



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Câmpus de Presidente Prudente

CLEBER JUNIOR ALENCAR

**USO DE DESCRITORES 3D E INTENSIDADE PARA A DETECÇÃO DE
ÁRVORES EM DADOS LIDAR AEROTRANSPORTADO**

Presidente Prudente
2023



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Câmpus de Presidente Prudente

CLEBER JUNIOR ALENCAR

USO DE DESCRITORES 3D E INTENSIDADE PARA A DETECÇÃO DE ÁRVORES EM DADOS LIDAR AEROTRANSPORTADO

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) da FCT - Faculdade de Ciências e Tecnologia da UNESP - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Campus de Presidente Prudente/SP, como parte dos requisitos para a obtenção do título de Mestre em Ciências Cartográficas. Área de concentração: Aquisição, análise e representação de informações espaciais.

Orientador: Prof. Dr. Mauricio Galo
Coorientador: Dr. Renato César dos Santos

Presidente Prudente
2023



A368u

Alencar, Cleber Junior

Uso de descritores 3D e intensidade para a detecção de árvores em dados
LiDAR Aerotransportado / Cleber Junior Alencar. -- Presidente Prudente,
2023
78 p.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências e Tecnologia, Presidente Prudente

Orientador: Mauricio Galo

Coorientador: Renato César dos Santos

1. LiDAR Aerotransportado. 2. Detecção de árvores. 3. Descritores
geométricos 3D. 4. Classificação de nuvem de pontos. 5. K-médias. I. Título.

IMPACTO¹ ESPERADO DESTA PESQUISA

Nesta dissertação foi proposto um método de detecção de árvores em áreas urbanas, a partir de dados obtidos por Sistemas de Varredura a Laser Aerotransportados. A detecção de árvores é relevante uma vez que provê dados para algoritmos de detecção de edificações parcialmente ocultas por vegetação, contribui para a manutenção preventiva da rede elétrica e são dados essenciais para a gestão pública das cidades.

POTENCIAL IMPACT OF THIS RESEARCH

In this master's thesis, it is proposed an automatic tree detection approach in urban environments using airborne LiDAR data. Tree detection is relevant because it provides data for algorithms used to identify buildings partially occluded by canopy, contributes to the preventive maintenance of the electrical networks, and offers relevant information for public urban management.

¹ Informação inserida de acordo com a Portaria Unesp no 117, de 21 de dezembro de 2022.



CERTIFICADO DE APROVAÇÃO


TÍTULO DA DISSERTAÇÃO: Uso de Descritores 3D e Intensidade para a Detecção de Árvores em Dados LiDAR Aerotransportado


AUTOR: CLEBER JUNIOR ALENCAR

ORIENTADOR: MAURICIO GALO

COORIENTADOR: RENATO CÉSAR DOS SANTOS

Aprovado como parte das exigências para obtenção do Título de Mestre em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:


Prof. Dr. MAURICIO GALO (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente


Prof. Dr. ALUIR PORFÍRIO DAL POZ (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Prof. Dr. VERALDO LIESENBERG (Participação Virtual)
Centro de Ciências Agroveterinárias / Universidade do Estado de Santa Catarina

Presidente Prudente, 14 de agosto de 2023

AGRADECIMENTOS

Agradeço aos meus professores por me ajudarem na minha trajetória de formação acadêmica. Em particular, manifesto meu profundo reconhecimento ao Professor Mauricio Galo, meu orientador, e ao Dr. Renato César dos Santos, meu coorientador, cuja dedicação e estímulo desempenharam papel crucial na concretização deste trabalho.

Agradeço à minha família, amigos e colegas do PPGCC que me apoiaram e me ajudaram a passar por todas as adversidades e alegrias durante o processo.

Agradeço à instituição Unesp, pelo apoio no desenvolvimento da pesquisa. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo fomento à esta pesquisa.

Um agradecimento também aos professores da banca, Prof. Dr. Aluir Dal Poz e Prof. Dr. Veraldo Liesenberg, que contribuíram com dicas valiosas para o aperfeiçoamento do trabalho.

Agradeço à Sensormap e Engemap pela disponibilização dos dados utilizados na pesquisa.

Muito obrigado!

RESUMO

A detecção de vegetação por meio remoto possui aplicações em diferentes áreas do conhecimento, sendo importante para o manejo e preservação florestal, detecção de objetos ocluídos pelas copas das árvores, planejamento urbano, dentre outras. Diferentes metodologias podem ser encontradas na literatura para esta finalidade, desde os que utilizam de técnicas de processamento de imagens aplicada às imagens derivadas da nuvem de pontos LiDAR até os que trabalham diretamente com os dados brutos, explorando as informações tridimensionais dos pontos e/ou a intensidade. Há também alguns trabalhos que fazem uso de descritores 3D baseados em autovalores aplicados especificamente para detectar árvores. Nesse sentido, este trabalho tem o propósito de avaliar a aplicabilidade dos descritores geométricos 3D baseados em autovalores e da intensidade na detecção de pontos amostrados sobre árvores a partir de dados LiDAR obtidos por sistemas aerotransportados. No cálculo dos atributos geométricos, dois tipos de vizinhança (esfera e cilindro vertical) foram definidos visando avaliar sua influência nos resultados. Dos diversos descritores geométricos, foram feitos experimentos com os descritores omnivariância, curvatura, planaridade e entropia dos autovalores, além da intensidade, para realizar a classificação das nuvens de pontos nas classes vegetação e não vegetação, com o algoritmo K-médias. Os resultados obtidos indicam a potencialidade do uso dos atributos intensidade e omnivariância na detecção automática de árvores, seguida da aplicação de operadores da morfologia matemática para o refinamento da classificação. Os parâmetros de qualidade, obtidos a partir da comparação com dados de referência, indicam que é possível detectar árvores com completeza de 96,08%, nível de acerto de 85,92 e *F-score* de 90,46%.

Palavras-chave: LiDAR aerotransportado; Detecção de árvores; Descritores 3D. K-médias; Intensidade.

ABSTRACT

The result derived from tree detection using airborne LiDAR data can be used in different applications such as forest management and preservation, detection of objects occluded by tree crowns, urban planning, among others. Several approaches are found in the literature to deal with tree detection task that goes from those using images derived from LiDAR data to those using directly the raw data and explore its three dimensional and intensity information. Precisely, the applicability of 3D descriptors based on eigenvalues for tree detection can be assessed more thoroughly. In this sense, this work aims to evaluate the use of 3D geometric descriptors based on eigenvalues and LiDAR intensity for tree detection in an urban area. In preliminary experiments, it was analyzed the impact of neighborhood (sphere and cylinder) on the geometric attribute estimation. From visual analyses, it was possible to notice that the use of some geometric attributes such as omnivariance, curvature, planarity and eigenentropy have more potential in detecting trees. Considering the four selected attributes (omnivariance, curvature, planarity and eigenentropy) and intensity, the K-Means algorithm was executed aiming to separate the point cloud into tree and non-tree classes. Obtained results indicated that the use of attributes such omnivariance and intensity, followed by one refinement step based on mathematical morphology operators have potential to fulfill the purpose of automatic tree detection in urban environments. Based on the experiments with real data, it was possible to verify that the trees were detected with completeness, correctness and *F-score* of 96.08%, 85.92% and 90,46%, respectively, indicating the potential of the proposed approach.

Keywords: Airborne LiDAR; Tree detection; 3D descriptors; K-means; Intensity.

LISTA DE FIGURAS

Figura 2.1 - Múltiplos retornos do pulso LASER.....	17
Figura 2.2 – Integração de sistemas de um SVLA.	18
Figura 2.3 - Etapas para a classificação de uma nuvem de pontos LiDAR.....	23
Figura 2.4 - Detecção de troncos por meio da definição de limiar de intensidade. Pontos em vermelho: intensidade ≥ 35 ; pontos em verde: intensidade ≤ 35 ..	25
Figura 2.5 - Em (a) se tem a representação matricial do objeto mostrado em (b). Em (c) e (d) tem-se, respectivamente, a reflexão e translação do objeto (b).	27
Figura 2.6 - Exemplos de elementos estruturantes para aplicação em operações morfológicas: quadrado, retângulo, diamante, disco, octógono e estrela.	27
Figura 2.7 - Abertura e fechamento em uma imagem binária com EE circular de raio (r) variando de 1,0 (primeira linha), 2,5 (linha do meio) e 5,0 (terceira linha).	29
Figura 3.1 - Recorte da nuvem de pontos de Presidente Prudente/Brasil colorida pela altura. Em (a) é destacada uma região cujo perfil é mostrado em (b).	34
Figura 3.2 - Imagens aéreas das áreas de estudo A1, A2 e A3 e de suas respectivas nuvens de pontos representadas em tons de cinza com base na intensidade.	35
Figura 3.3 – Dados de referência da classificação das áreas de estudo selecionadas. Os pontos em verde representam pontos de árvores isoladas ou conglomerados.	35
Figura 3.4 - Fluxograma do método proposto.	37
Figura 3.5 - Exemplo da aplicação da abertura morfológica em uma imagem binária contendo pontos de árvores (pixels brancos) e pontos de “não-árvore” (pixels pretos). Imagem antes (a) e após o refinamento por MM (b).	41
Figura 4.1 - Visualização da nuvem de pontos da área de estudo com base na intensidade. Em (a) é mostrada apenas a informação de intensidade e em (b) a mesma informação, mas mostrada numa escala de cores diferente.	45
Figura 4.2 - Resultados da aplicação do K-Médias usando a intensidade (a) em comparação com o dado de referência (b) (vista superior da nuvem 3D).	46
Figura 4.3 - Mapa dos atributos considerando diferentes descritores geométricos e vizinhanças.	48
Figura 4.4 – Comparação visual entre os resultados dos descritores omnivariância (A), curvatura (B), entropia dos autovalores (C) e planaridade (D).	49
Figura 4.5 - Histograma dos valores de omnivariância e curvatura para uma vizinhança esférica, e entropia dos autovalores e planaridade para uma vizinhança cilíndrica.	49
Figura 4.6 - Resultados da aplicação do K-Médias usando a omnivariância (a), curvatura (b), entropia dos autovalores (c) e planaridade (d) (vista superior da nuvem 3D).	50
Figura 4.7 - Gráficos dos parâmetros de qualidade da classificação considerando tamanhos de raio diferentes da vizinhança. Em (a) são apresentados os resultados de D3; em (b) de D6; e em (c) de D12.	55

Figura 4.8 – Região destacada na A1 (a) para ilustrar o resultado antes (b) e depois (c) da aplicação da MM na imagem binária.	58
Figura 4.9 – Imagem da região correspondente à área A1 (a). Em (b) são mostrados os dados referência (b), em (c) os resultados da detecção considerando intensidade e omnivariância e em (d) o resultado do agrupamento. Em (e) contém a imagem da nuvem original com intensidade em tons de cinza e (f) é mostrada a superposição das árvores detectadas.	60
Figura 4.10 - Exemplos de falsos positivos na área A1 obtidos com o método de detecção proposto.	61
Figura 4.11 - Mapa de erro da detecção de árvores para a área A1 considerando a análise por objeto. Os pontos em verde representam os TP; em azul estão os FP; em vermelho os FN.	62
Figura 4.12 – Resultados da detecção de árvores para a área A2. Em (a) tem-se a imagem aérea da região; (b) contém a nuvem de pontos de referência; (c) e (d) contém a nuvem classificada e refinada, respectivamente; (e) contém a imagem da nuvem original com intensidade em tons de cinza e (f) contém a superposição das árvores detectadas na nuvem original.	64
Figura 4.13 – Mapa de erro da detecção de árvores para a área A2. Os pontos em verde representam os TP; em azul os FP; em vermelho os FN.	65
Figura 4.14 – Resultados da detecção de árvores para a área A3. Em (a) tem-se a imagem aérea da região; (b) contém a nuvem de pontos de referência; (c) e (d) contém a nuvem classificada e refinada, respectivamente; (e) contém a imagem da nuvem original com intensidade em tons de cinza e (f) contém a superposição das árvores detectadas na nuvem original.	66
Figura 4.15 - Mapa de erro da detecção de árvores para a área A3. Os pontos em verde representam os TP; em azul os FP; em vermelho os FN.	67

LISTA DE TABELAS

Tabela 2.1 - Porcentagem de reflectividade de alguns objetos para um comprimento de onda de 900 nm.	19
Tabela 4.1 - Parâmetros de qualidade da classificação utilizando a intensidade.	46
Tabela 4.2 - Parâmetros de qualidade da classificação utilizando atributos diferentes.	51
Tabela 4.3 - Parâmetros de qualidade das classificações usando a omnivariância calculada em vizinhança esférica com raios variados para os dados com densidade da ordem de 3 pontos/m ²	53
Tabela 4.4 - Parâmetros de qualidade das classificações usando a omnivariância calculada em vizinhança esférica com raios variados para os dados com densidade da ordem de 6 pontos/m ²	53
Tabela 4.5 - Parâmetros de qualidade das classificações usando a omnivariância calculada em vizinhança esférica com raios variados para os dados com densidade da ordem de 12 pontos/m ²	53
Tabela 4.6 - Parâmetros de qualidade da classificação após aplicação do filtro de abertura morfológica considerando um disco de tamanho variado como EE. ..	57
Tabela 4.7 - Parâmetros de qualidade da classificação após aplicação do filtro de abertura morfológica considerando um quadrado de tamanho variado como EE.	57
Tabela 4.8 - Parâmetros de qualidade da classificação da A1.	62
Tabela 4.9 – Parâmetros de qualidade da classificação da A2.	63
Tabela 4.10 - Parâmetros de qualidade da classificação da A3.	67
Tabela 4.11 - Média dos parâmetros de qualidade obtidos para as três áreas de estudo mediante análise ponto a ponto.	68
Tabela 4.12 - Média dos parâmetros de qualidade obtidos para as três áreas de estudo mediante análise por objeto.	68
Tabela 4.13 - Média dos parâmetros de qualidade obtidos para as três áreas de estudo.	68
Tabela 4.14 - Comparação dos resultados do método proposto com trabalhos da literatura.	69

LISTA DE QUADROS

Quadro 3.1 - Alguns parâmetros de aquisição e características dos dados LiDAR que usados no estudo.	33
Quadro 3.2 - Características das áreas de estudo selecionadas.	34
Quadro 3.3 - Síntese das variáveis envolvidas no método proposto.....	43

SUMÁRIO

1	INTRODUÇÃO.....	9
1.1	Estado da Arte	11
1.2	Objetivos	14
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Sistemas de Varredura a LASER Aerotransportado	16
2.1.1	Informação de intensidade	18
2.2	Processamento de dados LiDAR	20
2.3	Detecção e extração de árvores	21
2.3.1	Uso de descritores geométricos para classificar nuvem de pontos	21
2.3.1.1	Tipos de vizinhança	24
2.3.2	Uso da intensidade na detecção de árvores.....	24
2.3.3	Métodos de classificação de nuvem de pontos	25
2.4	Filtros morfológicos	26
2.5	Crescimento de Regiões	29
2.6	Parâmetros de qualidade	31
3	MATERIAL E MÉTODO.....	33
3.1	Material	33
3.2	Áreas de estudo	33
3.3	Método	36
3.3.1	Detecção de <i>outliers</i>	37
3.3.2	Uso da intensidade e descritor geométrico 3D para detecção de árvores por meio do algoritmo K-médias.	38
3.3.3	Refinamento da detecção de árvores baseado no conceito de morfologia matemática	40
3.3.4	Agrupamento dos indivíduos e conglomerados arbóreos.....	42
3.3.5	Análise da qualidade	42
3.3.6	Parâmetros envolvidos no método proposto	43
4	RESULTADOS E DISCUSSÕES.....	44
4.1	Experimento I: Detecção de árvores usando a intensidade	44
4.2	Experimento II: Seleção dos atributos geométricos por meio de análise visual	46

4.3	Experimento III: Impacto do tipo de vizinhança e atributos geométricos na detecção de árvores.....	50
4.4	Experimento IV: Impacto do tamanho da vizinhança e da densidade de amostragem na detecção de árvores.....	52
4.5	Experimento V: Impacto do tipo e tamanho do elemento estruturante.....	56
4.6	Experimento VI: Aplicação do método proposto em diferentes áreas do conjunto de dados.....	59
4.6.1	Resultados para a área de estudo 1.....	59
4.6.2	Resultados para a área de estudo 2.....	63
4.6.3	Resultados para a área de estudo 3.....	65
4.7	Síntese dos resultados.....	68
5	CONCLUSÕES E RECOMENDAÇÕES	70
	REFERÊNCIAS.....	72

1 INTRODUÇÃO

A evolução da ciência e tecnologia permitiu o desenvolvimento de novas técnicas para a aquisição de dados e mapeamento da superfície terrestre. É possível dispor-se de dados de diferentes naturezas tais como imagens aéreas, imagens orbitais no espectro óptico, imagens de RADAR (*Radio Detection and Ranging*), nuvem de pontos tridimensionais, que podem ser obtidas tanto por sistemas LiDAR (*Light Detection and Ranging*), embarcados em diferentes plataformas, quanto por correspondência de imagens, dentre outros. Devido a agilidade e capacidade de adquirir uma grande quantidade de informação, os sistemas que utilizam o princípio LiDAR têm se destacado na área de Sensoriamento Remoto. Estes sistemas baseiam-se na emissão e recepção de feixes de raio LASER (*Light Amplification by Stimulated Emission of Radiation*), os quais podem ser embarcados em plataformas terrestres, aéreas ou orbitais. No caso de plataformas aéreas como aviões, helicópteros e VANTs (Veículos Aéreos Não Tripulados), é comum encontrar a denominação SVLA (Sistema de Varredura a LASER Aerotransportado) (DONG; CHEN, 2018).

Um sistema LiDAR consiste na integração de três sistemas que operam de modo integrado, são eles: sistema de varredura a LASER, sistema de posicionamento GNSS (*Global Navigation Satellite System*) e sistema de orientação, constituído por uma IMU (*Inertial Measurement Unit*) (EL-SHEIMY *et al.*, 2005). Essa integração de sistemas permite que, após o processamento dos dados brutos, se obtenha um conjunto de pontos tridimensionais com coordenadas conhecidas, também chamado de nuvem de pontos, nuvem de pontos 3D ou nuvem de pontos LiDAR.

Dentre as aplicações deste tipo de dado, pode-se destacar a geração de Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT) (FERNANDES *et al.*, 2017; HUI *et al.*, 2019), os quais são importantes em diferentes áreas da engenharia. Além disso, a tecnologia LiDAR pode ser aplicada no planejamento urbano por meio da detecção e extração de edificações (DOS SANTOS *et al.*, 2019; SHAO *et al.*, 2021); detecção de linhas de transmissão (GUO *et al.*, 2019), e detecção de estradas (RATO; SANTOS, 2021). No caso de aplicações cujo foco principal é a vegetação, o uso de dados LiDAR permite determinar as variáveis

dendrométricas² (RIBAS e BELMIRO, 2013; MARTINS-NETO, 2016; HANSSEN et al., 2021), tais como: altura da árvore, diâmetro da copa, número de indivíduos arbóreos, altura e diâmetro dos troncos. Por meio da modelagem destas informações, outras variáveis podem ser estimadas, tais como o DAP (Diâmetro na Altura do Peito), volume e biomassa. Essas métricas são de suma importância para as ciências relacionadas ao manejo de florestas e plantações (DONG et al., 2020; DA COSTA et al., 2021; ESTORNELL et al., 2021; LIU et al., 2021; YUN et al., 2021).

No que concerne às aplicações florestais que usam nuvem de pontos LiDAR, dependendo da quantidade e concentração das folhas do dossel, o pulso emitido pela unidade LASER consegue penetrar, atingindo alguns galhos e troncos, podendo chegar até o solo, o que depende de alguns fatores. Dentre eles pode-se mencionar: a densidade do dossel, o número de retornos registrados pela unidade LASER, ângulo de divergência, época do ano (outono, inverno, primavera, verão), dentre outros elementos. Segundo Tittmann et al. (2011), o potencial de medição direta em vegetação, através de dados coletados por Sistema de Varredura a Laser Aerotransportado – SVLA, tem crescido nos últimos anos. No entanto, a delimitação automática da vegetação é ainda desafiadora para os algoritmos devido à alta complexidade dos ambientes urbanos e florestais. Como consequência, novos métodos têm sido desenvolvidos e avaliados com este propósito, como apresentado por (ITAKURA; MIYATANI; HOSOI, 2022; MARINELLI; PARIS; BRUZZONE, 2022), por exemplo.

O processo de detecção consiste na separação dos pontos localizados sobre as árvores dos demais pontos localizados em outros objetos, enquanto o processo de extração de indivíduos consiste na segmentação dos pontos de árvores em *clusters*, obtendo cada árvore de modo individualizado. Adicionalmente, um processo de delimitação pode ser executado para obter o contorno das copas das árvores, ou do conglomerado de árvores. No cenário urbano típico das cidades brasileiras, essas tarefas se tornam ainda mais desafiadoras, uma vez que as características estruturais das árvores não são padronizadas devido à grande variedade de árvores. Somado a isso, a vegetação frequentemente divide espaço com outras feições do ambiente

² Dendrometria é uma palavra derivada dos vocábulos gregos *dendron* (árvore) e *metria* (medição) que representa um ramo da ciência florestal que trata da medição da árvore, tanto do ponto de vista individual quanto coletivo.

urbano como linhas de transmissão de energia, telhados, placas de sinalização, dentre outros.

A detecção e extração automática de árvores a partir de dados LiDAR é um tópico importante e tem reflexos em diferentes aplicações práticas. Dentre elas, tem-se a obtenção de dados dendrométricos da vegetação urbana, a fim de quantificar os recursos florestais de uma área e apoiar ações de manejo florestal por parte do poder público. A delimitação da copa das árvores é também essencial para aprimorar algoritmos de extração de contorno de edificações (DOS SANTOS; HABIB; GALO, 2022) e de linhas de transmissão, uma vez que a vegetação pode causar confusão no processo de segmentação e classificação desses objetos (OLIVEIRA e GALO, 2017). Além disso, fazer a detecção de árvores, principalmente as de grande porte, na proximidade, sob e/ou sobre linhas de transmissão aéreas tem suas vantagens, uma vez que estas regiões se caracterizam como áreas de riscos em casos de tempestades (OLIVEIRA, 2022), por exemplo.

A importância do tema também é evidenciada na comunidade científica internacional, como pode-se ver a partir da missão e dos termos de referência do Grupo de Trabalho WG II/3 (*3D Scene Reconstruction for Modeling & Mapping*) da Sociedade Internacional de Fotogrametria e Sensoriamento Remoto (ISPRS). Dentre os propósitos deste grupo de trabalho destaca-se o desenvolvimento de técnicas para o reconhecimento e reconstrução 3D de objetos em cenas complexas provenientes de imagens, nuvem de pontos e dados de outros tipos de sensores, além de trabalhar com a classificação e segmentação semântica de nuvens de pontos com ou sem informações radiométricas [<https://www2.isprs.org/commissions/comm2/wg3>].

1.1 Estado da Arte

Tradicionalmente, os trabalhos de detecção e delimitação de árvores partem de imagens bem como de Modelos de Altura da Copa (CHM – *Canopy Height Model*) geradas a partir dos pontos 3D (BARBOSA, 2017; DONG et al., 2020; HANSSEN et al., 2021; PU et al., 2023). No entanto, outras abordagens podem ser adotadas para trabalhar diretamente com os dados tridimensionais obtidos por SVLA. Nestes casos, é notada uma melhora na taxa de detecção em regiões onde há árvores com copas complexas e distribuição não regular.

Dentre os trabalhos que utilizam dados obtidos por SVLA alguns exploram a informação de intensidade do pulso de retorno para caracterizar os objetos da cena, como pode ser visto em Yunfei et al. (2008), Liu et al. (2009), Lu et al. (2014), Budei et al. (2022) e Gong et al. (2022). De acordo com Kashani et al. (2015) e Li et al. (2023), a intensidade está diretamente relacionada com a reflectância da superfície e com outras propriedades físicas dos objetos e, por isso, a aplicabilidade do dado LiDAR aumenta quando se tem disponível essas informações, as quais podem ser usadas individualmente ou como um suplemento para o reconhecimento de objetos.

Demantké et al. (2011) apresentaram um método multi-escala que determina localmente as características estruturais em torno de um ponto, por meio de atributos geométricos calculados com autovalores para selecionar a dimensão ótima da vizinhança local. Com base na combinação dos autovalores, os objetos presentes na cena são associados a quatro grandes classes que descrevem a sua forma geométrica: 1D (linhas de transmissão, postes, troncos, etc.); 2D (parede, porta, fachada, etc.); 3D (folhagem, gramado, árvores, etc.); e irregular (objetos sem uma forma específica). Os autores aplicaram o método proposto em dados provenientes de LiDAR aéreo, terrestre estático e móvel.

Na literatura podem ser encontrados outros trabalhos que utilizam descritores baseados nos autovalores (DITTRICH; WEINMANN; HINZ, 2017; WEINMANN et al., 2017). Como pode-se ver em Wienmann et al. (2017) os autores realizaram um estudo para avaliar a relevância de alguns atributos como planaridade, linearidade, entropia, omnivariância, curvatura, esfericidade e anisotropia para a tarefa de classificação de uma nuvem de pontos LiDAR. Os autores avaliariam diferentes aspectos, tais como: impacto do tipo de amostragem dos pontos, impacto do tipo e tamanho da vizinhança, e influência de diferentes classificadores supervisionados. Dessa forma, os autores conseguiram classificar os pontos entre as classes semânticas: linha de transmissão, poste/tronco, fachada, terreno e vegetação. Özdemir et al. (2021), por sua vez, consideraram os parâmetros de mudança de curvatura e planaridade para diferenciar pontos sobre edificações e vegetação a partir de um conjunto de pontos que não pertenciam ao terreno, os quais foram previamente filtrados.

Chen et al. (2018) desenvolveram um método de segmentação da nuvem de pontos que combinou a técnica de agrupamento de pontos convencional baseado na média móvel e a detecção de troncos. Dessa maneira, os autores obtiveram uma melhora na performance do algoritmo na tarefa de detectar árvores de sub-bosque

(ocluídas parcialmente por árvores maiores) em uma floresta de estrutura complexa.

A análise de nuvens de pontos LiDAR para o reconhecimento de objetos em uma cena também é assunto de estudos por parte da visão computacional, onde se faz o uso de descritores geométricos 3D para discriminar os diferentes objetos com base nas suas características geométricas (HAN et al., 2018).

Jaskierniak et al. (2021) propuseram um método para a detecção de árvores individuais e o delineamento de copas utilizando uma abordagem base-topo por meio da estimativa de densidades de kernel para estratificar o perfil da vegetação e diferenciar as árvores de sub-bosque do resto da vegetação. Para os indivíduos mais altos foi adotada a técnica de agrupamento *watershed* e então um procedimento de Análise de Componentes Principais (PCA) foi aplicado para formar os agrupamentos de tronco, galhos e dossel, antes de uni-los em uma só árvore.

Além das abordagens apresentadas, outras podem ser encontradas na literatura. Itakura; Miyatani; e Hosoi (2022) desenvolveram um trabalho que buscou estimar os parâmetros estruturais de árvores por meio de um método de segmentação automática de nuvem de pontos LiDAR onde foi utilizado o descritor FPFH (*Fast Point Feature Histogram*) (HAN et al., 2020) aplicado a um conjunto de pontos previamente filtrado e normalizado em relação ao terreno. Neste procedimento fez-se o uso de filtros morfológicos para separar entre as classes terreno e não terreno. As árvores individuais foram detectadas e segmentadas com o classificador não supervisionado K-médias, que por sua vez utilizou o descritor FPFH e distância euclidiana como parâmetro de agrupamento. Por fim, o método também foi capaz de classificar os galhos e folhas das árvores por meio de uma classificação por análise discriminatória com base em dados de treinamento.

No trabalho apresentado por (PU et al., 2023), a detecção e segmentação individual de árvores com e sem folhas foi o foco do método proposto. Foram usadas nuvens de pontos obtidas em épocas diferentes, quando as árvores estavam com as copas completas de folhas e quando boa parte delas havia caído. De acordo com os autores, o levantamento realizado com a folhagem menos densa permitiu definir as partes mais estruturais das árvores, como troncos e galhos, enquanto o levantamento feito com a folhagem mais densa permitiu segmentar as copas de cada árvore. Dessa forma, utilizando um algoritmo que partiu da detecção automática de pontos sementes na nuvem de pontos, realizou o agrupamento com base na densidade de pontos (DBSCAN) e refinou a segmentação com o classificador kNN (*K-Nearest Neighbor*

Classifier), que permitiu segmentar as árvores individualmente com acurácia e tempo de processamento otimizado em relação a outros métodos testados pelos autores.

Em função do que foi colocado, pretende-se desenvolver uma estratégia para identificação e extração de árvores isoladas ou conglomerados, em áreas urbanas, a partir de dados obtidos por um Sistema de Varredura a LASER Aerotransportado, com base na intensidade e em descritores 3D calculados com autovalores. No presente estudo a ideia foi desenvolver um método baseado em uma abordagem não supervisionada, dispensando a necessidade de coletar amostras de treinamento, que utilize o conceito de morfologia matemática para refinamento dos resultados. Além disso, os limiares envolvidos no processo podem ser intuitivamente determinados considerando características geométricas da nuvem (densidade média de pontos, precisão posicional) e das árvores presente na cena (altura média das árvores de interesse, e área mínima da copa da árvore).

1.2 Objetivos

O cálculo de descritores geométricos 3D aliado com a informação de intensidade podem ajudar caracterizar árvores de demais objetos presentes em áreas urbanas. Dessa forma, o objetivo deste trabalho é desenvolver e avaliar um método para extrair pontos pertencentes a árvores ou conglomerados em áreas urbanas, a partir de dados obtidos com Sistema de Varredura a LASER Aerotransportado.

Com este propósito, os seguintes objetivos específicos foram definidos:

- Propor e desenvolver um método de detecção de árvores em áreas urbanas com base na combinação dos descritores geométricos 3D e intensidade, e refinamento por morfologia matemática;
- Avaliar o desempenho do uso dos descritores e intensidade na detecção de indivíduos arbóreos e conglomerados por meio de dados LiDAR;
- Avaliar o impacto do tipo e tamanho da vizinhança no cálculo dos atributos geométricos para detecção de árvores, bem como a influência do tamanho do elemento estruturante no refinamento dos resultados de detecção por morfologia matemática;

- Testar a robustez do método proposto em ambientes urbanizados que apresentam cobertura vegetal com características variadas, utilizando dados reais de diferentes localidades e;
- Avaliar qualitativamente e quantitativamente o método proposto comparando os resultados com dados de referência, bem como em relação a outras abordagens presentes na literatura.

2 FUNDAMENTAÇÃO TEÓRICA


2.1 Sistemas de Varredura a LASER Aerotransportado

Os sistemas LiDAR tem como característica principal a emissão e recepção de pulsos LASER sobre uma superfície, com o objetivo de gerar uma nuvem de pontos tridimensional (3D) amostrados irregularmente. Conforme El-Sheimy et al. (2005), um sistema LiDAR consiste na integração de três tecnologias: sistema de varredura a LASER, sistema de posicionamento GNSS e IMU. A aquisição dos dados LiDAR pode ocorrer a partir de plataformas terrestres, aéreas ou orbitais. No caso aéreo, os chamados SVLA (Sistema de Varredura a LASER Aerotransportado) podem ser embarcados em aviões, helicópteros ou mesmo VANT (Veículos Aéreos Não Tripulados).

O princípio de um SVLA consiste basicamente em emitir um feixe LASER com o auxílio de um espelho na direção de objetos da superfície, e após a reflexão do feixe capturar o eco que retorna ao sistema. A partir do tempo de propagação do pulso LASER, o sistema calcula a distância entre o sensor e o objeto (WEHR; LOHR, 1999; GALVANIN; DAL POZ, 2013). A distância sensor-alvo pode ser medida a partir do tempo de propagação do sinal ou a partir da diferença de fase obtida da comparação entre as ondas emitidas e recebidas pelo sistema, como pode-se ver em Shan e Toth (2008). Por se tratar de um sistema ativo, o SVLA pode ser utilizado independentemente das condições de iluminação da cena.

Todo pulso LASER emitido possui um ângulo de divergência, como ilustrado na Figura 2.1. Esse ângulo de divergência faz com que o pulso projetado na superfície corresponda a uma dada área, em geral circular ou elíptica. O diâmetro correspondente à projeção do pulso é denominado de *footprint*. Dessa forma, dependendo do ângulo de divergência e da altura de voo, o diâmetro do *footprint* se modifica ao atingir um determinado alvo, e para um dado pulso emitido pode-se ter múltiplos retornos (Figura 2.1). Tal característica é explorada em diversas aplicações, principalmente nos estudos de detecção de vegetação, uma vez que os retornos intermediários são reflexões parciais da luz por parte de feições como galhos, folhas e troncos (CHEN et al., 2018; DONG et al., 2020).


Figura 2.1 - Múltiplos retornos do pulso LASER.



Fonte: Barbosa (2017).

Para a determinação das coordenadas 3D dos pontos amostrados, é necessária a combinação dos três sistemas que compõem um SVLA. A unidade LASER executa as funções de gerar e emitir os pulsos de energia amplificada e colimada, bem como receber parte dela que foi refletida pelos objetos presentes na superfície ou atmosfera. O GNSS tem a função de fornecer as coordenadas planimétricas (E, N) e a altimétrica (h) de cada ponto em um referencial predefinido. A IMU, por sua vez, é responsável por determinar e fornecer os ângulos de atitude da plataforma durante a missão. Deste modo, combinando-se as informações da unidade LASER, GNSS e da IMU é possível determinar a posição 3D de cada um dos pontos amostrados, como pode-se ver em El-Sheimy (2008) e Shan e Toth (2009), por exemplo. A integração desses sistemas é ilustrada na Figura 2.2.

Figura 2.2 – Integração de sistemas de um SVLA.



Fonte: Vosselman e Maas (2010).

2.1.1 Informação de intensidade

Grande parte dos sistemas de varredura registram, além do tempo de propagação ou diferença de fase, a amplitude do pulso LASER refletido após interagir com os objetos da superfície iluminada. Essa amplitude é comumente chamada de intensidade e é armazenada pelos sistemas, juntamente com as coordenadas tridimensionais do ponto (KASHANI et al., 2015; SHAN; TOTH, 2009). A energia recebida pelos fotodetectores do sistema LiDAR é convertida em um sinal elétrico, ao qual se atribui um número digital tipicamente nas resoluções de 8 bits (0 a 255), 12 bits (0 a 4.095) ou 16 bits (0 a 65.535) (KASHANI et al., 2015).

O valor da intensidade está relacionado com a capacidade de reflexão ou absorção do pulso LASER por parte do alvo e, conseqüentemente, com as suas propriedades físicas. Vale ressaltar que a resposta radiométrica varia em função do comprimento de onda do LASER que cada sistema produz, o qual geralmente está concentrado na região do infravermelho próximo (800 nm a 1000 nm) no caso dos SVLAs (WEHR; LOHR, 1999). Ainda, dependendo da forma do objeto iluminado, a reflexão do pulso poderá ser especular (quando a energia incidente é refletida com na mesma direção de incidência), difusa (quando a energia incidente é retroespalhada em direções dispersas) ou uma integração das duas (SHAN; TOTH, 2009). Assim, na reflexão especular a energia é refletida praticamente com a mesma intensidade, provocando uma resposta normalmente saturada, enquanto na reflexão difusa a intensidade da energia é atenuada. No caso das árvores, por exemplo, o padrão

rugoso do dossel (copa) causa um espalhamento volumétrico do pulso LASER que atenua a intensidade de energia que retorna aos sensores e, por consequência, as árvores apresentam valores de intensidade médios. Para exemplificar, Wehr e Lohr (1999) trazem a porcentagem de refletividade de alguns alvos para um comprimento de onda de 900 nm (Tabela 2.1):

Tabela 2.1 - Porcentagem de refletividade de alguns objetos para um comprimento de onda de 900 nm.

Material	Refletividade (%)
Neve	80 - 90
Alvenaria branca	85
Calcário e argila	Até 75
Árvore decídua	60
Árvore conífera	30
Concreto	24
Asfalto	17

Fonte: Adaptado de Wehr e Lohr (1999).

Dessa forma, nota-se o potencial do uso da informação de intensidade obtida por um sistema LiDAR, em algumas aplicações, com a finalidade de obter informações a respeito da superfície e identificar objetos que são difíceis de serem reconhecidos apenas com as informações de elevação (3D). Entretanto, devem ser considerados os diversos fatores da geometria de aquisição, do ambiente de varredura (ar, água, etc.) e dos sensores envolvidos, além do comprimento de onda do sistema, que podem influenciar nas medidas de intensidade. De acordo com Kashani et al. (2015), além dos componentes envolvidos na medição e registro, a intensidade pode ser afetada por outros parâmetros, como o poder de transmissão, distância, ângulo de incidência, transmitância atmosférica, umidade, divergência do feixe, responsividade do detector, dentre outros. Logo, para sanar esses problemas, várias técnicas foram e estão sendo desenvolvidas para calibrar, normalizar ou corrigir os valores de intensidade de forma que se obtenha dados mais coerentes com a realidade da superfície.

Além dos sistemas LiDAR mencionados, que operam na região do infravermelho próximo (800 nm a 1000 nm), destinados a levantamentos e aplicações topográficas, existem também os sistemas LiDAR aerotransportados destinados a operações batimétricas, que operam na região verde do espectro eletromagnético (532 nm). O uso deste comprimento de onda se deve justamente à sua capacidade

de penetração em lâminas d'água. Para mais detalhes sobre os sistemas LiDAR destinados a levantamentos batimétricos, as seguintes referências são sugeridas: Guenther et al. (1994), Guenther et al. (1996), Velasco et al. (2014), Nascimento et al. (2021), Zhou et al. (2022), e Awadallah et al. (2023).

2.2 Processamento de dados LiDAR

Como já mencionado anteriormente, os dados LiDAR são utilizados para fazer a amostragem de pontos na superfície, o que permite representá-la por meio de modelos digitais e ainda mapear objetos de interesse para diferentes aplicações, desde que uma série de processamentos sejam realizados.

No momento do levantamento, o pulso LASER emitido por um sistema LiDAR pode ser refletido por diversos objetos da superfície terrestre, tais como edificações, vegetação, carros, linhas de transmissão, vias e ferrovias, além do próprio terreno (VOSSELMAN, 2000). Além disso, os pontos medidos não são distribuídos uniformemente. Dessa forma, dependendo da aplicação, algumas informações podem ser consideradas descartáveis e, então, é necessário separá-las das demais e modelá-las conforme alguns parâmetros predefinidos. Segundo Sithole e Vosselman (2003), o processamento LiDAR inclui tarefas como modelagem dos erros sistemáticos, filtragem e classificação.

Uma das etapas do processamento dos dados LiDAR é a filtragem. A filtragem tem como objetivo remover pontos indesejados da nuvem, os quais foram medidos erroneamente, ou representam objetos que não são de interesse para uma determinada aplicação. As medições indesejadas podem, dependendo da aplicação, ser caracterizadas como ruído, *outliers* ou erros grosseiros (AXELSSON, 1999). Em alguns métodos os pontos de não terreno (edificações, postes, vegetação, dentre outros) são separados dos pontos de terreno por meio desse processo. Já em outras abordagens, a classificação é realizada diretamente sobre os pontos da nuvem de pontos original, dispensando a necessidade da filtragem.

Algumas aplicações exigem algoritmos e técnicas específicas para a classificação de uma nuvem de pontos LASER, uma vez que as propriedades físicas e geométricas dos objetos presentes em uma cena variam. Dessa forma, o processo de classificação pode ser executado com a finalidade de encontrar um padrão

geométrico ou estatístico que permite caracterizar um conjunto de pontos (AXELSSON, 1999) como edificação ou vegetação, por exemplo.

2.3 Detecção e extração de árvores

De acordo com Chen *et al.* (2018) a fotogrametria tradicional e o sensoriamento remoto por imagens orbitais e aerotransportadas não conseguem determinar diretamente informações 3D da estrutura das árvores. Por isso, devido à sua capacidade de gerar dados 3D com alta resolução espacial e precisão, os SLVAs estão cada vez mais sendo usados em monitoramento de recursos florestais baseados na detecção de indivíduos arbóreos e conglomerados.

Segundo BARBOSA (2017), as primeiras utilizações de dados LiDAR em aplicações florestais são reportadas por (NELSON; KRABILL; MACLEAN, 1984). Desde então, os estudos sobre o uso de dados obtidos por um SVLA para essa finalidade têm crescido consideravelmente. Nesse contexto, diversos algoritmos de processamento de imagens têm sido adaptados para a detecção da copa das árvores utilizando dados LiDAR, tal como o crescimento de regiões, segmentação *watershed*, análise morfológica, detecção de máximos locais (DONG et al., 2020; CASTRO; CENTENO, 2005). Por outro lado, outras abordagens têm buscado trabalhar diretamente com os pontos tridimensionais, onde se nota uma melhoria na taxa de detecção de árvores em regiões onde há árvores com copas complexas e distribuição não regular (JASKIERNIAK et al., 2021; KOCH; HEYDER; WEINACKER, 2006; LU et al., 2014).

2.3.1 Uso de descritores geométricos para classificar nuvem de pontos

Os algoritmos de detecção e extração de objetos tridimensionais operam baseados em critérios específicos para cada classe de objeto de interesse, os quais são denominados de descritores 3D. Segundo Han et al. (2020), os descritores permitem a realização de tarefas de visualização 3D de forma mais acurada e eficiente. Os autores ainda acrescentam que um descritor poderoso deve ser capaz de reconhecer uma determinada estrutura geométrica independentemente das suas variações de translação, escala e rotação.

Na literatura, é possível encontrar descritores com diferentes características dedicados ao reconhecimento de objetos em uma nuvem de pontos. No contexto da delimitação de indivíduos arbóreos, o padrão irregular das copas e a grande

ocorrência de áreas de oclusão e de sobreposição dificulta a tarefa de extrair descritores 3D significativos, a partir de dados LiDAR (CHEN et al., 2018; DONG et al., 2020).

Han et al. (2018) realizaram um levantamento dos descritores usados para análise de cenas 3D. Segundo os autores, os descritores podem ser organizados em três grandes classes: descritores locais, descritores globais e descritores híbridos. Neste levantamento, que envolvem dezenas de descritores para as mais diversas aplicações, alguns merecem ser destacados por apresentarem características mais apropriadas para a detecção de indivíduos arbóreos, que é o foco deste trabalho. Dentre eles estão os descritores baseados em autovalores; entropia da superfície e alguns descritores híbridos.

Diferentes estudos voltados para a análise de cenas 3D têm explorado o conceito dos autovalores para descrever as características dos objetos (DEMANTKÉ et al., 2012; DITTRICH; WEINMANN; HINZ, 2017; WEINMANN et al., 2015, 2017). Os autovalores são obtidos pela decomposição de uma matriz de variância-covariância local definida por pontos de uma região de suporte e são ordenados decrescentemente ($\lambda_1 > \lambda_2 > \lambda_3 \geq 0$). Por meio da combinação destes autovalores, um conjunto de descritores podem ser calculados, tais como: planaridade (P_λ), esfericidade (S_λ), omnivariância (O_λ), anisotropia (A_λ), entropia dos autovalores (E_λ), linearidade (L_λ) e a curvatura (C_λ), conforme as Equações 2.1 a 2.7.

$$P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (2.1)$$

$$S_\lambda = \frac{\lambda_3}{\lambda_1} \quad (2.2)$$

$$O_\lambda = \sqrt[3]{\lambda_1 \times \lambda_2 \times \lambda_3} \quad (2.3)$$

$$A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1} \quad (2.4)$$

$$E_\lambda = - \sum_{i=1}^3 \lambda_i \times \log \lambda_i \quad (2.5)$$

$$L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (2.6)$$

$$C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (2.7)$$

A entropia de superfície (FIOLKA et al., 2014) também é um descritor local de textura e forma baseado nas informações geométricas, além da informação de cor, se elas estiverem disponíveis. Dessa forma, este descritor mede o grau de dispersão da

superfície (textura) por meio do cálculo da entropia. Como visto na Equação (2.5), a entropia pode ser calculada por meio dos autovalores. No entanto, Oliveira e Galo (2017) utilizaram as altitudes dos pontos de uma vizinhança para definir este descritor, conforme mostra a Equação 2.8:


$$E_h = \frac{\sum_{i=1}^n [-(h_i - h_{min} + \Delta) \ln (h_i - h_{min} + \Delta)]}{n} \quad (2.8)$$

onde h_i é a altitude de um dado ponto da vizinhança, h_{min} é a altitude mínima da vizinhança, e Δ uma constante utilizada evitar a singularidade nos casos em que a diferença $(h_i - h_{min})$ se anule, ou seja, $h_i - h_{min} = 0$, evitando assim a indeterminação no cálculo do logaritmo e por consequência de E_h .

Os descritores híbridos, segundo Han *et al.* (2018), possuem essa denominação por combinarem descritores locais e globais ou por possuírem dois modos de inicialização: a partir dos pontos de maior altitude (*top-down*) e a partir dos pontos de menor altitude (*bottom-up*). Estes descritores geralmente operam em uma vizinhança cilíndrica ou células de volume (*voxels*), cujos parâmetros são definidos pelo usuário. Para aplicações florestais, Chen *et al.* (2018) propuseram um método de detecção que inicia nos pontos mais altos e continua até os pontos com uma altura mínima definida para detectar as copas das árvores e, em seguida, utilizava os pontos mais baixos para definir os troncos. Dessa forma, os autores utilizaram as detecções de troncos para auxiliar a detecção dos indivíduos arbóreos, obtendo uma melhoria na acurácia posicional e na capacidade de detecção de árvores oclusas.

No contexto da análise de cenas 3D com dados LiDAR, o processo de reconhecimento dos objetos presentes é baseado em uma sequência comum de etapas (WEINMANN *et al.*, 2015). Como mostra a Figura 2.3, as etapas envolvem (1) a seleção de uma vizinhança em torno de cada ponto, (2) extração de métricas geométricas com base nos pontos vizinhos, (3) seleção das métricas mais apropriadas, e (4) classificação da nuvem de pontos baseada nas métricas extraídas.

Figura 2.3 - Etapas para a classificação de uma nuvem de pontos LiDAR.



Fonte: Adaptado de Weinmann *et al.* (2015).

2.3.1.1 Tipos de vizinhança

Como mencionado anteriormente, a seleção da vizinhança é uma das etapas do processo de reconhecimento de objetos em cenas 3D obtidas por sistemas LiDAR. Por esse motivo, a preocupação com a seleção da melhor vizinhança para calcular os descritores em um conjunto de pontos não é recente e diversos estudos foram dedicados à resolução deste problema (LEE; SCHENK, 2002; FILIN; PFEIFER, 2005; DEMANTKÉ et al., 2012; WEINMANN et al., 2015).


Diferentes estratégias podem ser adotadas para recuperar a vizinhança de um ponto. Em geral, de acordo com Weinmann et al. (2015), as definições mais comuns de vizinhanças são a esférica, cilíndrica e a formada por uma quantidade fixa (N) de vizinhos mais próximos. A vizinhança esférica é definida por todos os pontos 3D que se encontram dentro de uma esfera de raio fixo centrada no ponto de interesse; a vizinhança cilíndrica é definida pelos pontos 3D cujas projeções 2D em um plano estão dentro de um círculo de raio fixo centrado no ponto de interesse; a terceira definição de vizinhança é formada por um número fixo de pontos 3D ou 2D mais próximos ao ponto de interesse. Embora as duas primeiras definições forneçam uma solução mais direta e de fácil implementação, o número de vizinhos varia principalmente em função da distribuição e da densidade de pontos da nuvem, que pode sofrer grandes variações, como pode-se ver em Santos et al. (2020).

2.3.2 Uso da intensidade na detecção de árvores

As aplicações da informação de intensidade variam entre registro dos dados, extração de características, análises de superfície em ambientes naturais, detecção e reconhecimento de objetos, e batimetria (KASHANI et al., 2015). Charaniya; Manduchi; Iodha (2004) concluíram em seu trabalho que a utilização da intensidade dos dados obtidos com um SVLA permite classificar objetos comuns do ambiente urbano como estradas/ruas asfaltadas, grama, árvores e telhados de residências. Liu et al. (2009) exploraram a intensidade para filtragem dos pontos localizados no terreno e dos pontos acima dele, com base em análises estatísticas de assimetria (*skewness*) e curtose, antes de detectar a vegetação e linhas de transmissão usando a Transformada de Hough. No contexto da detecção de vegetação, Yunfei et al. (2008) propuseram um método de geração de Modelo Digital de Terreno (DTM – *Digital*

Terrain Model) em área florestada. Para isso os autores utilizaram a intensidade para detectar os pontos sobre a vegetação e separá-los dos pontos de terreno. Em outro estudo realizado por LU et al. (2014), os autores observaram que diferentes estruturas das árvores (folhas, galhos e tronco) geram respostas de intensidade diferentes. No método proposto pelos autores, essa característica foi explorada para separar os pontos de tronco e copa por meio de um limiar de intensidade definido pelo usuário (Figura 2.4). Adicionalmente, os autores consideraram características da estrutura das árvores, visando detectá-las na nuvem de pontos LiDAR.

Figura 2.4 - Detecção de troncos por meio da definição de limiar de intensidade. Pontos em vermelho: intensidade ≥ 35 ; pontos em verde: intensidade ≤ 35



Fonte: Adaptado de Lu et al. (2014).

Budei et al. (2022) exploraram a potencialidade da informação de intensidade para classificar árvores em uma floresta de coníferas no Canadá entre seis espécies distintas. Para isso, foram utilizados dados provenientes de um sistema LiDAR multiespectral composto por LASER emitido em três comprimentos de onda diferentes. Os autores utilizaram um método de classificação por *Random Forest* e características geométricas e espectrais de cada espécie para sua caracterização.

2.3.3 Métodos de classificação de nuvem de pontos

Existem diversos algoritmos usados para a classificação de nuvem de pontos. Dentre os métodos que podem ser aplicados, estão aqueles baseados em aprendizado de máquina, tais como o *Random Forest* (CHEHATA et al., 2009), as Redes Neurais Convolucionais (CNN) (GUAN et al., 2019) e a Máquina de Vetores de Suporte (SVM – *Support Vector Machine*) (SECORD; ZAKHOR, 2007). Tratam-se de classificadores supervisionados, pelo fato de necessitarem de treinamento por meio de amostras das classes de referência fornecidas previamente pelo usuário.

Alternativamente às estratégias baseadas em aprendizagem de máquina, têm-se os métodos de agrupamentos, também chamados de *clustering*. Tais algoritmos possibilitam separar um conjunto de pontos em grupos (ou *clusters*) de acordo com alguma medida de similaridade ou distância predefinida (JOHNSON; WICHERN, 2007a). Estes algoritmos são comumente utilizados em análises e classificação de dados LiDAR, pois permitem criar conjuntos de pontos com características similares entre si e distintos dos demais conjuntos.

O K-médias, por exemplo, é um algoritmo amplamente utilizado devido a facilidade de implementação e relativa eficiência. Trata-se de um método não supervisionado, já que não necessita de informações prévias a respeito do conjunto de dados para gerar os *clusters*. Na sua forma mais simples, o algoritmo é composto por três etapas (JOHNSON; WICHERN, 2007a):

1. Seleção de K pontos que determinarão os centroides dos agrupamentos;
2. Atribuição de um ponto da nuvem ao conjunto cujo centroide (média) é o mais próximo, seguida do recálculo do centroide do agrupamento após sua atualização e;
3. Repetição do passo 2 até que não haja mais pontos para serem incluídos.

2.4 Filtros morfológicos

A morfologia matemática trata do estudo e análise de imagens, originalmente binárias, a partir do uso de operações não lineares para remover imperfeições, detectar falhas, analisar formas e texturas, além de extrair informações a respeito do tamanho e da forma de estruturas presentes nas imagens (GONZALEZ; WOODS, 2009; BURGER; BURGE, 2016).


Conceitualmente, a morfologia se baseia na teoria dos conjuntos, onde uma imagem binária (cujos pixels assumem apenas os valores 0 ou 1) é representada no espaço 2D (Z^2). Sendo B um conjunto de Z^2 , com componentes $b = (b_1, b_2)$, a reflexão e translação num ponto $z = (z_1, z_2)$ do conjunto são dadas, respectivamente, por:

$$\hat{B} = \{w | w = -b, \text{ para } b \in B\}, \quad (2.9)$$

$$(B)_z = \{c | c = b + z, \text{ para } b \in B\}. \quad (2.10)$$

A Figura 2.5 representa a reflexão e translação de um conjunto B .


Figura 2.5 - Em (a) se tem a representação matricial do objeto mostrado em (b). Em (c) e (d) tem-se, respectivamente, a reflexão e translação do objeto (b).



Fonte: O Autor (2023).

De acordo com (GONZALEZ; WOODS, 2009), a reflexão e translação são a base para formular operações morfológicas que utilizam os chamados elementos estruturantes (EE): conjuntos menores ou subimagens usadas para examinar uma imagem buscando as propriedades de interesse. Um EE pode apresentar formas diferentes (Figura 2.6), mas ao se trabalhar com imagens normalmente são definidos como um arranjo matricial simétrico com determinado número de elementos. A dimensão do EE depende da dimensão dos objetos de interesse presentes na imagem original e sua determinação normalmente é feita de modo empírico.

Figura 2.6 - Exemplos de elementos estruturantes para aplicação em operações morfológicas: quadrado, retângulo, diamante, disco, octógono e estrela.



Fonte: Scikit-Image (<https://scikit-image.org/>).

As operações fundamentais da morfologia matemática são a dilatação e a erosão, que correspondem, respectivamente, à adição de Minkowski e subtração de

Minkowski, como pode-se ver em Pedrini e Schwartz (2008). A dilatação corresponde ao processo no qual um EE é transladado pela imagem fazendo com que, ao se sobrepor a uma região ou objeto de interesse, resultará na expansão dessa região. Dessa forma, a dilatação é um processo que preenche espaços vazios, aumenta a espessura das bordas e conecta partes separadas de objetos, operando de forma similar ao processo de crescimento de regiões, no qual o contorno de objetos é expandido (BURGER; BURGE, 2016).


De maneira oposta, na operação de erosão um EE é transladado pela imagem e para cada posição sobreposta completamente por ele, a região sofre uma redução em seu tamanho. Assim, a erosão remete ao processo de desgaste dos objetos, sendo comum sua aplicação na remoção de pequenos detalhes indesejados e que não contribuem para a caracterização da forma de um objeto, além de segmentar, separar ou simplificar as partes de um região de interesse (BURGER; BURGE, 2016).

Embora não sejam mutualmente inversas (em geral, os efeitos obtidos com a dilatação não podem ser revertidos com uma operação de erosão subsequente), a dilatação e erosão possuem uma forte relação de dualidade. Por isso, elas são empregadas frequentemente em conjunto, dando origem a operações compostas chamadas de abertura e fechamento.

A Figura 2.7 ilustra os efeitos da aplicação de abertura e fechamento em uma imagem binária, para diferentes dimensões do EE. A coluna à esquerda contém os resultados da Abertura enquanto a coluna à direita contém os resultados da aplicação do Fechamento.

A abertura consiste numa erosão seguida de uma dilatação realizada pelo mesmo EE, resultando na eliminação de pequenas estruturas na imagem e suavização das estruturas restantes. Já no fechamento, a sequência das operações é revertida. A dilatação seguida por uma erosão resulta num fechamento (remoção) de descontinuidades na forma dos objetos, desde que estas descontinuidades sejam menores que o EE (BURGER; BURGE, 2016; GONZALEZ; WOODS, 2009).

Figura 2.7 - Abertura e fechamento em uma imagem binária com EE circular de raio (r) variando de 1,0 (primeira linha), 2,5 (linha do meio) e 5,0 (terceira linha).



Fonte: Adaptado de Burger e Burge (2016).

Ainda de acordo com Burger e Burge (2016), é possível fazer o uso de operações morfológicas em conjunto para formar os chamados Filtros Morfológicos, os quais são especificados por: (I) o tipo de operação e (II) o conteúdo do elemento estruturante. O tamanho apropriado e forma do EE vão depender da aplicação.

2.5 Crescimento de Regiões

O crescimento de regiões é uma técnica aplicada no processamento digital de imagens e na segmentação de outros tipos de dados que busca agrupar pixels ou

sub-regiões em regiões maiores baseado em critérios preestabelecidos (GONZALEZ; WOODS, 2009). O conceito básico do algoritmo de crescimento de regiões é iniciar o procedimento a partir de pontos iniciais, denominados de pontos sementes, e expandir essas regiões agrupando-se pixels ou elementos vizinhos que compartilham características de interesse, tais como intensidade de cor, textura, forma, posição espacial, dentre outros atributos relevantes.

O algoritmo inicia com a seleção automática, ou não, de um ponto semente, seguida de cálculos iterativos na vizinhança local para definir se um determinado ponto ou conjunto de pontos atende aos critérios de similaridade definidos previamente. Se os critérios forem atendidos, o ponto é incluído na região que contém o ponto semente inicial fazendo com que ela se expanda. Caso o ponto não atenda aos critérios de similaridade, significa que ele pertence a uma outra região, determinada a partir de um ponto semente diferente. O processo se repete até que todos os pontos do conjunto de dados sejam atribuídos a uma região.

Este processo pode ser realizado tanto no espaço 2D quanto 3D. No caso de nuvens de pontos LiDAR, formadas por pontos no espaço 3D, o processo é realizado no espaço tridimensional a partir da nuvem disponível. Pode-se adotar como critério de agrupamento dois limiares espaciais: distância planimétrica (d_{XY}) e distância altimétrica (d_Z). Na sequência, são descritos os passos realizados no agrupamento por crescimento de regiões, conforme a abordagem de Santos (2019):

Passo 1: Os pontos de árvores são organizados num conjunto E em ordem decrescente em relação a coordenada Z, de forma que $Z_{P1} > Z_{P2} > \dots > Z_{Pn}$;

Passo 2: O ponto mais alto P1 é definido como ponto semente;

Passo 3: Considerando uma esfera de raio r posicionada no ponto semente, selecionar todos os pontos que estão dentro dela, sendo que

$$r = [(d_{XY}^2 + d_H^2)]^{1/2} \quad (2.11)$$

Passo 4: Verifica-se se os critérios de agrupamento são atendidos, conforme as Equações 2.12 e 2.13. Os pontos que atendem aos dois critérios são armazenados em um conjunto A :

$$\sqrt{(X_i - X_c)^2 + (Y_i - Y_c)^2} < d_{XY} \quad (2.12)$$

$$|Z_i - Z_c| < d_Z \quad (2.13)$$

onde X_i , Y_i , e Z_i são as coordenadas de um dos pontos interiores da esfera, e X_c , Y_c , e Z_c são as coordenadas do centro da esfera;

Passo 5: Move-se a esfera para o ponto seguinte da vizinhança $[X_{i+1}, Y_{i+1}, Z_{i+1}]$;

Passo 6: Verificam-se novamente os critérios de similaridade considerando a nova posição da esfera. Os pontos que atendem aos critérios são armazenados num conjunto temporário T ;

Passo 7: Repetir os passos 5 e 6 até que a esfera seja centrada em todos os pontos do conjunto A do passo 4. Nesse passo, os pontos repetidos são ignorados;

Passo 8: Unir os pontos de A e T em um conjunto B ($B = \{A \cup T \cup B\}$);

Passo 9: Substitui-se os pontos de A pelos pontos de T e retorna ao passo 5;

Passo 10: Quando não houver mais pontos a serem adicionados em B , significa que a região está completa. Então, tais pontos são removidos do conjunto inicial de entrada e retoma-se ao Passo 2 e;

Passo 11: Finalizar o processo quando E estiver vazio.

Apesar de simples, a técnica pode apresentar alguns problemas de desempenho devido a dois fatores básicos fundamentais: (i) a seleção de pontos sementes que representam o conjunto de dados e o número de regiões de interesse de forma adequada para a segmentação; e (ii) a seleção das propriedades mais apropriadas que irão incluir ou não um determinado ponto para as regiões de interesse, especialmente quando não se tem informações a priori a respeito dos dados que estão sendo utilizados (GONZALEZ; WOODS, 2009).

Ainda assim, o algoritmo de crescimento de regiões tem sido utilizado em uma série de trabalhos para segmentação de dados, inclusive de nuvem de pontos 3D, como já mencionado na Seção Estado da Arte (Seção 1.1).

2.6 Parâmetros de qualidade

Os indicadores de qualidade podem variar em suas formulações matemáticas e nomenclaturas, de acordo com diferentes autores e aplicações. A principal finalidade destes indicadores é descrever qualitativamente um conjunto de dados e permitir uma comparação coerente entre diferentes métodos. Dessa forma, é possível avaliar o qual bem o conjunto atende às especificações descritas para um produto (ISO 19157, 2013).

Nos trabalhos cujo objetivo é a detecção da vegetação em dados LiDAR, os indicadores de qualidade frequentemente utilizados para avaliar a correspondência entre os objetos reconhecidos e os dados de referência são: completeza (*completeness*, *recall*, *sensitivity*), nível de acerto (*precision*), e *F-score* (SOKOLOVA et al., 2006; VEGA et al., 2014; MONGUS; ŽALIK, 2015; BARBOSA, 2017; CHEN et al., 2018). A completeza mede a taxa de árvores detectadas e está relacionada inversamente com o erro de omissão. Já o nível de acerto representa o número de árvores corretamente detectadas, sendo então inversamente proporcional ao erro de comissão. O *F-score* mede a acurácia geral da detecção de árvores, sendo a média harmônica entre nível de acerto e completeza (MONGUS e ŽALIK, 2015).

Os indicadores citados são obtidos por meio da matriz de confusão composta pelos elementos: (a) verdadeiro positivo (TP), o qual é número de elementos identificados e que existem no dado de referência; (b) falso positivo (FP) ou erro de comissão, que é o número de objetos erroneamente detectados como árvores; e falso negativo (FN) ou erro de omissão, que são as árvores que não foram detectadas.

A completeza, nível de acerto e *F-score* adotados como indicadores de qualidade neste trabalho são calculados com as Equações 2.9, 2.10 e 2.11, respectivamente.

$$Completeza = \frac{TP}{TP + FN} \quad (2.9)$$

$$Nível\ de\ acerto = \frac{TP}{TP + FP} \quad (2.10)$$

$$F - score = \frac{2 \times Nível\ de\ acerto \times Completeza}{Nível\ de\ acerto + Completeza} \quad (2.11)$$

3 MATERIAL E MÉTODO

As etapas para a realização deste trabalho foram elaboradas com o intuito de atingir os objetivos definidos no início, as quais compreendem: seleção da área de estudo e dos dados LiDAR; seleção dos descritores 3D, detecção das árvores, refinamento da classificação e avaliação dos resultados obtidos para as diferentes áreas.

3.1 Material

Os seguintes dados e *softwares* utilizados no desenvolvimento deste trabalho:

- Dados LiDAR da cidade de Presidente Prudente/SP - Brasil, com suas devidas especificações, sendo selecionadas três áreas de estudo a partir do dados disponíveis no “Unesp Photogrammetric Data Set” (<http://www.fct.unesp.br/#!/unespdataset>) (TOMMASELLI et al., 2018);
- *CloudCompare* (Disponível em: <https://www.danielgm.net/cc/>) e;
- *Python 3.9.2* (Disponível em: <https://www.python.org/>).

No Quadro 3.1 são apresentadas as principais especificações dos dados LiDAR selecionados para este estudo.

Quadro 3.1 - Alguns parâmetros de aquisição e características dos dados LiDAR que usados no estudo.

Dado	Presidente Prudente - Brasil
Sistema LiDAR	RIEGL LMS-Q680i
Densidade média de pontos	12,5 pontos/m ²
Espaçamento médio entre os pontos	0,4 m
Altura média de voo	550 m


Fonte: TOMMASELLI et al., 2018

3.2 Áreas de estudo

As áreas de estudo foram selecionadas em ambiente urbano na cidade de Presidente Prudente/Brasil com base na diversidade de espécies, padrões das copas e altura das árvores. Dessa forma, torna-se possível avaliar a capacidade do método proposto de detecção de árvores em diferentes regiões. Na Figura 3.1 é apresentado um recorte geral da nuvem de pontos de Presidente Prudente/Brasil. Estes dados foram escolhidos por serem provenientes de um SVLA, embarcado em aeronave

tripulada, além de conterem imagens aéreas que serviram de base para a criação dos dados de referência para classificação. Visualmente, é possível notar que a vegetação divide espaço com outros elementos como edificações, terreno, postes de iluminação e linhas de transmissão. Percebe-se que existem conglomerados de árvores e árvores individuais com área, altura e padrões de copas diversificados.

Figura 3.1 - Recorte da nuvem de pontos de Presidente Prudente/Brasil colorida pela altura. Em (a) é destacada uma região cujo perfil é mostrado em (b).



Fonte: O Autor (2023).


A partir do conjunto de dados foram selecionadas três áreas de estudos, em diferentes localidades, para avaliar o método proposto. As regiões foram denominadas de Área 1 (A1), Área 2 (A2) e Área 3 (A3) (Figura 3.2), onde algumas de suas características estão presentes no Quadro 3.2. As áreas selecionadas são regiões urbanizadas que contém edificações residenciais, barracões, linhas de transmissão, ruas asfaltadas, mas também contém uma quantidade significativa de árvores de médio e grande porte para testar o método de detecção. As espécies de árvores são variadas, assim como o tipo de folhagem, formato do tronco e o padrão das copas.

Quadro 3.2 - Características das áreas de estudo selecionadas.

Área de estudo	A1	A2	A3
Dimensões (m)	206,2 x 144,0	212,2 x 181,5	85,4 x 121,5
Área (m ²)	29.692,8	38.514,3	10.376,1
Número de pontos	366.463	742.678	80.803
Densidade média (pontos/m ²)	12	19	8

Fonte: O Autor (2023).


Figura 3.2 - Imagens aéreas das áreas de estudo A1, A2 e A3 e de suas respectivas nuvens de pontos representadas em tons de cinza com base na intensidade.



Fonte: Unesp Photogrammetric Data Set (2017).

Para cada área de estudo gerou-se o mapa de referência para a classe árvore, por meio de edição manual usando o software *CloudCompare*. Na Figura 3.3 são mostrados os mapas de referência gerado para as três áreas de estudo.

Figura 3.3 – Dados de referência da classificação das áreas de estudo selecionadas. Os pontos em verde representam pontos de árvores isoladas ou conglomerados.



Fonte: O Autor (2023).

3.3 Método

Com relação ao método proposto, um fluxograma sintético foi elaborado para representar a sequência das etapas realizadas, como mostrado na Figura 3.4. A primeira etapa consiste num pré-processamento para detectar e remover possíveis pontos espúrios (*outliers*) presentes na nuvem, por meio de um método que se baseia no uso da média e desvio padrão da altitude dos pontos, conforme descrito em Shiffler (1988). Então, seguindo a mesma lógica, foram detectados também os *outliers* dos valores de intensidade, os quais foram substituídos pelo valor mínimo ou máximo do intervalo de interesse.


Em seguida, os pontos que potencialmente são de árvores foram separados daqueles que não são, por meio do cálculo da omnivariância. Nesse caso, espera-se que o grau de dispersão dos pontos em uma região de vegetação seja maior do que em regiões relativamente regulares e planas, tais como em telhados e terreno. Nessa etapa diferentes descritores 3D foram testados, dentre eles: os baseados nos autovalores, e a entropia da superfície. Além disso, também foi utilizada a informação de intensidade (ver Seção 4.1). Considerando os resultados da omnivariância e da intensidade de cada ponto, o algoritmo K-médias foi empregado para rotular os pontos em duas classes: “árvore” ou “não-árvore”.

De acordo com o observado em Oliveira e Galo (2017), as linhas de transmissão e bordas de edificações podem ser confundidas com a copa das árvores, uma vez que nestas regiões ocorre também grande variação de altitude, ou seja, alta dispersão. Visando minimizar esse erro de classificação, uma etapa de refinamento baseado em morfologia matemática (MM) foi proposta. Neste caso explorou-se a técnica de abertura morfológica considerando o elemento estruturante (ES) circular de raio fixo. Logo, com base nos resultados da MM, pontos isolados e que não pertenciam à classe “árvore” foram removidos. Em seguida, foi executado o método de crescimento de regiões baseado em dois critérios espaciais (d_{xy} e d_h) para segmentar a nuvem e então extrair as árvores individualmente ou conglomeradas. Neste caso d_{xy} representa um limiar de distância horizontal e d_h um limiar de altura.

Finalmente, análises para avaliar a robustez e capacidade de detecção do método proposto foram feitas por meio do cálculo de indicadores de qualidade, comparando os resultados do processamento com dados de referência. A comparação foi realizada de dois modos: ponto a ponto e a nível de objeto (árvore

individual ou conglomerados), onde dados de referência foram criados manualmente por meio de análise visual no *software CloudCompare*.

Figura 3.4 - Fluxograma do método proposto.



Fonte: O Autor (2023).

3.3.1 Detecção de *outliers*

Em um conjunto de pontos obtido por um sistema LiDAR é comum a presença de pontos espúrios, também chamados de *outliers*, gerados por medições indesejadas no momento do levantamento. Os *outliers* podem causar problemas durante o processamento dos dados LiDAR (filtragem e classificação, por exemplo) e, portanto, a detecção e remoção prévia destes pontos é essencial de modo a não afetar as etapas posteriores (CARRILHO; GALO, 2017).

A etapa de detecção e remoção dos pontos espúrios presentes no conjunto de dados utilizado neste trabalho foi executada conforme a metodologia proposta por Carrilho e Galo (2017), a qual se baseia em operações estatísticas e não necessita de informações externas aos dados. O método considera como sendo *outlier* qualquer ponto cujo valor de altitude (coordenada Z) esteja fora de um intervalo predefinido. O intervalo de altitude é definido com base na média ($\bar{z}$) e desvio-padrão (σ_z) das altitudes, além de um valor arbitrado para o número de sigmas (n) que multiplica o desvio-padrão. Assim, a região de aceitação para a altitude dos pontos é definida por:

$$[\bar{z} - n \cdot \sigma_z ; \bar{z} + n \cdot \sigma_z] \quad (3.1)$$

Como se pretende fazer o uso das informações de intensidade dos pontos e, considerando que estas informações também estão sujeitas a medidas indesejadas causadas por diferentes fatores (KASHANI et al., 2015), o método de detecção de *outliers* foi adaptado para detectar pontos cujo valor de intensidade esteja fora do intervalo de aceitação definido pela média ($\bar{I}$) e desvio-padrão da intensidade (σ_I) para todo o conjunto. Porém, neste caso, o limite inferior do intervalo é zero, pois não há valores de intensidade negativos. Assim a Equação 3.1 toma a seguinte forma:

$$[0 ; \bar{I} + n \cdot \sigma_I] \quad (3.2)$$

Ainda, diferentemente do caso dos *outliers* de altitude, os pontos espúrios de intensidade (denominados aqui por pontos saturados por apresentarem valores de intensidade muito maiores que a média) não serão eliminados. Para estes pontos, o valor de intensidade será substituído pelo limiar $\bar{I} + n \cdot \sigma_I$ que corresponde ao limite superior do intervalo de aceitação. Este procedimento foi adotado para evitar que se perca uma quantidade significativa de pontos da nuvem.

3.3.2 Uso da intensidade e descritor geométrico 3D para detecção de árvores por meio do algoritmo K-médias.

Após a remoção dos pontos espúrios e modificação da intensidade dos pontos saturados, a próxima etapa consiste no cálculo do descritor 3D. Para isso, foi implementado um código computacional na linguagem *Python*. Inicialmente, a nuvem de pontos é armazenada na estrutura de dados denominada *Kd-Tree*, a qual permite trabalhar com os pontos da nuvem original mantendo-se as características dos dados de entrada e facilitar a busca por pontos vizinhos.

Primeiramente, foi executado o algoritmo K-médias utilizando como atributo o valor de intensidade, rotulando a nuvem em pontos candidatos a árvore e não-árvore. Essa estratégia baseou-se no estudo preliminar, descrito na Subseção 4.1, onde verificou-se que os pontos de árvores e de asfalto, principalmente, possuíam respostas de intensidade relativamente distintas dos pontos do terreno e de edificações.

Em seguida, em torno de cada ponto da nuvem que continha os candidatos a classe “árvore” foi definida uma vizinhança esférica de raio (r) fixo, cujos pontos vizinhos foram utilizados para calcular a Matriz de Variância-Covariância (MVC) das coordenadas. A função *numpy.cov* permitiu calcular a MVC tendo como parâmetro de entrada a matriz transposta das coordenadas normalizadas em relação ao valor mínimo de cada componente X , Y e Z para a vizinhança. Como resultado, obteve-se uma matriz quadrada onde cada elemento de sua diagonal principal correspondeu à variância das coordenadas dos pontos vizinhos. Vale ressaltar que o cálculo das covariâncias só é possível quando se tem mais de um ponto na vizinhança local e, por esse motivo, a MVC foi considerada nula nos casos em que não havia vizinhos próximos, ou em número suficiente, para um determinado ponto de interesse.

Assim, a partir da MVC da vizinhança local foi possível determinar seus autovalores por meio da Decomposição em Valores Singulares (SVD – *Singular Value Decomposition*). A implementação do cálculo utilizou a função *linalg.svd* do conjunto de funções para álgebra linear da biblioteca *Numpy*. A função retornou um conjunto de 3 matrizes, de forma que

$$U, S, V = \text{numpy.linalg.svd}(MVC) \quad (3.3)$$

onde S é uma matriz cujos elementos s_i correspondem aos valores singulares da MVC.

Então, os autovalores λ_1 , λ_2 e λ_3 de uma determinada vizinhança local foram calculados da seguinte forma:

$$\lambda_1 = s_0 * (s_0 + s_1 + s_2)^{-1} \quad (3.4)$$

$$\lambda_2 = s_1 * (s_0 + s_1 + s_2)^{-1} \quad (3.5)$$

$$\lambda_3 = s_2 * (s_0 + s_1 + s_2)^{-1} \quad (3.6)$$

Assim, utilizando as Equações 2.1 a 2.8, os descritores 3D foram calculados. No caso do método proposto, selecionou-se o descritor omnivariância para determinar a distribuição espacial dos pontos dentro da vizinhança. Os valores próximos a 0 representam regiões mais planas, enquanto valores mais próximos de 1 representam regiões mais irregulares (ex: árvores). A seleção do descritor, do tipo e tamanho de vizinhança (esférica ou cilíndrica) foi baseada em experimentos preliminares, como o apresentado nas Seções 4.2 e 4.3.

Por fim, o algoritmo K-médias foi aplicado novamente adotando como atributo de entrada, desta vez, os valores de omnivariância calculados para os pontos candidatos à árvore. Assim, os pontos das regiões mais irregulares (valores próximos a 1) foram mantidos na nuvem, enquanto as regiões mais planas (valores próximos a 0) foram incluídas na classe de “não-árvore”. A escolha do classificador K-médias se deu pelo fato de ser amplamente aplicado devido a sua facilidade de implementação e robustez (JOHNSON; WICHERN, 2007b), além de não necessitar de dados de treinamento. O algoritmo foi implementado com base na biblioteca *sklearn* do *Python* (<https://scikit-learn.org/stable/>), onde se utilizou a função *KMeans*, assumindo o número de classes como sendo 2 ($n_clusters = 2$).

3.3.3 Refinamento da detecção de árvores baseado no conceito de morfologia matemática


Após detectar os pontos de árvores usando a intensidade e omnivariância, notou-se que no resultado ainda havia pontos que não eram de interesse, tais como pontos individuais esparsos, agrupamentos pequenos que não poderiam constituir uma árvore e pontos sobre bordas de edificações ou linhas de transmissão de energia. Por isso, foi executada uma etapa de refinamento do resultado baseada em operações morfológicas com o intuito de remover esses pontos indesejados.

Inicialmente, foi criado uma grade regular a partir das coordenadas planimétricas X e Y dos pontos de forma a abranger toda a extensão da nuvem. O centro de cada célula da grade serviu como base para determinar se ele continha ou não pontos de árvores por meio de uma busca por vizinhos considerando uma vizinhança de raio igual a 0,5 m (mesmo tamanho da célula da grade). Vale ressaltar que o tamanho da célula influencia diretamente na resolução da imagem binária. No

caso deste trabalho, o tamanho escolhido levou em consideração o espaçamento médio entre os pontos da nuvem, que era de aproximadamente 0,4 m.

Pelo fato de haver apenas duas classes de interesse, determinou-se uma grade binária (imagem binária), atribuindo 1 para células de árvores e 0 para células vazias. Então, a etapa de refinamento da detecção consistiu em aplicar a operação morfológica de abertura em toda a imagem binária. Conceitualmente, o processo de abertura é composto por uma erosão seguida de dilatação que permite remover pequenos elementos presentes nas imagens e suavizar os restantes. Quanto ao elemento estruturante, foi definido o formato circular (disco) cujo tamanho do raio levou em consideração o tamanho aproximado das copas de uma árvore média presente nas áreas de estudo. Neste caso, o tamanho do EE foi 2 pixels, de acordo com os experimentos descritos na Seção 4.5, o que significa considerar um raio de 1 m na imagem cujo pixel é de 0,5 m. Após a abertura morfológica, a imagem resultante foi subtraída da imagem de entrada, obtendo-se uma imagem binária refinada (Figura 3.5).

Figura 3.5 - Exemplo da aplicação da abertura morfológica em uma imagem binária contendo pontos de árvores (pixels brancos) e pontos de “não-árvore” (pixels pretos). Imagem antes (a) e após o refinamento por MM (b).



Fonte: O Autor (2023).

A implementação da morfologia matemática foi realizada por meio das funções presentes na biblioteca de processamento de imagens em *Python*, a *Scikit-Image* (<https://scikit-image.org/>). Os parâmetros de entrada para a função *morphology.opening* foram a imagem binária e o EE (*disk*), que por sua vez, utilizou como parâmetro o tamanho de raio do disco (*disk_size*).

Por fim, a partir da imagem refinada, foi executado um processo inverso para reconstrução da nuvem de pontos. Os pontos cuja posição se encontrava dentro de uma célula de valor 1 foram mantidos na classe “árvore”, ao passo que os pontos que

se encontravam dentro de uma célula nula foram atribuídos à classe “não-árvore”. Dessa forma, obteve-se uma nuvem de pontos refinada contendo apenas os pontos de árvore de interesse.

3.3.4 Agrupamento dos indivíduos e conglomerados arbóreos

Além da detecção dos pontos de árvores, o método proposto também buscou segmentar a nuvem de pontos para obter os agrupamentos das árvores individualmente ou em conjunto, denominado aqui de conglomerados, nos casos em que a separação das árvores era mais complexa devido à proximidade entre elas. A abordagem utilizada foi o algoritmo de crescimento de regiões a partir de pontos semente selecionados em função da altura.

Conforme descrito na Seção 2.5, o processo iniciou com o conjunto de pontos de árvores (E) como dados de entrada e com a definição pelo usuário dos limiares de agrupamento d_{XY} e d_Z . Em algumas iterações, o algoritmo gerou agrupamentos pequenos que não eram de interesse para a tarefa de detecção de árvores. Por isso, foi definido também um limiar de tamanho mínimo para que os grupos que contivessem menos de T_{n_pontos} pontos fossem removidos.

3.3.5 Análise da qualidade

A análise da qualidade da detecção foi realizada por meio de duas abordagens: ponto a ponto e por objeto. Na análise ponto a ponto, cada ponto da classe “árvore” foi comparado com o seu correspondente que pertencia aos dados de referência e calculou-se os parâmetros de qualidade completeza, nível de acerto e F -score, conforme as Equações 2.9, 2.10 e 2.11. A correspondência entre o ponto detectado e o de referência foi estabelecida usando um limiar de proximidade definido como p definido de acordo com a densidade de pontos da nuvem (definiu-se $p = 0,5 m$).

No caso da análise por objeto, foram considerados os agrupamentos criados na etapa de segmentação. O resultado foi considerado válido quando o conjunto de pontos do agrupamento detectado sobrepunha a uma área da referência, numa proporção igual ou maior a um valor predefinido. Primeiramente, a nuvem de referência foi transformada em uma grade com espaçamento regular para facilitar e otimizar a análise e o nível de sobreposição foi calculado em função da quantidade de células comuns entre os dados e o número total de células presente na referência. O

agrupamento era considerado TP se a porcentagem de sobreposição fosse maior que o limiar s , caso contrário, o agrupamento foi considerado como FP ou FN. O valor de s é expresso entre 0 e 1, onde 0 significa uma sobreposição de 0% e 1 significa 100% de sobreposição mínima. Neste caso, foi definido um limiar 50% ($s = 0,5$).

3.3.6 Parâmetros envolvidos no método proposto

O Quadro 3.3 sintetiza as variáveis envolvidas na execução do método proposto, apresentando o nome, símbolo, descrição e como foi definido cada um. Pode-se notar que os dois últimos parâmetros não são usados exatamente no método proposto, mas sim no processo de avaliação da qualidade.

Quadro 3.3 - Síntese das variáveis envolvidas no método proposto.

Nome	Símbolo	Definição	Descrição
Número de sigmas	n	Multiplicador do desvio-padrão (sigma) dos valores de altitude ou intensidade	Está relacionado com a probabilidade estatística dos dados. Quanto maior o valor, maior será o conjunto de pontos considerados como <i>inliers</i> .
Raio da vizinhança	r	Tamanho do raio da vizinhança do tipo esférica	Está relacionado com o diâmetro da menor árvore que se pretende detectar.
Número de classes	$n_{clusters}$	Número de classes (<i>clusters</i>) que o algoritmo K-médias irá criar	Depende de quais tipos diferentes de objeto se pretende classificar. Ex.: árvore e não-árvore.
Tamanho da grade	$grid_size$	Tamanho da célula/pixel que terá a imagem binária para aplicação do filtro morfológico	Está relacionado com o espaçamento médio entre os pontos da nuvem
Tamanho do EE	$disk_size$	Tamanho do raio do disco que será o elemento estruturante do filtro morfológico	Considera o tamanho mínimo da copa de uma árvore de interesse e está relacionado com o tamanho da grade
Limiar planimétrico	d_{xy}	Limiar planimétrico de agrupamento de pontos para o crescimento de regiões	Está relacionado com o espaçamento médio da nuvem e a separação mínima em planimetria entre dois indivíduos
Limiar altimétrico	d_z	Limiar altimétrico de agrupamento de pontos para o crescimento de regiões	Está relacionado com a precisão da nuvem em termos altimétrico e com a mínima separação entre dois indivíduos em termos de diferença de altura
Tamanho mínimo do agrupamento	T_{n_pontos}	Limiar que define o número mínimo de pontos que deve formar um agrupamento	De acordo com a densidade de pontos da nuvem, irá definir o tamanho do menor objeto segmentado

Fonte: O Autor (2023).

4 RESULTADOS E DISCUSSÕES

Com o objetivo de avaliar o método proposto foram realizados seis experimentos, como descritos na sequência. O Experimento I avalia a aplicabilidade da intensidade na detecção de árvore em dados LiDAR. O Experimento II busca avaliar o potencial dos descritores baseados nos autovalores, enquanto o Experimento III busca obter informações a respeito da influência do tipo de vizinhança nos resultados de detecção. O Experimento IV permite avaliar o impacto do tamanho da vizinhança nos resultados de classificação, enquanto o Experimento V busca determinar a influência do tipo e tamanho do EE na aplicação da morfologia matemática para refinar a detecção de árvores. Por fim, o Experimento VI vai avaliar a performance do método proposto nas três áreas de estudos selecionadas (A1, A2 e A3).


Para o desenvolvimento dos experimentos iniciais (I ao V) foi selecionada a Área 1 (Figura 3.2), um recorte da nuvem de pontos do *dataset* de Presidente Prudente/Brasil que corresponde a uma parte do *campus* da FCT Unesp e possui dimensões da ordem de 200 m por 138 m (totalizando 27.622 m²). Esta região possui objetos artificiais e naturais com característica variadas que permitem realizar análises mais detalhadas dos experimentos.

4.1 Experimento I: Detecção de árvores usando a intensidade

Este experimento foi realizado primeiramente com base em análises visuais da nuvem de pontos e da imagem de intensidade correspondente. Em seguida, foi aplicado o algoritmo K-médias utilizando como atributo apenas a intensidade dos pontos para a separação em duas classes: potenciais pontos de árvore e não-árvore.

Na Figura 4.1, é mostrada a nuvem de pontos LiDAR da área de estudo colorida com uma escala de cinza (a) e com uma escala de cores arbitrada (b). É possível notar que os tons mais escuros estão associados aos pontos localizados em árvores e ruas asfaltadas, além das áreas de oclusão (sombras) onde não se tem dados. Em contrapartida, os pontos mais claros são gerados principalmente pelos pontos localizados no terreno (gramado ou não), calçadas e telhados de edificações. Dessa forma, é intuitivo supor que a intensidade pode ser considerada para auxiliar no processo de classificação dos pontos de vegetação.

Figura 4.1 - Visualização da nuvem de pontos da área de estudo com base na intensidade. Em (a) é mostrada apenas a informação de intensidade e em (b) a mesma informação, mas mostrada numa escala de cores diferente.




Fonte: O Autor (2023).

Entretanto, é possível notar a presença de pontos cujo valor de intensidade estava muito maior que a média para a região próxima a ele, como pode-se ver nos pontos destacados por uma circunferência na Figura 4.1. Isso pode ter ocorrido devido a fatores como possíveis mudanças no ângulo de incidência em relação à normal da superfície no ponto e sua vizinhança, e mudança no do tipo de material que compõe o objeto analisado. De acordo com Jutzi e Gross (2009), uma superfície orientada para o sistema de sensores gera uma resposta de intensidade maior que uma superfície que não esteja orientada diretamente para o sistema. Ademais, ainda de acordo com esses autores, as condições atmosféricas mudam sutilmente enquanto as medidas de intensidade estão sendo realizadas (no caso de um SVLA) e mudam consideravelmente nos casos de dados multi-temporais. Então, antes de realizar a classificação dos pontos usando o algoritmo K-médias, realizou-se a eliminação de valores saturados de intensidade, considerando um valor de $n = 4$ (4 sigmas) (Equação 3.2), seguida da normalização dos valores de intensidade.

Adicionalmente, realizou-se uma avaliação quantitativa da classificação comparando os resultados da classificação com os dados de referência (Figura 3.3), onde foram calculados os indicadores de qualidade comumente adotados em trabalhos do mesmo escopo, conforme as Equações 2.9, 2.10 e 2.11.

Ao analisar visualmente a aplicação do atributo intensidade (Figura 4.2), é possível notar que a maioria dos pontos de árvore foram classificados corretamente pelo algoritmo K-médias. Porém, como era esperado, as respostas geradas pelos pontos de árvore foram semelhantes às do asfalto, o que provocou a inserção desses elementos na mesma classe. Com relação aos parâmetros de qualidade, os resultados são apresentados na Tabela 4.1.

Figura 4.2 - Resultados da aplicação do K-Médias usando a intensidade (a) em comparação com o dado de referência (b) (vista superior da nuvem 3D).



Fonte: O Autor (2023).

Tabela 4.1 - Parâmetros de qualidade da classificação utilizando a intensidade.

	Completeza (%)	Nível de acerto (%)	F-score (%)
Intensidade	98,93	50,76	67,10

Fonte: O Autor (2023).

Nota-se que a completeza foi expressivamente maior que o nível de acerto, uma vez que a ocorrência de FN foi baixa, ou seja, quase todos os pontos de árvores presentes na referência foram detectados. No entanto, devido à resposta semelhante com ruas asfaltadas e outros objetos o número de falsos positivos (FP) foi elevado e consequentemente, o nível de acerto foi afetado. Como consequência, o parâmetro da qualidade geral *F-score* foi relativamente baixo.

4.2 Experimento II: Seleção dos atributos geométricos por meio de análise visual


Para o cálculo dos atributos, foram consideradas as definições de vizinhança esférica e cilíndrica de raios (r) constantes por não necessitarem de operações

prévias para determinar as características da região local de cada ponto da nuvem. Os descritores E_λ , E_h , A_λ , C_λ , L_λ , P_λ e O_λ , citados na Seção 2.3.1 e o desvio-padrão da altura (σ_h), foram calculados para os dois tipos de vizinhança adotando-se um raio $r = 1,0 m$. Este raio foi escolhido de forma empírica após a análise visual de alguns resultados obtidos com os descritores (ver Seção 4.4), bem como pelo que foi indicado em (DOS SANTOS et al., 2020, 2021). Assim, as análises visuais foram pautadas no comportamento dos valores dos descritores nas regiões de árvores.

A Figura 4.3 mostra os resultados dos descritores para a área de estudo selecionada. Ao comparar visualmente as imagens dos descritores, nota-se que alguns sofrem mais influência da vizinhança que outros. Por exemplo, tanto a entropia dos autovalores quanto a entropia das alturas fornecem resultados bem divergentes quando se altera o tipo de vizinhança. No caso da vizinhança esférica, o descritor consegue detectar pequenas variações de entropia dos objetos pelo fato da vizinhança ser menor e possuir menos pontos que a vizinhança cilíndrica. Dessa forma, os valores mais altos de entropia se distribuíram por toda a área, o que acabou limitando as diferenças entre objetos mais regulares da área e objetos mais irregulares como a copa das árvores.

No caso do uso da vizinhança cilíndrica, onde o intervalo das alturas dos pontos dentro do cilindro é maior, o descritor baseado na entropia mostrou uma maior amplitude de valores. Assim, de modo geral, a definição de um cilindro como vizinhança favoreceu a detecção de árvores, linhas de transmissão e bordas. Essa característica, foi verificada também nos resultados dos descritores linearidade e planaridade, onde ocorreu uma maior discriminação desses objetos em relação aos demais presentes na área. No entanto, isso não se manteve em outros descritores como a anisotropia, curvatura, esfericidade e omnivariância. Para estes casos, o uso da vizinhança cilíndrica não contribuiu para o realce da vegetação sobre outros elementos da cena. Particularmente, a diferença entre os resultados obtidos com o desvio-padrão das alturas para os dois tipos de vizinhança foi menos acentuada que nos demais descritores, porém, verifica-se que a utilização do cilindro tornou mais evidente as regiões de bordas de edificações, uma vez que em uma única vizinhança pode haver pontos localizados no terreno e pontos localizados nas copas das árvores e beirais das edificações.

Figura 4.3 - Mapa dos atributos considerando diferentes descritores geométricos e vizinhanças.




Fonte: O Autor (2023).

Em geral, a vizinhança cilíndrica tende a ser mais heterogênea quanto ao comportamento dos pontos vizinhos e às suas relações geométricas. Isso implicou numa maior capacidade de discriminação de objetos uniformes e não uniformes por parte dos descritores que exploram essa característica, tais como as entropias dos autovalores e da altura, linearidade, planaridade e desvio-padrão da altura.


Com relação às tarefas de detectar e reconhecer as árvores presentes em uma nuvem de pontos LiDAR, verificou-se a potencial capacidade de discriminação por parte dos descritores planaridade e entropia dos autovalores numa região cilíndrica, bem como da curvatura e omnivariância numa região esférica. Neste último caso, a omnivariância aparentemente se destaca entre os demais por conseguir distinguir melhor as copas das árvores das bordas de edificações e das linhas de transmissão (Figura 4.4). Na Figura 4.5 é apresentado o histograma para omnivariância e curvatura usando uma vizinhança esférica, bem como para os atributos entropia dos autovalores e planaridade considerando uma vizinhança cilíndrica. Visualmente é possível notar que o histograma de frequência da omnivariância tem comportamento próximo ao de duas modas (bimodal) relativamente distantes, que pode ser interessante para qualquer classificador que utilize medidas de similaridade.

Figura 4.4 – Comparação visual entre os resultados dos descritores omnivariância (a), curvatura (b), entropia dos autovalores (c) e planaridade (d).



Fonte: O Autor (2023).

Figura 4.5 - Histograma dos valores de omnivariância e curvatura para uma vizinhança esférica, e entropia dos autovalores e planaridade para uma vizinhança cilíndrica.




Fonte: O Autor (2023).

4.3 Experimento III: Impacto do tipo de vizinhança e atributos geométricos na detecção de árvores

Após executar o algoritmo K-médias para cada um dos quatro casos citados no Experimento II (omnivariância, curvatura, entropia dos autovalores e planaridade), obteve-se uma nuvem de pontos classificada em duas classes, uma contendo os pontos candidatos e não candidatos à árvore (Figura 4.6). Os valores de omnivariância (A) e curvatura (B) foram calculados considerando uma vizinhança esférica, e entropia dos autovalores (C) e a linearidade (D) para uma vizinhança cilíndrica. Em verde estão representados os pontos da classe árvore e em cinza claro os pontos da classe “não-árvore”. Nas Figuras 4.6a e 4.6b, o retângulo preto traçado na diagonal destaca uma região contendo linha de transmissão.

Figura 4.6 - Resultados da aplicação do algoritmo K-Médias usando a omnivariância (a), curvatura (b), entropia dos autovalores (c) e planaridade (d) (vista superior da nuvem 3D).



Fonte: O Autor (2023).

Uma característica em comum entre as quatro classificações baseadas nos elementos geométricos é a confusão entre as árvores e as bordas de edificações ou linhas de transmissão. Isso ocorre provavelmente devido ao padrão desordenado dos pontos que fazem parte da vizinhança destes locais, principalmente em função da coordenada Z (altura), onde há diferenças entre os pontos no topo de um telhado e

no chão, por exemplo. Entretanto, é possível observar que a presença das bordas é menor quando os descritores omnivariância e curvatura são adotados como atributos, em virtude da seleção da vizinhança do tipo esférica, como já apontado anteriormente.

Outra característica notada, é que as copas das árvores estão aparentemente mais definidas nos casos em que os descritores $O_{\lambda_{esfera}}$ e $E_{\lambda_{cilindro}}$ são utilizados. No entanto, no segundo caso as linhas de transmissão presentes na área (localizadas na diagonal noroeste-sudeste da figura) foram consideradas como um grande aglomerado de árvores, o que não ocorreu com o uso da omnivariância. No caso da curvatura, verificou-se que houve uma menor confusão da vegetação com as regiões de bordas, porém uma grande quantidade de pontos no interior das copas foi erroneamente atribuída à classe “não-árvore”, o que prejudicaria uma possível etapa posterior de delimitação das árvores individuais.

Ao comparar os resultados das classificações com os dados de referência (Figura 3.3), foi possível estimar os índices de qualidade completeza, nível de acerto e *F-score*, como mostra a Tabela 4.2.

Tabela 4.2 - Parâmetros de qualidade da classificação utilizando atributos diferentes.

	Completeza (%)	Nível de acerto (%)	<i>F-score</i> (%)
$O_{\lambda_{esfera}}$	92,47	73,48	81,89
$C_{\lambda_{esfera}}$	67,14	88,24	76,25
$E_{\lambda_{cilindro}}$	92,39	54,98	68,94
$P_{\lambda_{cilindro}}$	99,19	45,59	62,46

Fonte: O Autor (2023).

Ao comparar os parâmetros de qualidade apresentados, nota-se que os valores de completeza foram mais altos que os de nível de acerto. Isso ocorreu porque o número de falsos negativos (pontos erroneamente classificados como “não-árvore”) foram poucos em relação aos verdadeiros positivos (pontos que são de árvore e foram classificados como tal), indicando assim que os atributos adotados têm boa capacidade de atribuir os pontos de árvore à sua classe correta e podem ser considerados confiáveis para detectar esse tipo de feição. Verificou-se que o atributo planaridade (vizinhança cilíndrica) forneceu o melhor resultado em termos de completeza, sendo próximo a 99%, indicando que grande parte dos pontos supostamente localizados em árvores foram classificados corretamente.

No caso do nível de acerto, em geral, os resultados foram menos satisfatórios para os atributos entropia dos autovalores e planaridade, uma vez que os números de

falsos positivos (pontos classificados como árvore, mas que pertencem à classe “não-árvore”) foram expressivos. Já os atributos omnivariância e curvatura apresentaram resultados melhores, sendo acima dos 70%. Isso mostra que estes dois descritores possuem um grau de sensibilidade para detectar árvores maior que os demais. Esses resultados refletiram positivamente no parâmetro *F-score*, o qual representa a acurácia geral da classificação, sendo de 81,89% para a omnivariância e 76,25% para a curvatura.

A partir das análises realizadas, pôde-se notar que a seleção da vizinhança é um fator importante a ser considerado no cálculo dos atributos que caracterizem localmente uma região utilizando dados LiDAR. Além do tipo de vizinhança, o valor do raio de busca de pontos vizinhos (para o cilindro e esfera) também é um fator relevante para o reconhecimento de objetos (DEMANTKÉ et al., 2012; WEINMANN; JUTZI; MALLET, 2014) e que vizinhanças de tamanhos diferentes influenciam nos parâmetros de qualidade nível de acerto e completeza da classificação dos pontos (BLOMLEY et al., 2014). Por isso, o Experimento IV descrito na sequência trata desse tema.

Adicionalmente, foi possível determinar que o tipo de descritor 3D também afeta a tarefa de detecção de árvores em dados LiDAR, uma vez que alguns performaram melhor em relação a outros, considerando o mesmo tipo de vizinhança. Por fim, a omnivariância calculada em uma vizinhança do tipo esférica foi capaz de detectar melhor os pontos de árvores.

4.4 Experimento IV: Impacto do tamanho da vizinhança e da densidade de amostragem na detecção de árvores

Este experimento tem a finalidade de aprofundar a análise sobre a influência da vizinhança nos resultados de detecção de árvores, especificamente no que concerne à dimensão e quantidade de pontos vizinhos no seu interior. O procedimento adotado foi similar ao do Experimento III (seção 4.3), mas desta vez o descritor 3D considerado foi apenas a omnivariância calculada para vizinhança do tipo esférica. Além disso, como a densidade de pontos da nuvem afeta na quantidade de vizinhos para o cálculo do descritor, as análises também consideraram três níveis de densidade diferentes: 3 pontos/m² (D3), 6 pontos/m² (D6) e 12 pontos/m² (D12). As menores densidades foram simuladas por meio de uma sub-reamostragem da nuvem

LiDAR original cuja densidade média é de 12,5 pontos/m². Esta operação foi feita usando o *software CloudCompare*.

Dessa forma, foram realizadas uma série de classificações para esferas de raios variados e para cada um dos três conjunto de pontos de densidades diferentes. A partir da comparação ponto a ponto com os dados de referência, foram obtidos os parâmetros de qualidade que estão presentes na Tabelas 4.3 a 4.5.

Tabela 4.3 - Parâmetros de qualidade das classificações usando a omnivariância calculada em vizinhança esférica com raios variados para os dados com densidade da ordem de 3 pontos/m².

Densidade: 3 pontos/m ² (D3)											
Raio da esfera (m)	0,25	0,50	0,75	1,0	1,25	1,50	1,75	2,0	2,25	2,50	3,0
Completeza (%)	0	0,32	10,95	34,51	56,60	68,55	75,17	78,55	80,63	82,03	83,35
Nível de acerto (%)	0	58,52	84,66	94,48	95,27	94,72	93,82	92,68	91,84	90,83	89,14
F-score (%)	0	0,65	19,39	50,55	71,01	79,54	83,46	85,03	85,87	86,21	86,15

Fonte: O Autor (2023).

Tabela 4.4 - Parâmetros de qualidade das classificações usando a omnivariância calculada em vizinhança esférica com raios variados para os dados com densidade da ordem de 6 pontos/m².

Densidade: 6 pontos/m ² (D6)											
Raio da esfera (m)	0,25	0,50	0,75	1,0	1,25	1,50	1,75	2,0	2,25	2,50	3,0
Completeza (%)	0	5,75	34,93	60,38	73,35	81,99	86,56	88,92	90,40	91,35	91,86
Nível de acerto (%)	0	61,67	88,34	90,76	89,90	88,76	87,43	86,10	84,90	83,41	81,29
F-score (%)	0	10,52	50,06	72,52	80,79	85,24	86,99	87,49	87,56	87,20	86,25

Fonte: O Autor (2023).

Tabela 4.5 - Parâmetros de qualidade das classificações usando a omnivariância calculada em vizinhança esférica com raios variados para os dados com densidade da ordem de 12 pontos/m².

Densidade: 12 pontos/m ² (D12)											
Raio da esfera (m)	0,25	0,50	0,75	1,0	1,25	1,50	1,75	2,0	2,25	2,50	3,0
Completeza (%)	1,19	47,08	80,95	91,08	95,13	96,77	97,59	97,98	98,27	98,16	98,17
Nível de acerto (%)	53,11	86,69	89,59	86,73	83,37	80,69	78,45	76,56	73,54	75,10	71,06
F-score (%)	2,33	61,02	85,05	88,86	88,85	88,00	86,98	85,96	84,12	85,10	82,45

Fonte: O Autor (2023).


Após análise dos valores apresentados nas tabelas, nota-se que o parâmetro *F-score* que mede a qualidade geral da classificação foi mais alto para os casos em

que a densidade de pontos era maior, sendo em média de 76,25% para a densidade D12 (12 pontos/m²), contra 66,78% para D6 e 58,89% para D3. A completeza também apresentou um comportamento semelhante, sendo a média para D12 maior em relação às médias para D6 e D3 (82,03%, 64,14% e 51,88%, respectivamente). Em contrapartida, a média dos valores de nível de acerto foi maior para o caso D3 (80,54%) embora as médias para os outros casos tenham sido próximas (76,60% e 77,72%, respectivamente).

Outra informação importante se refere ao comportamento dos parâmetros ao passo que o tamanho da vizinhança esférica é modificado. No caso da completeza, os valores iniciaram em 0 ou próximo de 0 para a esfera de raio 0,25 m e foram aumentando conforme o tamanho do raio também aumentou, chegando às pontuações máximas quando o raio da esfera atingiu os 3 m. Com relação aos parâmetros nível de acerto e *F-score*, o comportamento de tendência se repetiu até atingir um máximo e depois passou a decair conforme o raio da vizinhança aumentou. Para os dados de D3, o valor máximo de nível de acerto (95,27%) foi obtido quando o raio foi igual a 1,25 m e depois decaiu para um valor abaixo de 90%; para o caso D6 o máximo (90,76%) ocorreu quando o raio foi igual a 1,0 m e passou a diminuir até pouco mais de 80%; e para o caso D12 o nível de acerto chegou a 88,86% quando o raio foi igual a 0,75 m e passou a decair até 71% quando o raio chegou aos 3 m. Tais comportamentos podem ser visualizados nos gráficos da Figura 4.7, para as três densidades

Os gráficos apresentados na Figura 4.7 permitem notar que os três parâmetros tendem a convergir para um valor próximo entre eles e, no caso das densidades D6 e D12, os valores passam a divergirem a partir de um certo ponto de inflexão localizado entre os raios de 1,0 e 1,75 m. Da mesma maneira, é possível inferir que este comportamento se repetiria para a densidade D3 caso o tamanho do raio fosse aumentado além dos 3,0 m que este estudo se limitou a considerar.

Figura 4.7 - Gráficos dos parâmetros de qualidade da classificação considerando tamanhos de raio diferentes da vizinhança. Em (a) são apresentados os resultados de D3; em (b) de D6; e em (c) de D12.



Fonte: O Autor (2023).

Logo, os dados apresentados nos diferentes casos sugerem que o tamanho da vizinhança pode favorecer ou prejudicar a tarefa de classificação de árvores a partir de nuvens de ponto LiDAR. Conforme a densidade de pontos aumenta, mais vizinhos podem ser encontrados para um determinado ponto de interesse e, então, o descritor 3D performará melhor. Além disso, a densidade de pontos está relacionada com o nível de detalhamento dos objetos presentes na área de estudo, principalmente das árvores que são feições que tendem a possuir uma forma mais complexa que edificações, ruas e linhas de transmissão de energia, por exemplo. Isso contribuiu para uma melhor definição das diferenças geométrica de cada objeto a ser detectado.

Com relação ao tamanho do raio da vizinhança, nota-se que há um limite de valor mais adequado para a detecção de árvores usando a omnivariância. Provavelmente, isso se deve ao fato de que o aumento da esfera fez com que um número maior de pontos de bordas de edificações, de copas das árvores, assim como de linhas de transmissão, fosse incluído. Assim, o classificador teve dificuldade de separar esses elementos que tiveram valores de omnivariância próximos, como visto anteriormente no Experimento III.

Portanto, considerando os dados de maior densidade de pontos (D12), o parâmetro de *F-score* mais alto obtido ocorreu quando o raio adotado foi igual a 1,0 m. Ainda, mesmo com os valores de completeza aumentando conforme a expansão da vizinhança para raios maiores que 1 m o nível de acerto diminuiu e prejudicou a qualidade geral da classificação. Deste modo, optou-se pela adoção do raio $r = 1$ m.

4.5 Experimento V: Impacto do tipo e tamanho do elemento estruturante

Como apresentado no método proposto, a aplicação de filtros morfológicos foi realizada para refinar o resultado da detecção de pontos de árvores. Logo, este estudo buscou determinar por meio de testes qual seria o elemento estruturante (EE) mais adequado para se obter um resultado desejável. Para isso, foi usada a nuvem de pontos classificada a partir da omnivariância, apresentada na Seção 4.3. Foram considerados dois tipos de EE: quadrado (com dimensões de lado variados) e disco (com dimensões de diâmetro variadas).

Como se sabe, a abertura morfológica tem como efeito a eliminação de pequenos elementos na imagem bem como a suavização de elementos maiores restantes. Por esse motivo, este filtro morfológico pode ser adequado para a eliminação de pontos isolados ou pequenos aglomerados que foram erroneamente

classificados como pontos de árvore. Logo, este experimento foi executado a partir da aplicação do filtro de abertura na imagem binária gerada com a nuvem de pontos de árvores. As Tabelas 4.6 e 4.7 apresentam os parâmetros de qualidade da classificação calculados para os dois tipos de EE e suas variações de tamanho (em pixels), considerando uma imagem com pixel de 0,5 m.

Tabela 4.6 - Parâmetros de qualidade da classificação após aplicação do filtro de abertura morfológica considerando um disco de tamanho variado como EE.

EE: Disco					
Tamanho (pixels)	1,0	2,0	3,0	4,0	5,0
Completeza (%)	89,50	89,08	87,27	83,92	78,83
Nível de acerto (%)	91,43	93,31	94,99	96,23	96,85
<i>F-score</i> (%)	90,45	91,15	90,97	89,65	86,91

Fonte: O Autor (2023).

Tabela 4.7 - Parâmetros de qualidade da classificação após aplicação do filtro de abertura morfológica considerando um quadrado de tamanho variado como EE.

EE: Quadrado					
Tamanho (pixels)	1,0	2,0	3,0	4,0	5,0
Completeza (%)	79,33	89,69	86,27	81,58	75,51
Nível de acerto (%)	92,49	84,13	89,80	91,83	93,58
<i>F-score</i> (%)	85,41	86,82	88,00	86,40	83,58

Fonte: O Autor (2023).

Ao analisar as tabelas, nota-se que o EE na forma de disco em geral promoveu parâmetros de qualidade melhores que o EE quadrado, especialmente os de nível de acerto e *F-score*. No primeiro, o nível de acerto variou entre 91,43% e 96,85% enquanto para o segundo caso o nível de acerto variou entre 89,90 e 93,58%. Com relação ao *F-score*, a maior pontuação ocorreu com o uso do disco de raio igual a 2,0 pixels (o equivalente a um raio de 1 m) e a menor ocorreu com o quadrado de lado igual a 5,0 pixels (equivalente a 2,5 m).


Em ambos os casos, é possível notar que a qualidade da classificação foi alterada à medida que o tamanho do EE variou. Para o parâmetro nível de acerto, quanto maior foi o EE, melhores foram os resultados. Em contrapartida, os parâmetros de completeza e *F-score* passaram a ter valores mais baixos conforme o tamanho do EE aumentou. Isso sugere que o filtro de abertura morfológica contribuiu para eliminação de alguns falsos positivos (pontos que foram classificados como sendo de árvores, mas não eram), aumentando o nível de acerto. Porém, a partir de um

determinado ponto, a expansão do EE causou ao mesmo tempo a eliminação de pontos de árvores refletindo negativamente nos índices de completeza e *F-score*.

Se tratando de filtros que são aplicados em uma imagem, o tamanho do EE consiste no número de pixels que serão considerados a partir do pixel central de interesse. Dessa forma, considerando a resolução da imagem binária de 0,5 m, um EE disco de raio igual a 2 teria um tamanho de 1 m e diâmetro de 2 m, o que pode ser interpretado como a definição de um tamanho mínimo para as árvores a serem detectadas. Logo, um grupo de pontos que supostamente eram de árvores foi eliminado se a área de cobertura fosse inferior aos 2 m de diâmetro.

Como forma de ilustrar, a Figura 4.8 apresenta duas imagens binárias que mostram os pixels eliminados pelo filtro morfológico (Figura 4.8-a) e os pixels restantes (Figura 4.8-b) após a execução da abertura com EE disco de raio 2 pixels. Observando as imagens é notório que uma grande quantidade de pixels foi eliminada, principalmente os que estavam presentes em regiões de bordas de edificação e em vegetação rasteira ou árvores de pequeno porte (arbustos). No entanto, alguns pixels de borda das copas das árvores também acabaram sendo eliminados.

Figura 4.8 – Região destacada na área A1 (a) para ilustrar o resultado antes (b) e depois (c) da aplicação da MM na imagem binária.



Fonte: O Autor (2023).

4.6 Experimento VI: Aplicação do método proposto em diferentes áreas do conjunto de dados

Nesta seção são apresentados os resultados obtidos usando o método proposto e os conjuntos de dados referentes às áreas de estudo apresentadas na Seção 3.2. A etapa de pré-processamento para a detecção de pontos espúrios considerou um número de sigmas igual a 4, tanto para *outliers* de posição 3D quanto para intensidade.


No processamento para a detecção de árvores foi definida uma vizinhança do tipo esférica de raio igual a 1 m para o cálculo dos valores de omnivariância. Então, a classificação foi refinada por meio da aplicação de filtro morfológico de abertura, considerando um EE disco de raio 2 (correspondente a um raio de 1 m uma vez que a dimensão da grade é de 0,5 m), e uma distância planimétrica de 0,5 m.

Na etapa de segmentação das árvores, foram considerados os parâmetros de distância planimétrica igual a 0,8 m (duas vezes o espaçamento médio entre os pontos) e distância altimétrica igual a 4,0 m. Os resultados serão apresentados e discutidos para cada uma das três áreas de estudo.

4.6.1 Resultados para a área de estudo 1

Na Figura 4.9-a é apresentada uma imagem aérea da área A1, ao lado da vista superior da nuvem utilizada como referência da classificação (Figura 4.9-b). Na Figura 4.9-c é apresentada a vista da nuvem de pontos classificada com a intensidade e omnivariância e na Figura 4.9-d a nuvem de pontos de árvores segmentada, onde cada agrupamento é mostrado com uma cor diferente. As Figuras 4.9-e e 4.9-f apresentam, respectivamente, a nuvem original em tons de cinza e a sobreposição com a nuvem final classificada e segmentada.

Figura 4.9 – Imagem da região correspondente à área A1 (a). Em (b) são mostrados os dados referência (b); em (c) os resultados da detecção considerando intensidade e omnivariância; em (d) o resultado do agrupamento; em (e) é mostrada a imagem da nuvem original com intensidade em tons de cinza e; em (f) é mostrada a superposição das árvores detectadas.




Fonte: O Autor (2023).

Visualmente é possível notar que o método foi capaz de detectar boa parte das árvores presentes na área A1, principalmente as de maior porte e área de cobertura da copa. No entanto, alguns objetos causaram confusão no classificador que atribuiu à classe de árvores pontos presentes em bordas de edificações e carros, conforme destacado na Figura 4.10. Isso ocorreu provavelmente devido à variação acentuada na altitude dos pontos nessas regiões, o que resultou em valores elevados de omnivariância, semelhantemente ao que ocorre em regiões onde há presença de

árvores. Por exemplo, partes de dois telhados de edificação que continham claraboias em seu centro foram classificados como árvores, pelo fato de os pontos LiDAR terem ultrapassado o nível do telhado e chegado até o chão. Logo, na análise quantitativa dos níveis de erro e acerto da classificação, estes casos são considerados como sendo falsos positivos (FP).

Figura 4.10 - Exemplos de falsos positivos na área A1 obtidos com o método de detecção proposto.



Fonte: O Autor (2023).

No total, foram classificados 101.053 pontos (27%) como sendo de árvores na nuvem LiDAR da área A1. Com relação a segmentação da nuvem por crescimento de regiões, foram criados 452 agrupamentos, dentre os quais 264 foram excluídos pela etapa de refinamento. A alta incidência de pontos isolados ou regiões com grande variação de altura contribuiu para esta taxa de exclusão, pois os limiares de distância planimétrica e altimétrica usados no agrupamento foram de 0,8 m e 4 m, respectivamente.

Após a análise comparativa com dados de referência, foram contabilizados os parâmetros de qualidade completeza, nível de acerto e *F-score* da classificação (Tabela 4.8). Para auxiliar na visualização dos resultados, foi gerado um mapa de erros da classificação (ver Figura 4.11), onde nos pontos selecionado pelo algoritmo são coloridos conforme os dados de referência. Os pontos mostrados na cor verde representam os verdadeiros positivos (TP) (classificados corretamente) e as cores vermelho e azul representam os falsos negativos (FN) e positivos (FP), respectivamente. Olhando esta figura é possível notar que a ocorrência de falsos


positivos foi consideravelmente maior que a de falsos negativos, e que boa parte deles se concentram em regiões próximas de edificações.

Tabela 4.8 - Parâmetros de qualidade da classificação da área A1.

Parâmetro	Análise ponto a ponto	Análise por objeto
Completeza (%)	94,46	94,38
Nível de acerto (%)	90,94	71,49
<i>F-score</i> (%)	92,66	81,35

Fonte: O Autor (2023).

Figura 4.11 - Mapa de erro da detecção de árvores para a área A1 considerando a análise por objeto. Os pontos em verde representam os TP; em azul estão os FP; em vermelho os FN.



Fonte: O Autor (2023).

No caso da análise ponto a ponto, que considerou cada ponto da nuvem individualmente, o índice de completeza foi de 94,46%, pois a incidência de falsos positivos em relação aos verdadeiros foi baixa, o que sugere uma boa sensibilidade por parte do método em detectar pontos de árvores nessa região. Já o nível de acerto obtida foi de 90,94%, o que representa o nível de acerto do classificador em atribuir um ponto à sua classe correta. Neste caso, a alta incidência de falsos positivos causada pela confusão de árvores com regiões de bordas de edificações prejudicou a métrica. Com relação à qualidade geral, o *F-score* obtido pelo método foi de 92,66%.

No caso da análise em relação ao objeto (agrupamento de pontos de uma árvore individual ou conglomerado), o parâmetro de completeza foi similar ao da análise ponto a ponto, porém o nível de acerto e *F-score* obtidos sofreram redução, chegando a 71,49% e 81,35%, respectivamente. Mesmo assim, este fato representa

o mesmo comportamento apontado anteriormente, ou seja, de que o método conseguiu detectar com precisão as árvores presentes na área, porém o número de FP foi elevado em comparação aos TP e FN.

4.6.2 Resultados para a área de estudo 2

Na Figura 4.12 é apresentada uma sequência de imagens que resumem os resultados da detecção de árvores para a A2. A Figura 4.12-a mostra uma imagem de contextualização da área de estudo A2, ao lado da vista superior da nuvem utilizada como referência da classificação (Figura 4.12-b). Na Figura 4.12-c é apresentada a vista da nuvem de pontos classificada com a intensidade e omnivariância, e já na Figura 4.12-d a mesma nuvem após a etapa de pós-processamento de refinamento com a morfologia matemática. Por fim, na Figura 4.12-e está a vista da nuvem de pontos antes da classificação e na Figura 4.12-f está a superposição com as árvores detectadas e segmentadas, onde cada agrupamento é mostrado com uma cor.

Um total de 339.920 pontos foram detectados como sendo de árvores, o que corresponde a cerca de 45%. Como é possível notar visualmente, esta região contém uma grande quantidade de árvores de tamanhos variados que se aglomeram na maior parte dos casos. Há também a presença de edificações cujos telhados concorrem espaço com as copas das árvores, resultando em confusão entre as bordas desses elementos, como observado na Figura 4.12-c. No entanto, o processo de refinamento contribuiu para eliminar boa parte desses falsos positivos (Figura 4.12-d).


Após a etapa de crescimento de regiões, foram criados 463 agrupamentos de pontos contendo árvores individuais e conglomerados (Figura 4.12-f). Destes, 184 foram excluídos pelo procedimento de refinamento. Considerando os pontos restantes, foi realizada a análise de qualidade que comparou o resultado com o dado de referência (Figura 4.12-b) para calcular os parâmetros apresentados na Tabela 4.9.

Tabela 4.9 – Parâmetros de qualidade da classificação da área A2.

Parâmetro	Análise ponto a ponto	Análise por objeto
Completeza (%)	98,61	96,78
Nível de acerto (%)	96,19	92,90
<i>F-score</i> (%)	97,38	94,80

Fonte: O Autor (2023).


Figura 4.12 – Resultados da detecção de árvores para a área A2. Em (a) tem-se a imagem aérea da região; (b) contém a nuvem de pontos de referência; (c) e (d) contém a nuvem classificada e refinada, respectivamente; (e) contém a imagem da nuvem original com intensidade em tons de cinza e (f) contém a superposição das árvores detectadas na nuvem original.



Fonte: O Autor (2023).

Na Figura 4.13 é apresentado o mapa de erro da classificação da área A2, onde os pontos de TP, FP e FN são atribuídos para cores diferentes. Nota-se que o classificador conseguiu detectar uma quantidade significativa das árvores que estavam presentes na região. Além disso, pelo fato de haver poucas edificações e outros elementos artificiais como linhas de transmissão, os FP tiveram incidência baixa, não prejudicando tanto o indicador de nível de acerto mostrado na Tabela 4.9.

Figura 4.13 – Mapa de erro da detecção de árvores para a área A2. Os pontos em verde representam os TP; em azul os FP; em vermelho os FN.



Fonte: O Autor (2023).


Nota-se pela Tabela 4.9 que os parâmetros de qualidade obtidos com as análises ponto a ponto e por objeto foram próximos entre si, sendo superiores a 96% para a completeza, a 92% para nível de acerto e a 94% para o *F-score*.

4.6.3 Resultados para a área de estudo 3

Na Figura 4.14 é apresentada uma sequência de imagens que resumem os resultados da detecção de árvores para a área A3. A Figura 4.14-a mostra uma imagem de contextualização da área de estudo A3, ao lado da vista superior da nuvem utilizada como referência da classificação (Figura 4.14-b). Na Figura 4.14-c é apresentada a vista da nuvem de pontos classificada com a intensidade e

omnivariância, e já na Figura 4.14-d a mesma nuvem após a etapa de pós-processamento de refinamento com a morfologia matemática. Por fim, na Figura 4.14-e está a vista da nuvem de pontos antes da classificação e na Figura 4.14-f está a superposição com as árvores detectadas e segmentadas, onde cada agrupamento é mostrado com uma cor.

Figura 4.14 – Resultados da detecção de árvores para a área A3. Em (a) tem-se a imagem aérea da região; (b) contém a nuvem de pontos de referência; (c) e (d) contém a nuvem classificada e refinada, respectivamente; (e) contém a imagem da nuvem original com intensidade em tons de cinza e (f) contém a superposição das árvores detectadas na nuvem original.




Fonte: O Autor (2023).

Observa-se que nesta região há uma maior incidência de edificações que dividem espaço com as árvores. Por isso, a quantidade de pontos de borda de telhados confundidos pelo algoritmo K-médias foi maior nesta área (Figura 4.14-c).

Mesmo assim o filtro morfológico de abertura foi capaz de eliminar a maior parte dos falsos positivos (Figura 4.14-d). No total, 18.682 pontos (23%) de árvores foram detectados, dos quais deram origem à 67 agrupamentos contendo árvores individuais ou conglomerados. Destes, 15 agrupamentos foram excluídos no refinamento.

Após comparar com a nuvem de pontos de referência, pôde-se calcular os parâmetros de qualidade da classificação, os quais são apresentados na Tabela 4.10, bem como criar um mapa de erro representando os TP, FP e FN (Figura 4.15).

Figura 4.15 - Mapa de erro da detecção de árvores para a área A3. Os pontos em verde representam os TP; em azul os FP; em vermelho os FN.



Fonte: O Autor (2023).

Tabela 4.10 - Parâmetros de qualidade da classificação da área A3.

Parâmetro	Análise ponto a ponto	Análise por objeto
Completeza (%)	96,92	95,34
Nível de acerto (%)	89,42	74,54
<i>F-score</i> (%)	92,92	83,64

Fonte: O Autor (2023).

No geral, a classificação resultou numa pontuação de 92,92%. A completeza foi de 96,72%, enquanto o nível de acerto foi de 89,42%. Conforme ilustrado na Figura 4.15, a ocorrência de um número relativamente elevado de falsos positivos prejudicou na métrica que mede o nível de acerto do classificador. Isso se deve provavelmente a quantidade elevada de edificações, cujas bordas fornecem valores próximos aos das árvores, quando considerado o descritor da omnivariância.

4.7 Síntese dos resultados

Ao analisar os resultados da detecção de árvores nas três áreas de estudo, com base nas Tabelas 4.8 a 4.10, é possível notar que os níveis de completeza, embora próximos, foram mais altos que os de nível de acerto em todas as áreas de estudo. Isso sugere que boa parte das árvores presentes foram detectadas, mas que ainda houve confusão com alguns objetos, principalmente com bordas de algumas edificações. Os resultados da classificação da área A2 podem corroborar com esta afirmação, uma vez que naquela região havia uma quantidade menor de edificações próximas e o nível de acerto calculada foi a maior em comparação com as áreas A1 e A3. No caso das análises de qualidade por objeto, o mesmo fenômeno foi observado.

As Tabelas 4.11 e 4.12 apresentam uma síntese dos resultados, sendo apresentadas as médias dos parâmetros completeza, nível de acerto e *F-score* das três áreas de estudo, levando em consideração os dois tipos de análises de qualidade: ponto a ponto e por objeto.

Tabela 4.11 - Média dos parâmetros de qualidade obtidos para as três áreas de estudo mediante análise ponto a ponto.

Parâmetro	A1	A2	A3	Média
Completeza (%)	94,46	98,61	96,92	96,66
Nível de acerto (%)	90,94	96,19	89,42	92,18
<i>F-score</i> (%)	92,66	97,38	92,92	94,32

Fonte: O Autor (2023).

Tabela 4.12 - Média dos parâmetros de qualidade obtidos para as três áreas de estudo mediante análise por objeto.

Parâmetro	A1	A2	A3	Média
Completeza (%)	94,38	96,78	95,34	95,50
Nível de acerto (%)	71,49	92,9	74,54	79,64
<i>F-score</i> (%)	81,35	94,8	83,64	86,60

Fonte: O Autor (2023).

A Tabela 4.13 apresenta as médias dos parâmetros de qualidade obtidos com as análises ponto a ponto e por objeto, para cada área de estudo. Uma média geral do método também é apresentada.

Tabela 4.13 - Média dos parâmetros de qualidade obtidos para as três áreas de estudo.

Parâmetro	A1	A2	A3	Média Geral
Completeza (%)	94,42	97,70	96,13	96,08
Nível de acerto (%)	81,22	94,55	81,98	85,92
<i>F-score</i> (%)	87,01	96,09	88,28	90,46

Fonte: O Autor (2023).

No geral, a metodologia proposta de detecção de árvores resultou em um *F-score* de 90,46%, uma completeza de 96,08% e nível de acerto de 85,92%. Ao comparar com alguns trabalhos citados na bibliografia (Tabela 4.14), é possível notar que estes valores estão em concordância. Özdemir et al. (2021) obtiveram com seu método 81% de *F-score*, 90% de nível de acerto e 85% de completeza, enquanto Itakura; Miyatani; e Hosoi (2022) atingiram uma acurácia geral de 94,83% para seu método de classificação de árvores. Pu et al. (2023) avaliaram diversos métodos de segmentação de árvores, além do próprio método desenvolvido, e obtiveram valores próximos de 99% para completeza, nível de acerto e *F-score*. No entanto, em ambos os trabalhos, as metodologias propostas utilizaram dados LiDAR obtidos em florestas coníferas, onde o padrão das árvores tende a ser mais regular. Além disso, os métodos citados utilizaram técnicas de processamento digital de imagens para a detecção dos pontos de árvores, enquanto aqui o filtro morfológico foi usado apenas para refinamento da detecção.

Tabela 4.14 - Comparação dos resultados do método proposto com trabalhos da literatura.

Trabalho	Completeza (%)	Nível de acerto (%)	F-score (%)
Özdemir et al. (2021)	85,00	90,00	81,00
Itakura; Miyatani; e Hosoi (2022)	-	-	94,83
Pu et al. (2023)	99,00	99,00	99,00
Método proposto	96,08	85,92	90,46

Vale destacar também o uso da intensidade como parâmetro para a detecção dos pontos de árvores que se mostrou um diferencial em relação as metodologias citadas. A inclusão desse atributo permitiu aumentar a sensibilidade do método proposto para detectar os pontos de árvores de interesse, conforme detalhado no Experimento I: Detecção de árvores usando a intensidade.

5 CONCLUSÕES E RECOMENDAÇÕES

O levantamento bibliográfico feito para a realização deste trabalho permitiu entender o estado da arte para a tarefa de detecção de árvores com base em dados LiDAR aerotransportado. Notou-se que é comum a utilização de métodos baseados em imagens geradas a partir da nuvem de pontos, onde boa parte explora classificadores por aprendizado de máquina e necessitam de dados prévios de treinamento. Além disso, alguns trabalhos estão voltados para a detecção de árvores em regiões de reflorestamento, as quais geralmente possuem padrões mais regulares do que os obtidos em áreas urbanas. Neste contexto, este trabalho propôs um método de detecção de árvores em ambiente urbano explorando o uso de nuvens de pontos, informação de intensidade e descritor geométrico 3D (omnivariância) e refinamento baseado na morfologia matemática.

Os resultados apresentados permitiram avaliar o uso de descritores geométricos 3D e, de forma complementar, o uso da informação de intensidade na detecção de árvores. É possível concluir que o tipo e dimensão da vizinhança, assim como a densidade de pontos da nuvem, podem influenciar diretamente a estimação dos descritores geométricos e consequentemente o processo de detecção. De modo geral a vizinhança definida por uma esfera de raio constante se mostrou adequada para diferentes descritores, além de causar menos confusão entre os pontos de árvores e os pontos localizados nas bordas dos telhados e nas linhas de transmissão de energia.

A partir dos experimentos realizados foi possível observar que alguns descritores se destacaram por apresentar uma taxa relativamente alta de detecção dos pontos sobre as árvores, tais como omnivariância, curvatura, planaridade e entropia dos autovalores. Além disso, foi notado um bom desempenho por parte do uso da intensidade para a mesma tarefa, uma vez que se obteve um valor de completeza de aproximadamente 99%, considerando os dados reais disponíveis. No entanto, este atributo deve ser adotado de maneira complementar, levando em consideração as informações fornecidas por outros descritores.

Ao considerar os valores de intensidade com omnivariância foi possível obter métricas de qualidade acima de 90% para as áreas selecionadas. Além disso, o filtro morfológico de abertura se mostrou adequado para eliminar boa parte dos falsos positivos.

De maneira geral, os resultados obtidos indicaram a potencialidade do método proposto, permitindo detectar as árvores com completeza de 96,08%, nível de acerto de 85,92 e *F-score* de 90,46%. Apesar dos resultados promissores alguns aspectos ainda devem ser investigados, tais como: emprego do método em outras regiões (diferentes cidades e países), inclusive utilizando o conjunto de dados LiDAR adquiridos por diferentes sistemas e com diferentes características geométricas (densidade de pontos e ponto de vista). Além disso, sugere-se a implementação da etapa de delineamento (extração) das árvores, assim como a estimação de algumas de suas variáveis dendométricas.

De modo geral, pode-se concluir que o método se destaca por seu potencial em detectar árvores em dados LiDAR aerotransportado, em ambientes urbanos com alta complexidade, sem a necessidade de aplicar algoritmos de classificação que dependam de dados de treinamento e da etapa de treinamento.

REFERÊNCIAS

- AWADALLAH, M. O. M.; MALMQUIST, C.; STICKLER, M.; ALFREDSEN, K. Quantitative Evaluation of Bathymetric LiDAR Sensors and Acquisition Approaches in Lærdal River in Norway. **Remote Sens.** 2023, 15(1), 263; <https://doi.org/10.3390/rs15010263>.
- AXELSSON, P. Processing of laser scanner data—algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 138–147, jul. 1999.
- BARBOSA, L. J. **Detecção e extração de vegetação utilizando dados LiDAR: Determinação de indivíduos e aglomerados**. Dissertação (Mestrado em Ciências Cartográficas), Pós-Graduação em Ciências Cartográficas da Universidade Estadual Paulista, Presidente Prudente, 2017.
- BLOMLEY, R.; WEINMANN, M.; LEITLOFF, J.; JUTZI, B. Shape distribution features for point cloud analysis – a geometric histogram approach on multiple scales. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. II–3, p. 9–16, 7 ago. 2014.
- BUDEI, B. C. et al. Effects of Viewing Geometry on Multispectral LiDAR-Based Needle-Leaved Tree Species Identification. **Remote Sensing**, v. 14, n. 24, p. 6217, 8 dez. 2022.
- BURGER, W.; BURGE, M. J. **Digital Image Processing: An Algorithmic Introduction Using Java**. London: Springer London, 2016.
- CARRILHO, A. C.; GALO, M. Remoção de Pontos Espúrios em Dados LiDAR Aerotransportado a Partir da Análise Estatística das Altitudes. **Simpósio Brasileiro de Geomática**, p. 323–327, 2017.
- CASTRO, F. C. E.; CENTENO, T. M. Segmentação de imagens geradas por perfilamento a laser para delimitação de árvores individuais em uma área de reflorestamento de eucaliptos. **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 12., 2005, Goiânia. São José dos Campos: INPE, 2005. p. 737-744.
- CHARANIYA, A. P.; MANDUCHI, R.; LODHA, S. K. Supervised Parametric Classification of Aerial LiDAR Data. **2004 Conference on Computer Vision and Pattern Recognition Workshop**. Washington, DC, USA: IEEE, 2004. Disponível em: <<https://ieeexplore.ieee.org/document/1384821>>. Acesso em: 5 ago. 2021
- CHEN, W.; HU, X.; CHEN, W.; HONG, Y.; YANG, M. Airborne LiDAR Remote Sensing for Individual Tree Forest Inventory Using Trunk Detection-Aided Mean Shift Clustering Techniques. **Remote Sensing**, v. 10, n. 7, p. 1078, 6 jul. 2018.
- CRAMER, M. The DGPF-Test on Digital Airborne Camera Evaluation Overview and Test Design. **Photogrammetrie - Fernerkundung - Geoinformation**, v. 2010, n. 2, p. 73–82, 1 maio 2010.

DA COSTA, M. B. T. et al. Beyond trees: Mapping total aboveground biomass density in the Brazilian savanna using high-density UAV-LiDAR data. **Forest Ecology and Management**, v. 491, p. 119155, jul. 2021.

DEMANTKÉ, J.; MALLET, C.; DAVID, N.; VALLET, B. Dimensionality based scale selection in 3d LiDAR point clouds. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVIII-5/W12, p. 97–102, set. 2012.

DITTRICH, A.; WEINMANN, M.; HINZ, S. Analytical and numerical investigations on the accuracy and robustness of geometric features extracted from 3D point cloud data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 126, p. 195–208, abr. 2017.

DONG, P.; CHEN, Q. **LiDAR Remote Sensing and Applications**. 1ª Ed. Boca Raton: CRC Press, Taylor & Francis, 2018.

DONG, T.; ZHANG, X.; DING, Z.; FAN, J. Multi-layered tree crown extraction from LiDAR data using graph-based segmentation. **Computers and Electronics in Agriculture**, v. 170, p. 105213, mar. 2020.

DOS SANTOS, R. C.; PESSOA, G. G.; CARRILHO, A. C.; GALO, M. BUILDING DETECTION FROM LiDAR DATA USING ENTROPY AND THE K-MEANS CONCEPT. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-2/W13, p. 969–974, 5 jun. 2019.

DOS SANTOS, R. C.; PESSOA, G. G.; CARRILHO, A. C.; GALO, M. Automatic Building Boundary Extraction From Airborne LiDAR Data Robust to Density Variation. **IEEE Geoscience and Remote Sensing Letters**, p. 1–5, 2020.

DOS SANTOS, R.; GALO, M.; PESSOA, G. G.; CARRILHO, A. C.; OLIVEIRA, R. Automatic Building Change Detection Using Multi-Temporal Airborne LiDAR Data. **IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)**. Santiago, Chile: IEEE, mar. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9165628/>>. Acesso em: 14 ago. 2021.

DOS SANTOS, R. C.; GALO, M.; PESSOA, G. G.; CARRILHO, A. C. The use of Otsu algorithm and multi-temporal airborne LiDAR data to detect building changes in urban space. **Applied Geomatics**, 24 abr. 2021.

DOS SANTOS, R. C.; HABIB, A. F.; GALO, M. Weighted Iterative CD-Spline for Mitigating Occlusion Effects on Building Boundary Regularization Using Airborne LiDAR Data. **Sensors**, v. 22, n. 17, p. 6440, 26 ago. 2022.

EL-SHEIMY, N. Georeferencing component of LiDAR systems. Em: SHAN, J.; CHARLES K., T. (Eds.). **Topographic LASER Ranging and Scanning - Principles and Processing**. Boca Raton: CRC Press, Taylor & Francis Group, 2008. p. 195–214.

EL-SHEIMY, N.; VALEO, C.; HABIB, A. **Digital terrain modeling: acquisition, manipulation, and applications**. Boston: Artech House, 2005.

ESTORNELL, J.; HADAS, E.; MARTI, J.; LOPEZ-CORTEZ, I. Tree extraction and estimation of walnut structure parameters using airborne LiDAR data. **International Journal of Applied Earth Observation and Geoinformation**, v. 96, p. 102273, abr. 2021.

FERNANDES, V.; MARTINS, E.; DAL POZ, A.; IMAI, N. Filtragem de nuvem laser para geração de mdt por krigagem. **Boletim de Ciências Geodésicas**, v. 23, n. 1, p. 196–212, mar. 2017.

FILIN, S.; PFEIFER, N. Neighborhood Systems for Airborne Laser Data. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 6, p. 743–755, 1 jun. 2005.

FIOLKA, T.; STÜCKLER, KLEIN, D.; SCHULZ, D.; BEHNKE, S. Distinctive 3D surface entropy features for place recognition. **2013 European Conference on Mobile Robots**. Barcelona, Catalonia, Spain: IEEE, set. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6698843/>>. Acesso em: 25 mar. 2021.

GONG, Y. et al. Tree Species Classifications of Urban Forests Using UAV-LiDAR Intensity Frequency Data. **Remote Sensing**, v. 15, n. 1, p. 110, 25 dez. 2022.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital De Imagens**. [s.l.] ADDISON WESLEY BRA, 2009.

GUAN, H.; YU, Y.; YAN, W.; LI, D.; LI, J. 3D-CNN BASED TREE SPECIES CLASSIFICATION USING MOBILE LiDAR DATA. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-2/W13, p. 989–993, 5 jun. 2019.

GUENTHER, G. C.; LAROCQUE, P. E.; LILLYCROP, W. J. Multiple surface channels in Scanning Hydrographic Operational Airborne LiDAR Survey (SHOALS) airborne LiDAR. **Proc. SPIE** 1994, 2258, 422–430.

GUENTHER, G.C.; THOMAS, R. W. L.; LAROCQUE, P. E. Design Considerations for Achieving High Accuracy with the SHOALS Bathymetric LiDAR System, **SPIE**, vol. 2964, pp. 54–71, 1996.

GUO, T. et al. Research on Point Cloud Power Line Segmentation and fitting algorithm. **2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)**. Chengdu, China: IEEE, dez. 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8997632/>>. Acesso em: 30 mar. 2021.

HAN, X.; JIN, J.; XIE, J.; WANG, M.; JIANG, W. A comprehensive review of 3D point cloud descriptors. **ArXiv**, v. abs/1802.02297, 2018.

HAN, X.; SUN, S.; SONG, X.; XIAO, G. 3D Point Cloud Descriptors in Hand-crafted and Deep Learning Age: State-of-the-Art. **arXiv:1802.02297 [cs]**, 26 jul. 2020.

HANSEN, F.; BARTON, D.; ZANDER, V.; NOWELL, M.; CIMBUROVA, Z. Utilizing LiDAR data to map tree canopy for urban ecosystem extent and condition accounts in Oslo. **Ecological Indicators**, v. 130, p. 108007, nov. 2021.

H'ROURA, J.; ROY, M.; MANSOURI, A.; MAMMASS, D.; JUILLION, P.; BOUZIT, A.; MENIEL, P. Salient Spin Images: A Descriptor for 3D Object Recognition. Em: MANSOURI, A. et al. (Eds.). **Image and Signal Processing**. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2018. v. 10884p. 233–242.

HUI, Z.; LI, D.; JIN, S.; WANG, L.; YOUJIAN, H. Automatic DTM extraction from airborne LiDAR based on expectation-maximization. **Optics & Laser Technology**, v. 112, p. 43–55, abr. 2019.

ITAKURA, K.; MIYATANI, S.; HOSOI, F. Estimating Tree Structural Parameters via Automatic Tree Segmentation From LiDAR Point Cloud Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 15, p. 555–564, 2022.

JASKIERNIAK, D.; LUCIEER, A.; KUCZERA, G.; TURNER, D.; LANE, P.; BENYON, R.; HAYDON, S. Individual tree detection and crown delineation from Unmanned Aircraft System (UAS) LiDAR in structurally complex mixed species eucalypt forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 171, p. 171–187, jan. 2021.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 6th ed. Upper Saddle River, N.J: Pearson Prentice Hall, 2007.

JUTZI, B.; GROSS, H. Normalization of LiDAR intensity data based on range and surface incidence angle. **ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.**, v. 38, jan. 2009.

KASHANI, A.; OLSEN, M.; PARRISH, C.; WILSON, N. A Review of LiDAR Radiometric Processing: From Ad Hoc Intensity Correction to Rigorous Radiometric Calibration. **Sensors**, v. 15, n. 11, p. 28099–28128, 6 nov. 2015.

KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of Individual Tree Crowns in Airborne LIDAR Data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 357–363, 1 abr. 2006.

LEE, H. SLATTON, K.; ROTH, B.; CROPPER JR, W. Adaptive clustering of airborne LIDAR data to segment individual tree crowns in managed pine forests. **International Journal of Remote Sensing**, v. 31, n. 1, p. 117–139, 5 jan. 2010.

LEE, I.; SCHENK, T. Perceptual organization of 3D surface points. In: The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**, Vol. XXXIV, Part 3A. 2002.

LI, X. et al. LiDAR intensity correction for road marking detection. **Optics and Lasers in Engineering**, v. 160, p. 107240, jan. 2023.

LIU, Y.; LI, Z.; HAYWARD, R.; WALKER, R.; JIN, H. Classification of Airborne LiDAR Intensity Data Using Statistical Analysis and Hough Transform with Application to Power Line Corridors, **2009 Digital Image Computing: Techniques and Applications**, Melbourne, VIC, Australia, 2009, pp. 462–467, doi: 10.1109/DICTA.2009.83.

LU, X.; GUO, Q.; LI, W.; FLANAGAN, J. A bottom-up approach to segment individual deciduous trees using leaf-off LiDAR point cloud data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 94, p. 1–12, ago. 2014.

MARINELLI, D.; PARIS, C.; BRUZZONE, L. A Triangulation-Based Technique for Tree-Top Detection in Heterogeneous Forest Structures Using High Density LiDAR Data. **IEEE Geoscience and Remote Sensing Letters**, v. 19, p. 1–5, 2022.

MONGUS, D.; ŽALIK, B. An efficient approach to 3D single tree-crown delineation in LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 219–233, out. 2015.

MARINELLI, D.; PARIS, C.; BRUZZONE, L. A Triangulation-Based Technique for Tree-Top Detection in Heterogeneous Forest Structures Using High Density LiDAR Data. **IEEE Geoscience and Remote Sensing Letters**, v. 19, p. 1–5, 2022.

NASCIMENTO, G. A. G. do; GALO, M. Aplicabilidade dos dados obtidos por sistema LASER batimétrico aerotransportado à cartografia náutica: estudo de caso para o Arquipélago de Fernando de Nouronha. **Anuário do Instituto de Geociências**, v. 44, p. 1-10, 2021. DOI: 10.11137/1982-3908_2021_44_37487.

NELSON, R.; KRABILL, W.; MACLEAN, G. Determining forest canopy characteristics using airborne laser data. **Remote Sensing of Environment**, v. 15, n. 3, p. 201–212, jun. 1984.

OLIVEIRA, R.A.; GALO, M. Classificação de feições na superfície a partir de dados LiDAR e medidas de entropia e desvio padrão das altitudes. In: **Anais do Simpósio Brasileiro de Sensoriamento Remoto**, 2017. Campinas, Galoá, 2017. Disponível em: <https://proceedings.science/sbsr/trabalhos/classificacao-de-feicoes-na-superficie-a-partir-de-dados-LiDAR-e-medidas-de-entr?lang=pt-br> > Acesso em: 31 ago. 2021.

OLIVEIRA, R. A. R. DE. **Extração de redes de distribuição aérea de energia elétrica e identificação de regiões de contato com a vegetação a partir de dados obtidos por sistemas de varredura a LASER**. Dissertação (Mestrado) - PPGCC - Programa de Pós-Graduação em Ciências Cartográficas, Unesp - Universidade Estadual Paulista, Presidente Prudente, São Paulo, Brasil, Ago. 2022.

ÖZDEMİR, S. ZEYNEP, A.; FEVZI, K.; HAYRETTIN, A. Automatic extraction of trees by using multiple return properties of the LiDAR point cloud. **International Journal of Engineering and Geosciences**, v. 6, n. 1, p. 20–26, 1 fev. 2021.

PU, Y. et al. A New Strategy for Individual Tree Detection and Segmentation from Leaf-on and Leaf-off UAV-LiDAR Point Clouds Based on Automatic Detection of Seed Points. **Remote Sensing**, v. 15, n. 6, p. 1619, 16 mar. 2023.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais – Princípios, Algoritmos e Aplicações**. São Paulo: Thomson, 2008.

RATO, D.; SANTOS, V. LiDAR based detection of road boundaries using the density of accumulated point clouds and their gradients. **Robotics and Autonomous Systems**, v. 138, p. 103714, abr. 2021.

SECORD, J.; ZAKHOR, A. Tree Detection in Urban Regions Using Aerial LiDAR and Image Data. **IEEE Geoscience and Remote Sensing Letters**, v. 4, n. 2, p. 196–200, abr. 2007.

SHAN, J.; TOTH, C. K. **Topographic LASER Ranging and Scanning - Principles and Processing**. Boca Raton: CRC Press, Taylor & Francis Group, 2009.

SHAO, J.; ZHANG, W.; SHEN, A.; MELLADO, N.; CAI, S.; LUO, L.; WANG, N.; YAN, G.; ZHOU, G. Seed point set-based building roof extraction from airborne LiDAR point clouds using a top-down strategy. **Automation in Construction**, v. 126, p. 103660, jun. 2021.

SHIFFLER, R. E. Maximum Z Scores and Outliers. **The American Statistician**, v. 42, n. 1, p. 79–80, fev. 1988.

SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. Em: SATTAR, A. et al. (Eds.). **AI 2006: Advances in Artificial Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. v. 4304p. 1015–1021.

TOMMASELLI, A. M. G.; GALO, M.; REIS, T.; RUY, R.; MORAES, M.; MATRICARDI, W. Development and Assessment of a Data Set Containing Frame Images and Dense Airborne Laser Scanning Point Clouds. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 2, p. 192–196, fev. 2018.

VEGA, C.; HAMROUNI, A.; EL MOKHTARI, S.; MOREL, J.; BOCK, J.; RENAUD, J.; BOUVIER, M.; DURRIEU, S. PTrees: A point-based approach to forest tree extraction from LiDAR data. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, p. 98–108, dez. 2014.

VELASCO, J.; MOLINA, I.; MARTINEZ, E.; ARQUERO, Á.; PRIETO, J. F. Sea Bottom Classification by Means of Bathymetric LiDAR Data. **IEEE Latin America Transactions**, v. 12, n. 4, p. 590–595, 2014.

VOSELMAN, G.; MAAS, H.-G. (EDS.). **Airborne and terrestrial laser scanning**. repr ed. Dunbeath: Whittles, 2010.

WEHR, A.; LOHR, U. Airborne laser scanning—an introduction and overview. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2–3, p. 68–82, jul. 1999.

WEINMANN, M.; JUTZI, B.; MALLET, C. Semantic 3D scene interpretation: A framework combining optimal neighborhood size selection with relevant features. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. II–3, p. 181–188, 7 ago. 2014.

WEINMANN, M.; JUTZI, B.; HINZ, S.; MALLET, Z. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 286–304, jul. 2015.

WEINMANN, M.; JUTZI, B.; HINZ, S.; MALLET, Z. GEOMETRIC FEATURES AND THEIR RELEVANCE FOR 3D POINT CLOUD CLASSIFICATION. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. IV-1/W1, p. 157–164, 30 maio 2017.

YUN, T. et al. Individual tree crown segmentation from airborne LiDAR data using a novel Gaussian filter and energy function minimization-based approach. **Remote Sensing of Environment**, v. 256, p. 112307, abr. 2021.

YUNFEI, B. et al. Classification of LiDAR Point Cloud and Generation of DTM from LiDAR Height and Intensity Data in Forested Area. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, jan. 2008.

ZHOU, G.; ZHOU, X.; LI, W.; ZHAO, D.; SONG, B.; XU, C.; ZHANG, H.; LIU, Z.; XU, J.; LIN, G.; DENG, R.; HU, H.; TAN, Y.; LIN, J.; YANG, J.; NONG, X.; LI, C.; ZHAO, Y.; WANG, C.; ZHANG, L.; ZOU, L. Development of a Lightweight Single-Band Bathymetric LiDAR. **Remote Sensing**. 2022, 14, 5880. <https://doi.org/10.3390/rs14225880>.