolada com os pontos classificados pelo algoritmo CSF apresenta resultados ligeiramente piores em termos de média e dispersão em comparação ao observado com os resultados do algoritmo PMF. A algoritmo tem uma média consideravelmente maior e uma dispersão mais ampla, sugerindo uma menor precisão ou consistência nesse tipo de superfície.

A influência de um ambiente de asfalto nos resultados LiDAR tende a ser menos complexa em termos de múltiplos retornos em comparação com ambientes vegetados. O asfalto é uma superfície relativamente homogênea e densa, o que geralmente leva a um retorno forte e único do pulso de laser. Desvios podem ocorrer devido a variações na inclinação da superfície, imperfeições no asfalto ou ruído no sistema de aquisição.

Para o perfil de Asfalto, o algoritmo PMF demonstrou o melhor desempenho com um RMSE de apenas 0.082 m, indicando uma melhor precisão na identificação do terreno em superfícies urbanas lisas. O CSF também obteve um bom resultado (0.096), enquanto o PTIN apresentou um RMSE consideravelmente maior (0.351), sugerindo menor adequação para este tipo de cobertura.

A maior dispersão e a maior média observada para a algoritmo PTIN podem indicar uma maior sensibilidade dessa metodologia a essas características da superfície asfáltica ou a outros fatores não diretamente relacionados à natureza da superfície em si. A menor variabilidade e a média mais próxima de zero para o algoritmo PMF sugerem que essa abordagem é mais robusta ou mais adequada para levantamentos LiDAR em superfícies como o asfalto.

5.3.2 Resultados estatísticos para região com floresta secundária

A Tabela 13 apresenta os resultados na análise estatísticas comparando os três algoritmos para a classe de cobertura da terra floresta secundária.

Tabela 13 - Estatística descritiva para os 03 algoritmos para classe de cobertura da terra floresta secundária

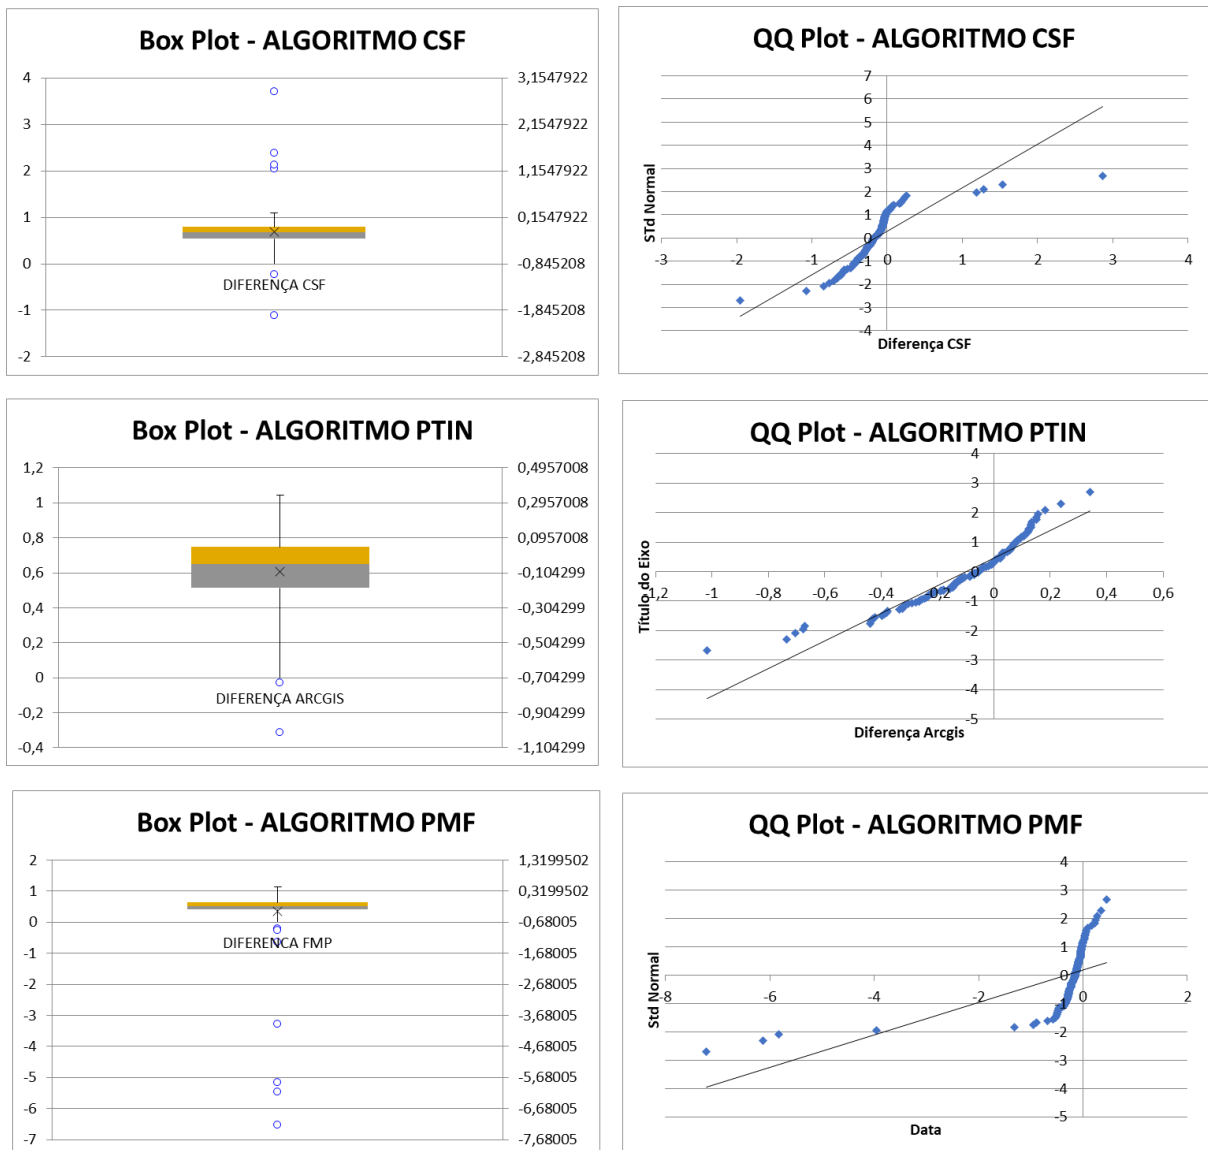
	Resultado com algoritmo PMF (m)	Resultado com algoritmo CSF (m)	Resultado com algoritmo PTIN (m)
Média	-0,338	-0,161	-0,096
Erro Padrão	0,084	0,037	0,017
Mediana	-0,156	-0,171	-0,055
Desvio Padrão	0,990	0,434	0,204
Variância Amostral	0,979	0,188	0,041
Curtose	32,289	20,971	3,410
Assimetria	-5,585	2,747	-1,409
Amplitude	7,670	4,817	1,361
Maximo	0,454	2,867	0,342
Minimo	-7,216	-1,950	-1,019
Soma	-46,662	-22,263	-13,283
Contagem (n)	138	138	138
AAD	0,376	0,229	0,152
MAD	0,112	0,129	0,113
IQR	0,230	0,258	0,235
Teste Shapiro-Wilk			
W-estatística	0,329	0,678	0,908
p-valor	0,000	0,000	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste d'Agostino-Pearson			
DA-estatística	187,490	118,685	46,091
p-valor	0,000	0,000	0,000
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	não
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-7,216	2,867	-1,019
G	6,950	6,976	4,530
G-crit	3,316	3,316	3,316
significativo	sim	sim	sim
RMSE	1,042	0,462	0,225

Fonte: Elaborada pelo autor (2025)

Ao observarmos as médias, o algoritmo PTIN apresenta o valor mais próximo de zero (-0,096 m), sugerindo que, em média, essa metodologia tende a gerar as menores discrepâncias. O algoritmo CSF tem uma média de -0,161 m, enquanto a algoritmo PMF exibe a maior magnitude de média, com -0,338 m.

Em relação à dispersão dos resultados, medida pelo desvio padrão, o algoritmo PTIN também demonstra a menor variabilidade (0,204 m), indicando uma maior consistência dos resultados obtidos com essa abordagem. O algoritmo CSF apresenta um desvio padrão intermediário (0,434 m), e a algoritmo PMF a maior dispersão (0,990 m). Os gráficos obtidos para as diferenças observadas na classe floresta secundária são mostrados Figura 63.

Figura 63 - Gráficos QQ Plot e Box Plot gerados para áreas com floresta secundária



Fonte: Elaborada pelo autor (2025)

Os testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson indicam, de forma consistente para ambos os testes, que os dados de nenhuma das três diferenças seguem uma distribuição normal, visto que os p-valores são inferiores ao nível de significância de 0,05 em todos os casos. Essa rejeição da normalidade é importante para a escolha de testes estatísticos inferenciais, sugerindo a preferência por métodos não paramétricos em comparações futuras.

O Teste de Grubbs identificou outliers significativos em todas as três distribuições. Para o algoritmo PMF, o outlier é o valor mínimo de -7,216 m; para o algoritmo CSF, o valor máximo de 2,867 m; e para o algoritmo PTIN, o valor mínimo de -1,019 m. A presença desses valores atípicos pode influenciar as estatísticas descritivas e precisa ser considerada em análises mais aprofundadas.

Considerando a menor magnitude da média e a menor dispersão dos resultados, o algoritmo PTIN se destaca como o método que, aparentemente, apresenta o melhor desempenho neste levantamento LiDAR em ambiente de floresta ombrófila mista em estágio secundário médio de sucessão.

Em ambientes florestais complexos, como a floresta ombrófila mista em estágio secundário médio, a estrutura vertical diversificada da vegetação (com diferentes alturas, densidades de copa, sub-bosque e estratos emergentes) tem uma influência significativa nos resultados LiDAR. Essa complexidade dificulta a penetração dos pulsos de laser até o solo e aumenta a ocorrência de múltiplos retornos, tornando mais difícil distinguir os pontos do solo da vegetação.

O perfil de Floresta Secundária se mostrou o mais desafiador para a maioria dos algoritmos, sendo o PTIN o que obteve o melhor resultado com um RMSE de 0.225. Este valor, apesar de maior que em outros perfis para o PTIN, é significativamente inferior aos do CSF (0.462) e, especialmente, do PMF (1.042), que demonstrou grande dificuldade em estimar o terreno sob a complexa estrutura de vegetação densa e heterogênea deste tipo de floresta.

A maior densidade de biomassa atenua o sinal do laser, reduzindo a detecção do terreno sob a copa. A variabilidade na densidade da vegetação ao longo da área de estudo pode gerar inconsistências nos MDT e MDS. Nesse contexto, métodos menos sensíveis a essa variabilidade estrutural, como o algoritmo PTIN mencionada, tendem a ser mais eficazes.

5.3.3 Resultados estatísticos para região com araucárias

A Tabela 14 apresenta os resultados na análise estatísticas comparando os três algoritmos para a classe de cobertura da terra araucária.

Tabela 14 - Estatística descritiva para 03 algoritmos para classe de cobertura da terra araucária

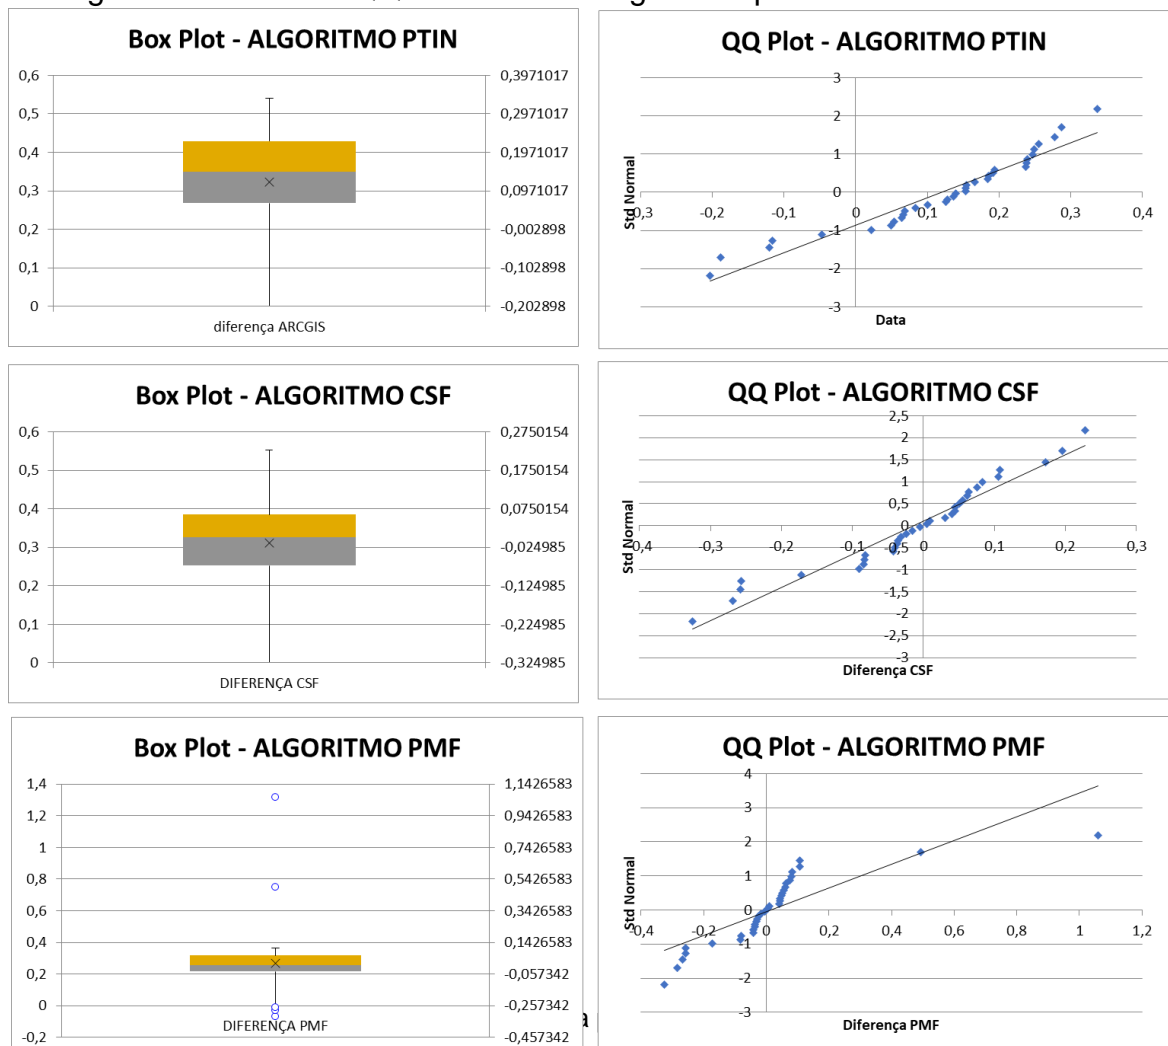
	Resultados com o algoritmo PMF (m)	Resultados com o algoritmo CSF (m)	Resultados com o algoritmo PTIN (m)
Média	0,013	-0,014	0,121
Erro Padrão	0,041	0,022	0,023
Mediana	0,000	0,000	0,147
Desvio Padrão	0,238	0,129	0,134
Variância Amostral	0,057	0,017	0,018
Curtose	11,369	0,505	0,447
Assimetria	2,689	-0,660	-0,898
Amplitude	1,384	0,553	0,540
Maximo	1,059	0,228	0,337
Minimo	-0,325	-0,325	-0,203
Soma	0,441	-0,476	4,114
Contagem (n)	34	34	34
AAD	0,131	0,095	0,102
MAD	0,058	0,062	0,086
IQR	0,102	0,133	0,162
Teste Shapiro-Wilk			
W-estatística	0,706	0,943	0,928
p-valor	0,000	0,078	0,028
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	sim	não
Teste d'Agostino-Pearson			
DA-estatística	41,069	3,411	5,281
p-valor	0,000	0,182	0,071
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	sim	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	1,059	-0,325	-0,203
G	4,399	2,419	2,424
G-crit	2,799	2,799	2,799
sigificativo	sim	não	no
RMSE	0,234	0,127	0,179

Fonte: Elaborada pelo autor (2025)

Ao examinarmos as médias, a superfície interpolada com pontos classificados com o algoritmo CSF demonstra o valor mais próximo de zero (-0,014 m), sugerindo uma tendência a menores desvios médios. O algoritmo PMF apresenta uma média de 0,013 m, também próxima de zero, enquanto o algoritmo PTIN exibe uma média um pouco maior, de 0,121 m.

No que concerne à dispersão dos resultados, avaliada pelo desvio padrão, o algoritmo CSF novamente se destaca com o menor valor (0,129m), indicando uma menor variabilidade e, portanto, uma maior consistência dos resultados em torno de sua média. O algoritmo PTIN apresenta um desvio padrão ligeiramente maior (0,134 m), e a algoritmo PMF o maior (0,238 m), revelando uma maior dispersão em seus resultados. Os gráficos obtidos para as diferenças observadas na classe araucária são mostrados Figura 64.

Figura 64 - Gráficos QQ Plot e Box Plot gerados para áreas com araucária



Os testes de normalidade fornecem informações mistas. O teste de Shapiro-Wilk sugere que apenas o algoritmo CSF segue uma distribuição normal (p -valor = $0,078 > \alpha = 0,05$), enquanto as outras duas não. O teste de D'Agostino-Pearson indica normalidade para o algoritmo CSF e o algoritmo PTIN (p -valores de $0,182$ e $0,071$, respectivamente, ambos maiores que $0,05$), mas não para o algoritmo PMF. Essa inconsistência ressalta a importância de cautela ao aplicar testes estatísticos que assumem normalidade.

O Teste de Grubbs identificou um outlier significativo apenas para o algoritmo PMF (o valor máximo de $1,059$ m). Para as outras duas abordagens, nenhum outlier foi considerado significativo no nível de $\alpha=0,05$.

Considerando a proximidade da média ao zero e a menor dispersão, a superfície interpolada com os pontos classificados com o algoritmo CSF parece apresentar o melhor desempenho geral neste conjunto de dados obtidos em ambiente com araucárias. Ela demonstra a menor média em valor absoluto e a menor variabilidade, além de apresentar evidências de distribuição normal segundo ambos os testes aplicados.

A influência do ambiente florestal com araucárias nos resultados LiDAR é notável. A densa estrutura da copa das araucárias pode dificultar a penetração dos pulsos de laser até o solo, levando a uma menor quantidade de retornos do terreno e a uma maior complexidade nos retornos da vegetação. Isso pode resultar em DTMs menos precisos e em desafios na distinção entre a superfície do solo e a vegetação durante o processamento dos dados LiDAR.

No perfil de Araucária, o CSF se destacou com o menor RMSE de $0,127$, mostrando sua eficácia em ambientes florestais com árvores de porte significativo, mas talvez com menor densidade de sub-bosque. O PTIN ($0,179$) e o PMF ($0,234$) seguiram, com o PMF apresentando o maior erro para esta cobertura.

A capacidade de uma metodologia em gerar resultados consistentes e com baixo desvio médio, como observado para a superfície gerada com o algoritmo CSF, sugere uma maior robustez em LiDAR com essas características específicas de um ambiente florestal denso como o de araucárias. Portanto, o algoritmo CSF parece ser a abordagem mais adequada neste contexto.

5.3.4 Resultados estatísticos para região com pinus e eucalipto

A Tabela 15 apresenta os resultados na análise estatísticas comparando os 03 algoritmos para a classe de cobertura da terra pinus e eucalipto.

Tabela 15 - Estatística descritiva para 03 algoritmos para classe de cobertura da terra pinus e eucalipto

	Resultado com o algoritmo PMF (m)	Resultado com o algoritmo CSF (m)	Resultado com o algoritmo PTIN (m)
Média	-0,162	-0,213	-0,029
Erro Padrão	0,031	0,042	0,035
Mediana	-0,150	-0,152	-0,023
Desvio Padrão	0,176	0,239	0,198
Variância Amostral	0,031	0,057	0,039
Curtose	0,020	0,664	0,167
Assimetria	-0,094	-1,041	-0,164
Amplitude	0,760	0,895	0,920
Maximo	0,256	0,125	0,431
Minimo	-0,504	-0,770	-0,490
Soma	-5,186	-6,810	-0,933
Contagem (n)	32	32	32
AAD	0,131	0,182	0,155
MAD	0,115	0,128	0,105
IQR	0,223	0,217	0,227
Teste Shapiro-Wilk			
W-estatística	0,968	0,900	0,981
p-valor	0,441	0,006	0,831
alpha (α)	0,05	0,05	0,05
Distribuição normal	sim	não	sim
Teste d'Agostino-Pearson			
DA-estatística	0,125	6,674	0,372
p-valor	0,940	0,036	0,830
alpha (α)	0,05	0,05	0,05
Distribuição normal	sim	não	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	0,256	-0,770	-0,490
G	2,380	2,332	2,331
G-crit	2,773	2,773	2,773
sigificativo	não	não	não
RMSE	0,237	0,317	0,196

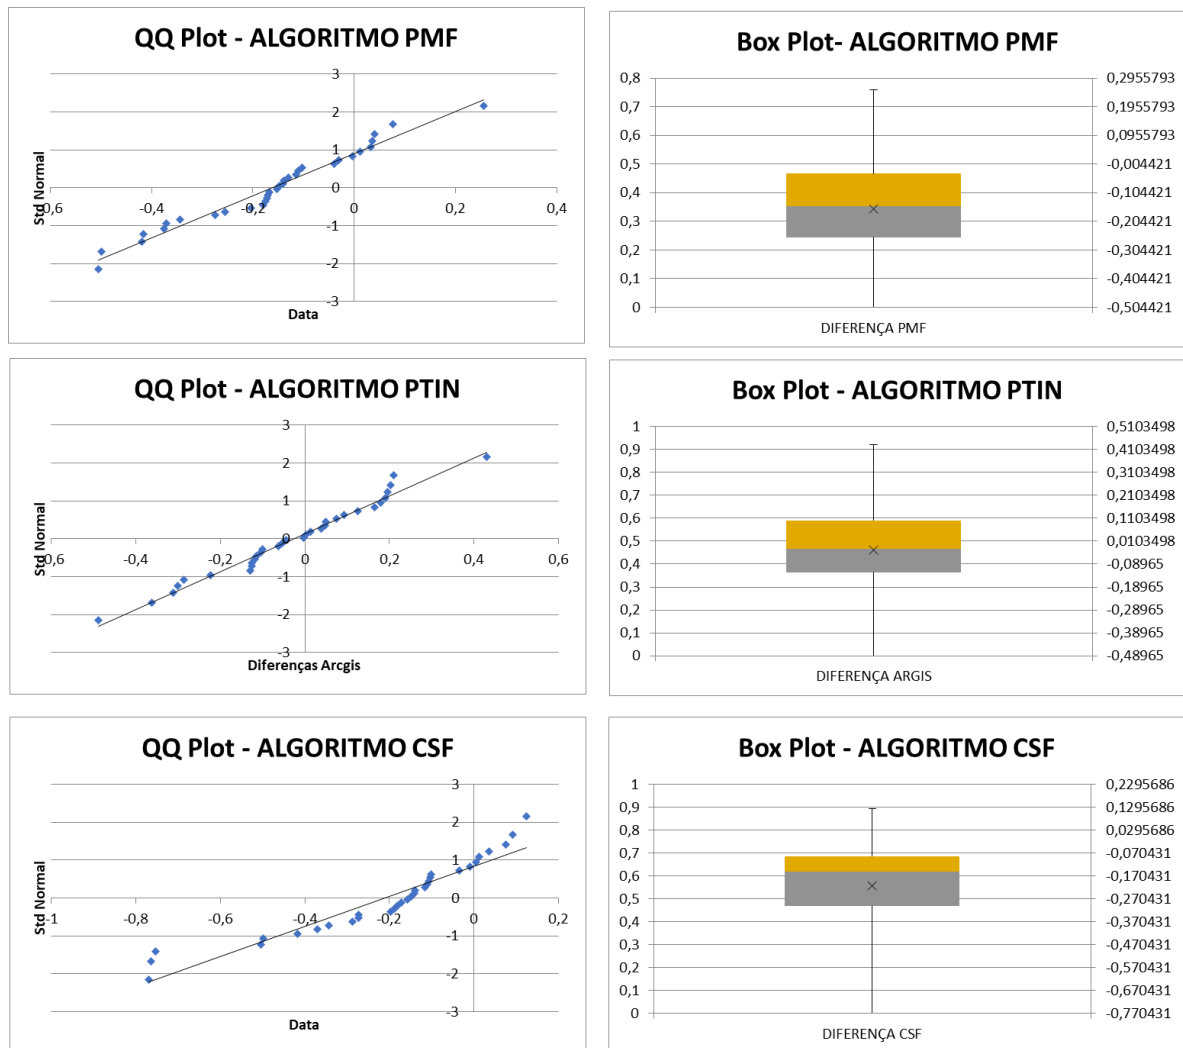
Fonte: Elaborada pelo autor (2025)

Dada a complexidade estrutural desse tipo de vegetação, com suas copas densas e alturas consideráveis, a capacidade de um método em fornecer estimativas precisas da elevação do terreno é fundamental.

Observa-se que o algoritmo PTIN apresenta a média mais próxima de zero (-0,029 m), sugerindo que, em média, suas estimativas de elevação se desviam menos do que as dos outros métodos em relação a algum valor de referência. O algoritmo CSF, por outro lado, exibe a média mais distante de zero (-0,213 m). O algoritmo PMF situa-se entre os dois, com uma média de -0,162 m.

Os gráficos obtidos para as diferenças observadas na classe de cobertura da terra pinus e eucalipto são mostrados Figura 65.

Figura 65 - Gráficos QQ Plot e Box Plot gerados para áreas com pinus e eucalipto



Fonte: Elaborada pelo autor (2025)

Constata-se que a superfície interpolada com os pontos classificados com o algoritmo CSF apresenta o maior desvio padrão (0,239 m), revelando uma maior variabilidade nos seus erros. O algoritmo PMF demonstra o menor desvio padrão (0,176 m), indicando uma maior homogeneidade nos seus resultados. O algoritmo PTIN possui um desvio padrão intermediário (0,198 m).

Para a escolha do melhor método neste contexto específico de floresta de pinus e eucalipto, devemos buscar um equilíbrio entre a centralidade das diferenças (média próxima de zero) e a sua dispersão (menor desvio padrão). A superfície interpolada com os pontos classificados com o algoritmo PTIN se destaca por apresentar a menor média das diferenças, sugerindo uma menor tendência de afastamento geral do valor de referência. No entanto, a superfície interpolada com os pontos classificados com o algoritmo o algoritmo PMF demonstra a menor dispersão dos erros, indicando uma maior consistência nas suas estimativas.

Em um ambiente florestal denso como o de pinus e eucalipto adultos, a capacidade de minimizar a variabilidade nas estimativas pode ser tão importante quanto a proximidade da média ao valor de referência. Portanto, considerando a menor dispersão observada e uma média razoavelmente próxima de zero, o algoritmo PMF pode ser considerado o mais robusto para esta situação específica, oferecendo resultados mais consistentes. Embora algoritmo PTIN apresente uma menor diferença média, sua maior variabilidade pode levar a uma menor confiabilidade em estimativas pontuais.

Para Pinus e eucalipto, o PTIN foi o mais preciso, registrando um RMSE de 0.196. Isso indica sua capacidade de LiDAR bem com florestas de monocultura, que podem apresentar desafios devido à densidade das copas. O PMF (0.237) e o CSF (0.317) apresentaram erros superiores, com o CSF sendo o menos eficaz neste tipo de cobertura.

Em resumo, analisando os principais índices descritivos, e considerando a busca por um método que forneça estimativas consistentes em um ambiente florestal complexo, a superfície interpolada com os pontos classificados com o algoritmo PMF se apresenta como uma opção promissora devido à sua menor dispersão dos erros.

5.3.5 Resultados estatísticos para região com grama e campo nativo

A Tabela 16 apresenta os resultados na análise estatísticas comparando os 03 algoritmos para a classe de cobertura da terra grama e campo nativo.

Tabela 16 - Estatística descritiva para os 03 algoritmos para a classe de cobertura da terra grama e campo nativo

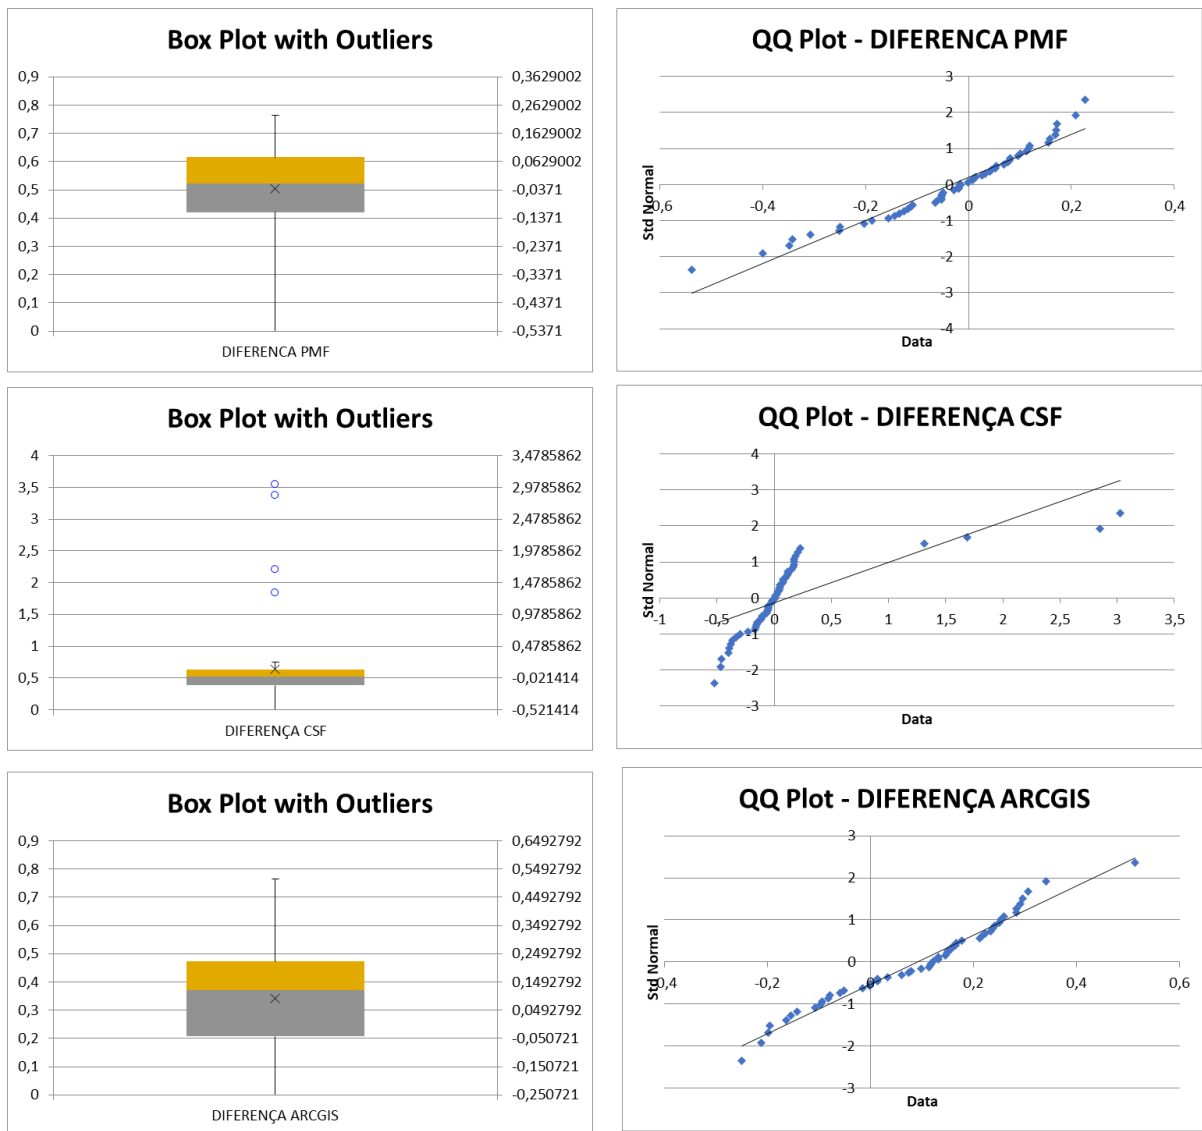
	Resultados com algoritmo PMF (m)	Resultados com algoritmo CSF (m)	Resultados com algoritmo PTIN (m)
Média	-0,034	0,112	0,091
Erro Padrão	0,022	0,090	0,023
Mediana	-0,016	0,005	0,120
Desvio Padrão	0,162	0,662	0,168
Variância Amostral	0,026	0,439	0,028
Curtose	0,887	11,924	-0,440
Assimetria	-0,918	3,339	-0,154
Amplitude	0,763	3,548	0,765
Maximo	0,226	3,026	0,514
Minimo	-0,537	-0,521	-0,251
Soma	-1,811	6,042	4,919
Contagem (n)	54	54	54
AAD	0,124	0,334	0,138
MAD	0,096	0,119	0,120
IQR	0,195	0,253	0,264
Teste Shapiro-Wilk			
W-estatística	0,947	0,563	0,972
p-valor	0,018	0,000	0,240
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	sim
Teste d'Agostino-Pearson			
DA-estatística	8,937	61,959	0,692
p-valor	0,011	0,000	0,707
alpha (α)	0,05	0,05	0,05
Distribuição normal	não	não	sim
Teste de Grubbs			
alpha (α)	0,05	0,05	0,05
outlier	-0,537	3,026	0,514
G	3,112	4,400	2,522
G-crit	2,987	2,987	2,987
sigificativo	sim	sim	não
RMSE	0,164	0,666	0,190

Fonte: Elaborada pelo autor (2025)

Em superfícies mais abertas e com vegetação rasteira como campo e grama, esperaríamos uma menor complexidade na interação do pulso laser em comparação com ambientes florestais densos.

Os gráficos obtidos para as diferenças observadas na classe de cobertura da terra com grama e campo nativo são mostrados Figura 66.

Figura 66 - Gráficos QQ Plot e Box Plot gerados para áreas com grama e campo nativo



Fonte: Elaborada pelo autor (2025)

Observando a média das diferenças, a superfície gerada através da interpolação com os pontos classificados com o algoritmo PTIN apresenta o valor mais próximo de zero (0,091 m), sugerindo um menor afastamento geral em relação a alguma referência. O algoritmo PMF também exibe uma média relativamente baixa (-

0,034 m). Em contraste, o algoritmo CSF demonstra uma média consideravelmente maior (0,112 m).

A dispersão dos erros, avaliada pelo desvio padrão, revela que o algoritmo PMF possui a menor dispersão (0,162 m), indicando uma maior consistência em suas estimativas. Os resultados obtidos com o algoritmo PTIN apresenta um desvio padrão ligeiramente maior (0,168 m), enquanto o algoritmo CSF exibe uma dispersão muito maior (0,662 m).

Considerando os testes de normalidade, o Teste de Shapiro-Wilk indica que apenas as diferenças do algoritmo PTIN seguem uma distribuição normal (p -valor = 0,240 > 0,05). As diferenças do PMF (p -valor = 0,018 < 0,05) e do CSF (p -valor = 0,000 < 0,05) não apresentam distribuição normal. O Teste de D'Agostino-Pearson corrobora esses resultados, com apenas os resultados obtidos com o algoritmo PTIN indicando normalidade.

O Teste de Grubbs para detecção de outliers identificou um outlier significativo para os resultados com o algoritmo CSF (valor máximo da diferença de 3,026 m, com G calculado maior que G -crítico), e também para o PMF (valor mínimo de -0,537 m). Os resultados obtidos com o algoritmo PTIN não apresentou outliers significativos.

Em um ambiente de campo e grama, onde a superfície é relativamente menos complexa, esperaríamos que os métodos fornecessem resultados mais consistentes. A superfície obtida com o algoritmo PMF se destaca por apresentar a menor dispersão dos erros, o que sugere uma maior confiabilidade e homogeneidade nas suas estimativas. Embora o algoritmo PTIN tenha a média das diferenças mais próxima de zero e siga uma distribuição normal, sua dispersão é ligeiramente maior que a do PMF. O método CSF demonstra uma dispersão muito elevada e não segue uma distribuição normal, além de apresentar um outlier significativo, o que o torna menos adequado para este tipo de ambiente.

Em Grama e campo, o PMF obteve o menor RMSE de 0.164, demonstrando sua eficiência em áreas abertas com vegetação rasteira. Curiosamente, o CSF registrou o pior desempenho de toda a tabela para este perfil, com um RMSE muito alto de 0.666, indicando uma dificuldade significativa em separar o terreno da vegetação herbácea. O PTIN (0.190) também performou bem, próximo ao PMF.

Portanto, para um ambiente de campo e grama, a superfície gerada com o algoritmo PMF parece ser a melhor escolha devido à sua menor variabilidade nos resultados, indicando uma maior precisão na obtenção do Modelo Digital de Terreno.

6 DISCUSSÃO

6.1 RESULTADOS AGRUPADOS EM PERFIS

Ao revisitar as oito tabelas de resultados que analisamos, buscando um panorama geral do desempenho dos algoritmos PMF, CSF e PTIN, podemos traçar algumas conclusões sobre qual deles consistentemente entrega os resultados mais promissores. Os resultados de média e desvio padrão estão agrupados na tabela 17.

Tabela 17 - Média e Desvio Padrão para os três algoritmos aplicados em cada perfil

Perfil	Média CSF	Desvio Padrão CSF	Média PMF	Desvio Padrão PMF	Média PTIN	Desvio Padrão PTIN
01	-0,109	0,108	0,028	0,368	0,017	0,137
02	0,057	0,197	0,009	0,131	0,1427	0,1319
03	-0,091	0,124	-0,090	0,129	0,045	0,1497
04	-0,012	0,5768	-0,112	0,244	0,015	0,193
05	-0,954	2,079	-0,020	0,551	0,0245	0,2528
06	-0,018	0,943	-0,134	0,184	-0,043	0,257
07	-0,270	0,262	-0,196	0,212	-0,138	0,264
08	-0,155	0,189	-0,086	0,177	0,001	0,161

Fonte: Elaborada pelo autor (2025)

Em relação à tendência central, avaliada pela média, observamos que tanto o algoritmo PMF quanto o PTIN demonstraram, em diferentes momentos, médias mais próximas de zero, indicando um menor erro sistemático em relação ao valor de referência. Os resultados do algoritmo CSF, por vezes, também apresentou médias competitivas.

No que concerne à dispersão, medida pelo desvio padrão, o PTIN e o PMF frequentemente exibiram menor variabilidade nos erros, sugerindo uma maior precisão em suas estimativas em comparação com o CSF, que tendeu a mostrar uma maior dispersão.

A normalidade da distribuição dos erros foi mais frequentemente sugerida para os resultados obtidos com PTIN pelos testes estatísticos, o que é uma característica desejável para a aplicação de muitas técnicas de análise. Os resultados obtidos com o algoritmo PMF mostrou normalidade em algumas ocasiões, enquanto o CSF raramente a indicou.

Quanto à presença de outliers, o PTIN, em algumas das análises, foi o método que menos frequentemente apresentou outliers significativos, o que pode indicar uma maior estabilidade de suas estimativas.

Considerando um equilíbrio entre um baixo erro sistemático (média próxima de zero), uma boa precisão (menor dispersão), a aderência à normalidade (quando verificada) e a ausência de outliers, o algoritmo PTIN parece ser o método que, de forma mais consistente ao longo das oito tabelas, entregou resultados que balanceiam essas qualidades de maneira mais eficaz. Embora nenhum método seja perfeito em todos os cenários, a regularidade com que os resultados obtidos com o algoritmo PTIN demonstra um bom desempenho em múltiplos aspectos sugere uma robustez maior em diferentes conjuntos de dados.

Portanto, ao considerar o conjunto das oito análises, as superfícies interpoladas com pontos classificados com o algoritmo PTIN se destaca como o método que, de maneira geral, oferece o melhor resultado, apresentando um equilíbrio mais favorável entre as diversas métricas estatísticas avaliadas.

6.1.1 Avaliação da acurácia altimétrica de acordo com a Classe A do Decreto-Lei nº 89.817/84

Para a Classe A do Decreto-Lei nº 89.817/84, o Erro Padrão dos erros altimétricos não deve exceder $1/3$ da equidistância das curvas de nível sugeridas para projeto. Para efeitos desta pesquisa é considerado a equidistâncias de 1m, que comumente é exigido para projetos geométricos de estradas. Com uma equidistância de 1 metro, o limite máximo permitido para o Erro Padrão é $1\text{ m}/3=0.333\text{ m}$

A tabela 18 agrupa os dados de RMSE e EP encontrados nos oitos perfis analisados, e atribui ao algoritmo se atende ou não os requisitos para a Classe A do referido Decreto-Lei.

Tabela 18 - RMSE e Erro Padrão para os três algoritmos aplicados em cada perfil e atendimento ao padrão Classe A da Decreto-Lei nº 89.817/84

Perfil	RMSE PMF (m)	Erro Padrão PMF (m)	Atende ao padrão Classe A	RMSE CSF (m)	Erro Padrão CSF (m)	Atende ao padrão Classe A	RMSE PTIN (m)	Erro Padrão PTIN (m)	Atende ao padrão Classe A
1	0.355	0.102	Sim	0.151	0.109	Sim	0.133	0.038	Sim
2	0.13	0.016	Sim	0.204	0.025	Sim	0.194	0.016	Sim
3	0.156	0.063	Sim	0.153	0.068	Sim	0.154	0.0246	Sim
4	0.266	0.037	Sim	0.57	0.869	Não	0.191	0.029	Sim
5	2.254	0.393	Não	0.542	0.104	Sim	0.249	0.0478	Sim
6	0.225	0.034	Sim	0.9274	0.172	Sim	0.256	0.047	Sim
7	0.287	0.035	Sim	0.374	0.043	Sim	0.295	0.043	Sim
8	0.195	0.024	Sim	0.243	0.026	Não	0.159	0.022	Sim

Fonte: Elaborada pelo autor (2025)

A avaliação dos algoritmos PTIN, PMF e CSF, em relação à qualificação para a Classe A conforme o Decreto-Lei nº 89.817/84, demonstrou que o PTIN é o único a atingir consistentemente a Classe A em todos os perfis, indicando alta acurácia e confiabilidade. O PMF e o CSF qualificam-se para a Classe A na maioria dos perfis, mas falham em cenários específicos (Perfil 5 para PMF e Perfil 4 para CSF).

A análise comparativa dos algoritmos PTIN, PMF e CSF, baseada nos valores de RMSE, revela que o algoritmo PTIN se destaca como o mais consistente. Ele obteve o menor RMSE em quatro dos oito perfis e, crucialmente, evitou os erros extremamente altos observados nos outros métodos. Embora o PMF tenha sido o mais acurado em três perfis, sua performance foi comprometida por um RMSE excepcionalmente elevado no Perfil 5. Já o CSF, com o menor RMSE em apenas um perfil, mostrou-se o menos confiável, apresentando os maiores erros em múltiplos cenários.

6.2 RESULTADOS AGRUPADOS EM TIPO DE COBERTURA DA TERRA

No ambiente de asfalto, os três métodos tendem a superestimar os valores em relação à referência, sendo essa superestimação mais forte nos resultados obtidos com o algoritmo PTIN. Em termos de consistência, os algoritmos PMF e CSF mostram-se mais precisos (menor dispersão) que o PTIN. Os resultados de média e desvio padrão estão agrupados na tabela 19.

Tabela 19 - Média e Desvio Padrão para os três algoritmos aplicados em cada classe de cobertura de solo

Ambiente	Média PMF	Desvio Padrão PMF	Média CSF	Desvio Padrão CSF	Média PTIN	Desvio Padrão PTIN
Asfalto	0,063	0,054	0,075	0,061	0,239	0,261
Floresta Secundária	-0,338	0,990	-0,161	0,434	-0,096	0,204
Áreas com Araucária	0,013	0,238	-0,014	0,129	0,121	0,134
Áreas com Pinus e Eucalipto	-0,162	0,176	-0,213	0,239	-0,029	0,198
Gramma e Campo Nativo	-0,034	0,162	0,112	0,662	0,091	0,168

Fonte: Elaborada pelo autor (2025)

Um ponto problemático é que as diferenças geradas por todos os métodos não seguem uma distribuição normal, o que dificulta o uso de testes estatísticos que assumem essa propriedade. Além disso, foram detectados outliers significativos para todos os métodos, indicando a presença de valores discrepantes que podem distorcer as análises.

Na floresta secundária, a situação se inverte em relação ao erro sistemático: os três métodos tendem a subestimar a referência. Curiosamente, os resultados obtidos com o algoritmo PTIN apresenta o menor grau de subestimação nesse ambiente. Contudo, o algoritmo PMF demonstra a menor precisão, com um desvio padrão das diferenças consideravelmente maior que os dos outros dois métodos. Similarmente

ao asfalto, as diferenças não são normalmente distribuídas para nenhum dos métodos, e há outliers significativos detectados, o que pode ser esperado dada a maior complexidade estrutural de uma floresta.

Em áreas de araucária, tanto os resultados obtidos com o algoritmo PMF quanto o CSF exibem médias de diferenças próximas de zero, o que é um bom sinal de menor erro sistemático. O PTIN apresenta um erro sistemático ligeiramente maior. A precisão é maior para CSF e PTIN (menor dispersão) em comparação com o PMF. Uma vantagem notável é que as diferenças do CSF e do PTIN mostram indícios de normalidade. Apenas os resultados do algoritmo PMF apresentou um outlier significativo. Isso sugere que, para áreas com araucária, as superfícies geradas com os algoritmos CSF e PTIN podem ser mais confiáveis e produzir dados mais adequados para análises estatísticas paramétricas.

Nas áreas de pinus e eucalipto, observa-se uma leve tendência de subestimação por todos os métodos, com o algoritmo PTIN apresentando o menor erro sistemático. A precisão dos três métodos é comparável (desvios padrão semelhantes). Um resultado positivo é que as diferenças encontradas nos resultados obtidos com o algoritmo PMF e PTIN parecem seguir uma distribuição normal. Nenhum outlier significativo foi detectado nesse tipo de cobertura, o que pode indicar uma maior homogeneidade nas diferenças geradas.

Finalmente, em áreas de grama e campo nativo, o algoritmo PMF tende a subestimar levemente, enquanto os resultados obtidos com o algoritmo CSF e PTIN tendem a superestimar. A precisão é maior aplicando o algoritmo PMF e PTIN (menor dispersão) em relação ao algoritmo CSF. Apenas as diferenças geradas pelo algoritmo PTIN aparentam seguir uma distribuição normal. Foram identificados outliers significativos para os algoritmos PMF e CSF, mas não para os resultados com o algoritmo PTIN. Isso indica que, para essas áreas, a superfície gerada com o algoritmo PTIN pode ser o método que gera resultados com distribuição mais próxima da normal e sem valores atípicos detectados pelo teste utilizado.

6.2.1 Avaliação da acurácia altimétrica de acordo com a Classe A do Decreto-Lei nº 89.817/84

A tabela 20 agrupa os dados de RMSE e EP encontrados nas diferentes classes de ocupação de solo analisadas, e atribui ao algoritmo se atende ou não os requisitos para a Classe A do referido Decreto-Lei.

Tabela 20 - RMSE e Erro Padrão para os três algoritmos aplicados em cada cobertura de solo e atendimento ao padrão Classe A da Decreto-Lei nº 89.817/84

Perfil	RMSE PMF (m)	Erro Padrão PMF (m)	Atende ao padrão Classe A	RMSE CSF (m)	Erro Padrão CSF (m)	Atende ao padrão Classe A	RMSE PTIN (m)	Erro Padrão PTIN (m)	Atende ao padrão Classe A
Asfalto	0,082	0,009	Sim	0,096	0,01	Sim	0,351	0,041	Sim
Araucária	0,234	0,041	Sim	0,127	0,022	Sim	0,179	0,023	Sim
Pinus e eucalipto	0,237	0,031	Sim	0,317	0,042	Sim	0,196	0,035	Sim
Gramma e campo	0,164	0,022	Sim	0,666	0,09	Sim	0,19	0,023	Sim
Floresta Secundária	1,042	0,084	Sim	0,462	0,037	Sim	0,225	0,017	Sim

Fonte: Elaborada pelo autor (2025)

6.3 DISCUSSÃO DOS RESULTADOS

A tabela 21 agrupa os valores de média, desvio padrão, RMSE e erro padrão, além de indicar se cada perfil atende ou não ao padrão da Classe A da Decreto-Lei nº 89.817/84.

Na análise das métricas de média e desvio padrão, observa-se que o algoritmo PMF apresenta as menores médias de diferença em relação aos perfis, indicando que, em geral, ele tende a estar mais próximo do valor real dos perfis. No entanto, seu desvio padrão é significativamente mais alto em alguns casos (como no Perfil 5 com 0,551), sugerindo uma maior variabilidade em seus resultados e, conseqüentemente, menor consistência em certas situações. O algoritmo CSF, por sua vez, exibe médias de diferença ligeiramente maiores que o PMF em alguns perfis, mas com desvios padrão que também variam consideravelmente, especialmente em perfis como o 5 (2,079), indicando uma menor precisão e maior dispersão dos resultados. Já o PTIN se destaca por apresentar médias de diferença e desvios padrão consistentemente

baixos em todos os perfis, demonstrando uma maior acurácia e, principalmente, uma notável estabilidade e repetibilidade em seus resultados.

Tabela 21 – Tabela resumo de resultados para os 08 perfis.

Perfil Vs. PMF	Média PMF (m)	Desvio Padrão PMF (m)	RMSE PMF (m)	Erro Padrão PMF (m)	Atende ao padrão Classe A
1	0,028	0,368	0.355	0.102	Sim
2	0,009	0,131	0.13	0.016	Sim
3	-0,09	0,129	0.156	0.063	Sim
4	-0,112	0,244	0.266	0.037	Sim
5	-0,02	0,551	2.254	0.393	Não
6	-0,134	0,184	0.225	0.034	Sim
7	-0,196	0,212	0.287	0.035	Sim
8	-0,086	0,177	0.195	0.024	Sim
Perfil vs. CSF	Média CSF (m)	Desvio Padrão CSF (m)	RMSE CSF (m)	Erro Padrão CSF (m)	Atende ao padrão Classe A
1	-0,109	0,108	0.151	0.109	Sim
2	0,057	0,197	0.204	0.025	Sim
3	-0,091	0,124	0.153	0.068	Sim
4	-0,012	0,5768	0.57	0.869	Não
5	-0,954	2,079	0.542	0.104	Sim
6	-0,018	0,943	0.9274	0.172	Sim
7	-0,27	0,262	0.374	0.043	Sim
8	-0,155	0,189	0.243	0.026	Não
Perfil vs. PTIN	Média PTIN (m)	Desvio Padrão PTIN (m)	RMSE PTIN (m)	Erro Padrão PTIN (m)	Atende ao padrão Classe A
1	0,017	0,137	0.133	0.038	Sim
2	0,1427	0,1319	0.194	0.016	Sim
3	0,045	0,1497	0.154	0.0246	Sim
4	0,015	0,193	0.191	0.029	Sim
5	0,0245	0,2528	0.249	0.0478	Sim
6	-0,043	0,257	0.256	0.047	Sim
7	-0,138	0,264	0.295	0.043	Sim
8	0,001	0,161	0.159	0.022	Sim

Fonte: Elaborada pelo autor (2025)

Em relação ao RMSE e ao erro padrão, observa-se que o algoritmo PTIN demonstra um desempenho superior. Ele apresenta os menores valores de RMSE em praticamente todos os perfis, indicando que seus erros de previsão são

consistentemente menores em magnitude. Da mesma forma, o erro padrão do PTIN é sistematicamente mais baixo, o que denota uma maior estabilidade e confiabilidade de suas estimativas. Essa performance se traduz diretamente no atendimento à Classe A: enquanto o PMF e o CSF frequentemente falham em cumprir os requisitos da Classe A, o PTIN consegue atender a esse padrão de qualidade em todos os perfis testados, consolidando-se como o algoritmo mais preciso e robusto para as aplicações avaliadas.

A Análise do desempenho dos algoritmos por tipo de cobertura da terra revela a importância do ambiente na escolha do método mais adequado. Para superfícies homogêneas como o asfalto, o PMF demonstrou ser o mais eficaz, com a menor média e dispersão. Em ambientes florestais, o PTIN destacou-se em floresta secundária pela menor média e dispersão, enquanto o CSF se mostrou mais robusto em áreas com araucárias, também com a menor média e dispersão. Para áreas de pinus e eucalipto, apesar do PTIN apresentar a menor média, o PMF foi considerado mais robusto devido à menor dispersão. Por fim, em áreas de grama e campo nativo, o PMF foi a melhor escolha pela menor dispersão dos erros, e o PTIN também se mostrou uma boa alternativa, com média próxima de zero e menor dispersão em comparação ao CSF, sem a presença de outliers significativos.

Um estudo de Silva *et al.* (2018) comparou quatro algoritmos de filtragem de terreno (WLS, MCH, PMF e PTIN) para remover objetos em ambientes florestais usando dados LiDAR. Embora todos os algoritmos tenham removido adequadamente os objetos, com pequenas diferenças DTMs gerados, o PMF se destacou por subestimar a elevação, especialmente em áreas abertas, devido à remoção excessiva de pontos de solo. As maiores discrepâncias entre os DTMs ocorreram em áreas de maior inclinação. Os pesquisadores concluíram que algoritmos de código aberto como WLS e MCH são viáveis para gerar DTMs precisos, essenciais para o manejo florestal.

No artigo de Becker e Centeno (2013) os autores comparam métodos de filtragem de pontos de solo em ambientes variados, incluindo áreas urbanas e florestadas. Eles testaram diversos algoritmos, como filtros morfológicos, de adensamento progressivo e de bloco mínimo. A principal conclusão é que, em situações mais complexas de terreno, seja por declividade, densidade de vegetação ou complexidade de objetos não-solo, o método PTIN é o mais eficaz para preservar os detalhes do terreno.

Štular e Lozić (2020) conduziram uma pesquisa sobre a filtragem de dados LiDAR para estudos arqueológicos. Ele comparou nove algoritmos de filtragem, incluindo PTIN, CSF e PMF, e concluiu que o PTIN foi significativamente superior aos outros, seguido por PMF e CSF. O estudo destacou a consistência do PTIN em quatro cenários de ambientes florestais, inclusive mantendo sua eficácia mesmo com dados de baixa densidade de pontos.

Em resumo, o desempenho dos métodos de análise é fortemente influenciado pelo tipo de ambiente. Em superfícies homogêneas como o asfalto, alguns métodos exibem menor variabilidade nas diferenças encontradas. Por outro lado, em ambientes mais complexos, como florestas, essa dispersão tende a aumentar.

O algoritmo PTIN se destaca pela sua notável superioridade, apresentando consistentemente um erro sistemático menor em uma variedade de ambientes. Além disso, dependendo das características da superfície, ele oferece uma maior probabilidade de gerar distribuições de diferenças que se ajustam aos critérios de normalidade estatística, o que o torna uma escolha mais robusta e confiável para análises de desempenho.

7 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo geral avaliar a tecnologia LiDAR na geração de modelos digitais para rodovias e suas faixas de domínio. Para alcançar esse objetivo compararam-se os resultados obtidos com o LiDAR/UAV aos dados coletados por métodos de topografia convencional.

Segundo Qin *et al.* (2023) para ser eficaz na filtragem de terreno, um algoritmo de propósito geral deve conseguir capturar detalhes do terreno com precisão, ser robusto em diferentes paisagens sem a necessidade de muitos ajustes e processar grandes volumes de dados de forma eficiente. Além disso, é crucial que ele tenha custos aceitáveis de memória e computação para ser prático em aplicações reais, garantindo que seja preciso, adaptável, escalável e eficiente.

Em suma, a tecnologia LiDAR/UAV demonstrou potencial significativo para levantamentos topográficos em áreas com cobertura vegetal ao longo de rodovias, como alternativa ou complemento às técnicas clássicas de Topografia e Geodésia. A qualidade do DTM gerado depende da escolha do algoritmo de filtragem e é influenciada pelo tipo de cobertura vegetal.

Análises estatísticas aprofundadas revelam que algoritmos como PTIN, PMF, e CSF são capazes de gerar DTMs com boa acurácia e precisão a partir de dados LiDAR. No entanto, a eficácia relativa de cada um é intrinsecamente ligada às características do ambiente mapeado. Isso sublinha a importância crucial de selecionar o método de filtragem de pontos de solo com base no contexto específico e na aplicação desejada, especialmente ao lidar com áreas complexas onde a confiabilidade do DTM é essencial.

MacDonell *et al.* 2023, em seu estudo realizado com LiDAR/UAV, comparando velocidades de voo, altura assim como diferentes algoritmos de classificação pontos de solo, sugere dez recomendações práticas para melhorar os resultados na geração de DTM:

- a) Planejamento de Voo: Envolve a escolha do VANT, aplicativo de navegação, altura, velocidade e direção do voo, além da logística de decolagem e pouso (incluindo a gestão da bateria).
- b) Operação do Sensor: Abrange a seleção do sensor, largura da faixa de varredura e sobreposição lateral (sugerido 50%), número de retornos a

serem registrados, taxa de amostragem e calibração da Unidade de Medição Inercial (IMU).

- c) Dados de Levantamento Independentes: Considera a distribuição e o número de pontos independentes para levantamento (como feições da paisagem) e a escolha do equipamento para avaliação da precisão (ex: RTK-GNSS/estação total/TLS).
- d) Transformação de Coordenadas: Refere-se ao sistema de coordenadas para coleta de dados e o produto final.
- e) Raleamento da Nuvem de Pontos: Aborda os métodos para sobrepor e reduzir a nuvem de pontos geral.
- f) Classificação de Pontos: Envolve a seleção do algoritmo e a definição de uma amostra representativa para avaliação da precisão.
- g) Edição Manual da Nuvem de Pontos: Considera-se opcional, mas recomendada após avaliar a precisão da classificação automática.
- h) Interpolação para Raster: Trata da seleção do algoritmo (ex: Topo2Raster, TIN para Raster).
- i) Avaliações de Precisão: Inclui a seleção de métodos estatísticos em três estágios: (1) avaliação do levantamento de pré-processamento, (2) avaliação da classificação pós-processamento e (3) avaliação da interpolação raster.
- j) Áreas Úmidas: Aborda a identificação e mapeamento da extensão de áreas úmidas, a seleção da técnica de reconstrução (se necessário) e as abordagens disponíveis (estação total robótica, RTK-GNSS, ecosondagem, correção de refração de nuvem de pontos derivada de fotogrametria SfM, análise espectral baseada em Optimal Band Ratio Analysis).

Como sugestões para estudos futuros a consideração de buffers ao entorno dos pontos mensurados em campo para a determinação das diferenças e a comparação com outros sistemas LiDAR.

REFERÊNCIAS

- ARTERIS. Apresentação da concessionária Autopista Litoral Sul. [s. l.], 2024. Disponível em: <https://www.arteris.com.br/contorno-de-florianopolis/programas-ambientais/>. Acessado em: 22 ago. 2024.
- ANDRADE, M. S.; GORGENS, E. B.; REIS, C. R.; CANTINHO, R. Z.; ASSIS, M.; SATO, L.; OMETTO, J. P. H. B. Airborne laser scanning for terrain modeling in the Amazon forest. **Acta Amazonica**, [s. l.], vol. 48, nº 4, p. 271–279, dez. 2018. <https://doi.org/10.1590/1809-4392201800132>.
- AXELSSON, P. DEM Generation from Laser Scanner Data Using Adaptive TIN Models. **International Archives of Photogrammetry and Remote Sensing**, [s. l.], vol. XXXIII, Part B4, p. 110–117, 2000. Disponível em: <https://scispace.com/papers/dem-generation-from-laser-scanner-data-using-adaptive-tin-2pyktozmc2>.
- AZIZI, Z.; NAJAFI, A.; SADEGHIAN, S. Forest Road Detection Using LiDAR Data. **Journal of Forestry Research**, [s. l.], vol. 25, nº 4, p. 975–980, 6 dez. 2014. <https://doi.org/10.1007/s11676-014-0544-0>.
- BALENOVIĆ, I.; LIANG, X.; JURJEVIĆ, L.; HYYPPÄ, J.; SELETKOVIĆ, A.; KUKKO, A. Hand-Held Personal Laser Scanning. **Croatian journal of forest engineering**, [s. l.], vol. 42, nº 1, p. 165–183, 15 jan. 2021. <https://doi.org/10.5552/crojfe.2021.858>.
- BARBOSA, L. da S.; SOUZA, L. M.; CUNHA, M. J. P.; SANTOS, A. de P. Análise Comparativa das Normas de Controle de Qualidade Posicional de Produtos Cartográficos do Brasil, do INCRA e da ASPRS. **Revista Brasileira de Cartografia**, [s. l.], vol. 73, nº 3, p. 771–786, 30 jun. 2021. <https://doi.org/10.14393/rbcv73n3-59581>.
- BECKER, J. H.; CENTENO, J. A. S. Avaliação de métodos de filtragem de nuvem de pontos derivados do sistema laser scanner aerotransportado para obtenção de MDT. **Revista Brasileira de Cartografia**, [s. l.], vol. 65, nº 4, 24 ago. 2013. DOI 10.14393/rbcv65n4-43850. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43850>.
- BELAND, M.; PARKER, G.; HARDING, D.; HOPKINSON, C.; CHASMER, L.; ANTONARAKIS, A. **White Paper – On the Use of LiDAR Data at AmeriFlux Sites**. Berkeley Lab / Fluxnet: [s. n.], 2015.
- BRASIL. **Decreto No. 89.817, de 20 de Junho de 1984: Instruções Reguladoras das Normas Técnicas da Cartografia Nacional**. [S. l.: s. n.], jun. 1984. Disponível em: <https://www2.camara.leg.br/legin/fed/decret/1980-1987/decreto-89817-20-junho-1984-439814-publicacaooriginal-1-pe.html>.

BRASIL. ET-PCDG 2016 (2ª edição): Produtos de Conjuntos de Dados

Geoespaciais. [S. l.]: Exército Brasileiro. Diretoria de Serviço Geográfico (DSG), 2016. Disponível em:

https://geoportal.eb.mil.br/portal/images/Documentos/2024/ET_PCDG_2016_2aEdicao_Aprovada_Publicada_BE_7_16.pdf.

BRASIL. Lei n.º 10.406, de 10 de janeiro de 2002 (Código Civil). [s. l.], 2002.

Disponível em: https://www.planalto.gov.br/ccivil_03/leis/2002/L10406compilada.htm.

BIENERT, A.; GEORGI, L.; KUNZ, M.; MAAS, H.-G.; VON OHEIMB, G. Comparison and Combination of Mobile and Terrestrial Laser Scanning for Natural Forest Inventories. **Forests**, [s. l.], vol. 9, nº 7, p. 395, 4 jul. 2018.

<https://doi.org/10.3390/f9070395>.

CABO, C.; DEL POZO, S.; RODRÍGUEZ-GONZÁLVEZ, P.; ORDÓÑEZ, C.; GONZÁLEZ-AGUILERA, D. Comparing Terrestrial Laser Scanning (TLS) and Wearable Laser Scanning (WLS) for Individual Tree Modeling at Plot Level. **Remote Sensing**, [s. l.], vol. 10, nº 4, p. 540, 1 abr. 2018. <https://doi.org/10.3390/rs10040540>.

CHICATI, M. L.; SILVA NETO, O. T. da; NANNI, M. R.; OLIVEIRA, R. B. de; CÉZAR, E.; CHICATI, M. S. Uso de drones no georreferenciamento de imóveis rurais para levantamento de vértices de difícil acesso. 2019. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto** [...]. Santos: INPE, 2019.

CORRÊA, C. M. C.; MALINOVSKI, J. R. BASES PARA PLANEJAMENTO DE REDE VIÁRIA EM REFLORESTAMENTO NO SUL DO BRASIL. **FLORESTA**, [s. l.], vol. 36, nº 2, 18 out. 2006. <https://doi.org/10.5380/ufv.v36i2.6450>.

COOK, B.; CORP, L.; NELSON, R.; MIDDLETON, E.; MORTON, D.; MCCORKEL, J.; MASEK, J.; RANSON, K.; LY, V.; MONTESANO, P. NASA Goddard's LiDAR, Hyperspectral and Thermal (G-LiHT) Airborne Imager. **Remote Sensing**, [s. l.], vol. 5, nº 8, p. 4045–4066, 13 ago. 2013. DOI 10.3390/rs5084045. Disponível em: <https://www.mdpi.com/2072-4292/5/8/4045>.

DAER. Faixa de Domínio. 2025. Disponível em: <https://www.daer.rs.gov.br/faixa-de-dominio>. Acessado em: 17 jan. 2025.

DALLA CORTE, A. P.; BROADBENT, E. N.; SANTOS, L. H. de O.; KARASINSKI, M. A.; SANQUETTA, C. R.; PRATA, G. A.; ALMEIDA, D. R. A. de; SILVA, C. A. **Aplicações do LiDAR para o inventário florestal – enfoque unidade de área.** Ponta Grossa: Atena Editora, 2022. <https://doi.org/10.22533/at.ed.223222904>.

DJI. DJI Terra User Manual v4.3 (English). [s. l.], out. 2024. Disponível em: https://dl.djicdn.com/downloads/dji-terra/20241024/DJI_Terra_User_Manual_v4.3_EN.pdf.

DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. Boca Raton: Taylor & Francis, 2018.

DUNCANSON, L.; NEUENSCHWANDER, A.; HANCOCK, S.; THOMAS, N.; FATOYINBO, T.; SIMARD, M.; SILVA, C. A.; ARMSTON, J.; LUTHCKE, S. B.; HOFTON, M.; KELLNER, J. R.; DUBAYAH, R. Biomass estimation from simulated GEDI, ICESat-2 and NISAR across environmental gradients in Sonoma County, California. **Remote Sensing of Environment**, [s. l.], vol. 242, p. 111779, jun. 2020. <https://doi.org/10.1016/j.rse.2020.111779>.

FITZ, P. R. **Geoprocessamento sem complicação**. 3º ed. São Paulo: Oficina de Textos, 2008.

GIONGO, M.; KOEHLER, H. S.; MACHADO, S. do A.; KIRCHNER, F. F.; MARCHETTI, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, [s. l.], vol. 30, nº 63, p. 231–244, 28 out. 2010. DOI 10.4336/2010.pfb.30.63.231. Disponível em: <https://pfb.sede.embrapa.br/pfb/article/view/148>.

GOMES, A. de A. da R.; SILVA, B. N. da; BARROS, B. A.; GIRI, F. B.; NUNES, J. C. B.; OLIVEIRA, M. P. de; ISAHIAS, M. de S.; RODRIGUES, D. de S. O uso de drones para mapeamento topográfico. **Revista de Gestão e Secretariado**, [s. l.], vol. 15, no 5, p. e3799, 17 maio 2024. <https://doi.org/10.7769/gesec.v15i5.3799>.

LAPORTE-FAURET, Q.; MARIEU, V.; CASTELLE, B.; MICHALET, R.; BUJAN, S.; ROSEBERY, D. Low-cost UAV for high-resolution and large-scale coastal dune change monitoring using photogrammetry. **Journal of Marine Science and Engineering**, [s. l.], vol. 7, nº 3, p. 63, 2019. <https://doi.org/10.3390/jmse7030063>.

LIN, D.; GIANNICO, V.; LAFORTEZZA, R.; SANESI, G.; ELIA, M. Use of airborne LiDAR to predict fine dead fuel load in Mediterranean forest stands of Southern Europe. **Fire Ecology**, [s. l.], vol. 20, nº 1, p. 58, 4 jul. 2024. <https://doi.org/10.1186/s42408-024-00287-7>.

MACDONELL, C. J.; WILLIAMS, R. D.; MANIATIS, G.; ROBERTS, K.; NAYLOR, M. Consumer-grade UAV solid-state LiDAR accurately quantifies topography in a vegetated fluvial environment. **Earth Surface Processes and Landforms**, [s. l.], vol. 48, nº 11, p. 2211–2229, 15 set. 2023. <https://doi.org/10.1002/esp.5608>.

MATINNIA, B.; PARSAKHOO, A.; MOHAMADI, J.; JOUIBARY, S. S. Study of the LiDAR accuracy in mapping forest road alignments and estimating the earthwork volume. **Journal of Forest Science**, [s. l.], vol. 64, nº 11, p. 469–477, 30 nov. 2018. <https://doi.org/10.17221/87/2018-JFS>.

MEANS, J. E. Design, Capabilities and Uses of Large-Footprint and Small-Footprint LiDAR Systems. XXXII-3/W14., nov. 1999. **Proceedings of ISPRS Commission III & WG III/5 and II MAPPING SURFACE STRUCTURE AND TOPOGRAPHY BY AIRBORNE AND SPACEBORNE LASERS** [...]. La Jolla, California, USA: [s. n.], nov. 1999. vol. XXXII-3/W14, p. 201–207. Disponível em: <https://www.isprs.org/proceedings/XXXII/3-W14/pdf/p201.pdf>.

MEDEIROS, R. C. **Rodprow: projeto geométrico de estradas assistido por computador**. 1997. Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 1997.

MENG, X.; CURRIT, N.; ZHAO, K. Ground Filtering Algorithms for Airborne LiDAR Data: A Review of Critical Issues. *Remote Sensing*, [s. l.], vol. 2, no. 3, p. 833–860, 22 Mar. 2010. <https://doi.org/10.3390/rs2030833>.

MENZONI, M. **Georreferenciamento: conceitos**. 1º ed. São Paulo: Baraúna, 2017.

MIKHAIL, E. M.; ACKERMANN, F. E. **Observations and Least Squares**. Washington, D.C.: University Press of America, 1982. Disponível em: <https://archive.org/details/observationsleas0000mikh>.

MONICO, J. F. G.; DAL PÓZ, A. P.; GALO, M.; SANTOS, M. C. Dos; OLIVEIRA, L. de C. Acurácia e precisão: revendo os conceitos de forma acurada. **Boletim de Ciências Geodésicas**, Curitiba, vol. 15, p. 441–469, 2009. <https://doi.org/10.5380/bcg.v15i3.15513>.

NISHIWAKI, A. M.; MOURA, S. B. de; GALVÍNCIO, D. J.; OLIVEIRA, C. P. de; SILVA, E. A.; LIMA, J. R. de S.; ANTONINO, A. C. D.; SOUZA, E. S. de; MENEZES, R. S. C.; MONTENEGRO, S. M. G. L.; DOMINGUES, T. F. *Revista Brasileira de Geografia Física*. **Revista Brasileira de Geografia Física**, [s. l.], vol. 16, 2023. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe>.

OMAR, H.; O, N.; AD, N.; FAIDI, A.; KASSIM, A. R. AIRBORNE LIDAR FOR ESTIMATING ABOVEGROUND BIOMASS IN DIPTEROCARP FORESTS OF MALAYSIA. jul. 2015. [S. l.: s. n.], jul. 2015.

OMETTO, J. P.; GORGENS, E. B.; DE SOUZA PEREIRA, F. R.; SATO, L.; DE ASSIS, M. L. R.; CANTINHO, R.; LONGO, M.; JACON, A. D.; KELLER, M. A biomass map of the Brazilian Amazon from multisource remote sensing. **Scientific Data**, [s. l.], vol. 10, nº 1, p. 668, 30 set. 2023. <https://doi.org/10.1038/s41597-023-02575-4>.

PACHECO, A. da P.; CENTENO, J. A. S.; ASSUNÇÃO, M. G. T. de; BOTELHO, M. F. Classificação de pontos LIDAR para a geração do MDT. **Boletim de Ciências Geodésicas**, [s. l.], vol. 17, nº 3, p. 471–438, set. 2011. <https://doi.org/10.1590/S1982-21702011000300006>.

PAPA, D. de A.; ALMEIDA, D. R. A. de; SILVA, C. A.; FIGUEIREDO, E. O.; STARK, S. C.; VALBUENA, R.; RODRIGUEZ, L. C. E.; D'OLIVEIRA, M. V. N. Evaluating tropical forest classification and field sampling stratification from lidar to reduce effort and enable landscape monitoring. **Forest Ecology and Management**, [s. l.], vol. 457, p. 117634, fev. 2020. <https://doi.org/10.1016/j.foreco.2019.117634>.

QIN, N.; TAN, W.; GUAN, H.; WANG, L.; MA, L.; TAO, P.; FATHOLAH, S.; HU, X.; LI, J. Towards intelligent ground filtering of large-scale topographic point clouds: A comprehensive survey. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], vol. 125, p. 103566, dez. 2023. <https://doi.org/10.1016/j.jag.2023.103566>.

SANTOS, A. de P. dos; RODRIGUES, D. D.; SANTOS, N. T.; JUNIOR, J. G. Avaliação da acurácia posicional em dados espaciais utilizando técnicas de estatística espacial: proposta de método e exemplo utilizando a norma brasileira. **Boletim de Ciências Geodésicas**, [s. l.], vol. 22, nº 4, p. 630–650, dez. 2016. <https://doi.org/10.1590/s1982-21702016000400036>.

SCHÄFER, A. G.; LOCH, R. E. N. **Aplicação de produtos fotogramétricos e do sensor Laser Scanner em projetos rodoviários – Estudo de caso: trecho da SC-414**. 2004. Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, 2004. Disponível em: <http://repositorio.ufsc.br/xmlui/handle/123456789/87559>.

SILVA, C. A.; DUNCANSON, L.; HANCOCK, S.; NEUENSCHWANDER, A.; THOMAS, N.; HOFTON, M.; FATOYINBO, L.; SIMARD, M.; MARSHAK, C. Z.; ARMSTON, J.; LUTCHKE, S.; DUBAYAH, R. Fusing simulated GEDI, ICESat-2 and NISAR data for regional aboveground biomass mapping. **Remote Sensing of Environment**, [s. l.], vol. 253, p. 112234, fev. 2021. <https://doi.org/10.1016/j.rse.2020.112234>.

SILVA, C. A.; KLAUBERG, C.; HENTZ, Â. M. K.; CORTE, A. P. D.; RIBEIRO, U.; LIESENBERG, V. Comparing the Performance of Ground Filtering Algorithms for Terrain Modeling in a Forest Environment Using Airborne LiDAR Data. **Floresta e Ambiente**, [s. l.], vol. 25, nº 2, 1 fev. 2018. <https://doi.org/10.1590/2179-8087.015016>.

SOILÁN, M.; SÁNCHEZ-RODRÍGUEZ, A.; DEL RÍO-BARRAL, P.; PEREZ-COLLAZO, C.; ARIAS, P.; RIVEIRO, B. Review of Laser Scanning Technologies and Their Applications for Road and Railway Infrastructure Monitoring. **Infrastructures**, [s. l.], vol. 4, nº 4, p. 58, 20 set. 2019. <https://doi.org/10.3390/infrastructures4040058>.

ŠTULAR, B.; LOZIĆ, E. Comparison of filters for archaeology-specific ground extraction from airborne LiDAR point clouds. **Remote Sensing**, [s. l.], vol. 12, nº 15, 2020. <https://doi.org/10.3390/rs12152452>.

YANG, X.; WANG, C.; XI, X.; WANG, Y.; ZHANG, Y.; ZHOU, G. Footprint Size Design of Large-Footprint Full-Waveform LiDAR for Forest and Topography Applications: A Theoretical Study. **IEEE Transactions on Geoscience and Remote Sensing**, [s. l.], vol. 59, n° 11, p. 9745–9757, nov. 2021. <https://doi.org/10.1109/TGRS.2021.3054324>.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Varredura a laser aerotransportado para estimativa de variáveis dendrométricas. **Scientia Forestalis**, [s. l.], vol. 36, n° 79, p. 273–281, 2008. .

ZHANG, K.; CHEN, S.-C.; WHITMAN, D.; SHYU, M.-L.; YAN, J.; ZHANG, C. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. **IEEE Transactions on Geoscience and Remote Sensing**, [s. l.], vol. 41, n° 4, p. 872–882, abr. 2003. <https://doi.org/10.1109/TGRS.2003.810682>.

ZHANG, W.; QI, J.; WAN, P.; WANG, H.; XIE, D.; WANG, X.; YAN, G. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. **Remote Sensing**, [s. l.], vol. 8, n° 6, p. 501, 15 jun. 2016. <https://doi.org/10.3390/rs8060501>.