



## Uso de Descritores 3D e Intensidade na Detecção de Árvores em Ambiente Urbano por meio de Dados LiDAR

### *The Use of 3D Descriptors and Intensity to Detect Trees from LiDAR Data in Urban Environment*

Cleber Junior Alencar <sup>1</sup>, Mauricio Galo <sup>2</sup> e Renato César dos Santos <sup>2</sup>

<sup>1</sup> Universidade Estadual Paulista “Júlio de Mesquita Filho”, Programa de Pós-Graduação em Ciências Cartográficas, Presidente Prudente, Brasil. [cleber.alencar@unesp.br](mailto:cleber.alencar@unesp.br)

ORCID: <https://orcid.org/0000-0001-6562-8104>

<sup>2</sup> Universidade Estadual Paulista “Júlio de Mesquita Filho”, Departamento de Cartografia, Presidente Prudente, Brasil.

[mauricio.galo@unesp.br](mailto:mauricio.galo@unesp.br); [renato.cesar@unesp.br](mailto:renato.cesar@unesp.br)

ORCID: <https://orcid.org/0000-0002-0104-9960>

ORCID: <https://orcid.org/0000-0003-0263-312X>

Recebido: 09.2021 | Aceito: 09.2023

**Resumo:** A detecção de vegetação por meio de dados LiDAR possui aplicações em diferentes áreas do conhecimento, sendo importante para o manejo e preservação florestal, planejamento urbano, detecção de objetos obstruídos pelas copas das árvores, dentre outras. Nesse sentido, este artigo tem o propósito de avaliar a aplicabilidade dos descritores geométricos 3D baseados em autovalores e da intensidade na detecção de pontos amostrados sobre árvores. No cálculo dos atributos geométricos, vizinhanças do tipo esférica e cilíndrica foram definidas para o cálculo dos descritores, visando avaliar sua influência nos resultados. Após análises visuais dos resultados, os descritores omnivariância, curvatura, planaridade e entropia dos autovalores, além da intensidade, foram utilizados como atributos para a classificação dos pontos com o algoritmo K-Médias. Na classificação os pontos foram separados em duas classes: pontos de vegetação e não vegetação, sendo os resultados da classificação avaliados quantitativamente, com base em dados de referência e no uso dos indicadores de completude, nível de acerto e *F-Score*. A completude obtida para os atributos omnivariância, entropia dos autovalores, planaridade e intensidade foram superiores a 90%, o que sugere uma boa confiabilidade por parte dos descritores selecionados na detecção de árvores. No entanto, os valores de nível de acerto, em torno de 62%, não foram tão altos devido ao grande número de falsos positivos, devido a confusão entre pontos de árvores e pontos de bordas de edificação e linhas de transmissão. Analisando os valores de *F-Score*, a classificação usando o atributo omnivariância calculado numa vizinhança esférica de raio igual a 1 m se destacou, resultando em *F-Score* superior a 80%.

**Palavras-chave:** LiDAR aerotransportado. Vegetação em ambiente urbano. Análise de componentes principais. K-Médias. Intensidade.

**Abstract:** The result derived from tree detection using LiDAR data can be used in different applications such as forest management and preservation, urban planning, detection of occluded objects by tree crowns, among others. In this sense, this work aims to evaluate the applicability of 3D geometric descriptors based on eigenvalues and LiDAR intensity in tree detection. In experiments, it was analyzed the influence of neighborhood (sphere and cylinder) in the calculation of geometric attributes. From visual analyses, it was possible to notice that the use of some geometric attributes such as omnivariance, curvature, planarity and eigenentropy showed more potential in detecting trees. Considering the four selected attributes (omnivariance, curvature, planarity, eigenentropy) and intensity, the K-Means algorithm was executed to each attribute aiming to separate the point cloud into tree and non-tree. The results derived from classification were compared with reference data using quality parameters such as completeness, correctness and F-Score. Completeness values obtained with for omnivariance, eigenentropy, planarity and intensity reached values above 90%, indicating that these descriptors have high reliability for tree detection. The average correctness was around 62%, presenting a large number of false positives. When analyzing F-Score values, it was possible to verify the potential of omnivariance, computed in a spherical neighborhood, in detecting trees from LiDAR data (F-Score above 80%).

**Keywords:** Airborne LiDAR. Vegetation in urban space. Principal Component Analysis. K-Means. Intensity.

## 1 INTRODUÇÃO

A evolução da capacidade dos sistemas LiDAR (*Light Detection and Ranging*) de registrar uma grande quantidade de pontos de modo rápido e acurado aumentou a disponibilidade de dados tridimensionais e, assim, abriu uma série de possibilidades de aplicações em 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.

Por meio da integração dos sistemas de varredura a LASER, de posicionamento GNSS (*Global Navigation Satellite System*) e de orientação, constituído por uma IMU (*Inertial Measurement Unit*), o sistema LiDAR fornece diretamente um conjunto de pontos tridimensionais com coordenadas conhecidas, conjunto este denominado nuvem de pontos, nuvem de pontos 3D ou nuvem de pontos LiDAR (EL-SHEIMY; VALEO; HABIB, 2005). Nas últimas duas décadas têm-se notado um crescimento da utilização desses dados para as mais variadas aplicações, como por exemplo a geração de Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT) (HUI et al., 2019), detecção e extração de edificações (DOS SANTOS et al., 2019; SHAO et al., 2021), modelagem de fachadas (SOUSA; CENTENO, 2021), detecção de linhas de transmissão (GUO et al., 2019, OLIVEIRA, 2022), detecção de vegetação (JASKIERNIAK et al., 2021; ITAKURA, MIYATANI e HOSOI, 2022) e detecção de estradas (RATO; SANTOS, 2021).

No caso de aplicações sobre a vegetação, o uso de dados LiDAR permite determinar as variáveis dendrométricas (MARTINS-NETO, 2016), tais como: altura da árvore, diâmetro da copa, número de indivíduos arbóreos, altura e diâmetro dos troncos. Essas métricas são de suma importância para a Engenharia Florestal, Engenharia Ambiental, Inventário Florestal e, conseqüentemente para o manejo de florestas e plantações (CHEN et al., 2018; DONG et al., 2020; LIU et al., 2021). Além disso, a delimitação da copa das árvores é também essencial para aprimorar algoritmos de contorno de edificações e de linhas de transmissão, uma vez que a vegetação pode causar confusão no processo de segmentação e classificação desses objetos (OLIVEIRA, GALO, 2018; OLIVEIRA, 2022) e a proximidade com as linhas de transmissão representa risco em caso de tempestades.

Tradicionalmente, os trabalhos de detecção e delimitação de árvores consideram o uso de imagens bem como de Modelos de Altura da Copa (CHM – *Canopy Height Model*) geradas a partir dos pontos 3D (RIBAS e ELMIRO, 2013; BARBOSA, 2017). No entanto, abordagens que trabalham diretamente com os dados tridimensionais podem ser adotadas (CHEN et al., 2018; JASKIERNIAK et al., 2021; KOCH; HEYDER; WEINACKER, 2006; LU et al., 2014). Nestes casos, é notada uma melhora na taxa de detecção em regiões onde há árvores com copas complexas e distribuição não regular.

A análise de nuvens de pontos LiDAR para reconhecimento de objetos também é assunto de estudos por parte da visão computacional, onde se faz o uso de descritores geométricos 3D para discriminar os objetos com base nas suas características geométricas (CHEN et al., 2018; WEINMANN et al., 2015, 2017). No trabalho apresentado por (WEINMANN et al., 2015), por exemplo, foi proposta uma metodologia que consistiu em selecionar a vizinhança definida no entorno de cada ponto da nuvem, determinar o conjunto de atributos extraídos com base nos autovalores calculados para cada vizinhança e depois realizar uma classificação supervisionada dos pontos entre as classes linha de transmissão, poste/tronco, fachada, terreno e vegetação. Adicionalmente, existem alguns trabalhos que têm explorado 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) e (LU et al., 2014).

Nesse contexto, o presente artigo tem como objetivo avaliar a aplicação de diferentes descritores geométricos e o uso da intensidade na detecção de árvores em dados LiDAR obtidos por um sistema de varredura a LASER embarcado em uma aeronave (Sistema de Varredura a LASER aerotransportado – SVLA).

## 2 DESCRITORES 3D APLICADOS NA ANÁLISE DE NUVEM DE PONTOS

Diante dos avanços tecnológicos dos sistemas LiDAR e da sua capacidade de obtenção de dados tridimensionais de maneira direta, diversos estudos se dedicaram à tarefa de reconhecer diferentes objetos usando essa fonte de dado. No contexto da análise de cenas 3D, o reconhecimento dos objetos presentes é

baseado nas características geométricas, radiométricas e/ou espaciais, onde comumente são efetuadas uma sequência de etapas, tais como: (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 (WEINMANN et al., 2015, 2017).

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 em visão computacional. Segundo Han et al. (2018), os descritores permitem a realização de tarefas de visualização 3D de forma mais acurada e eficiente, podendo ser categorizados como globais, locais ou híbridos. Os globais são calculados com um único vetor de atributos para toda a nuvem de pontos. Os locais são calculados a partir de um vetor de atributos obtido com as características geométricas de uma vizinhança local, definida para cada ponto da nuvem. Por fim, os híbridos combinam descritores globais e locais. Os autores ainda acrescentam que um descritor poderoso deve ser capaz de caracterizar 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. Um dos mais antigos é o *Spin Image* (“imagem giratória”) criado por (JOHNSON, 1997) para a correspondência entre objetos, o qual consiste em usar uma base local definida por um dado ponto 3D orientado pela normal à superfície e acumular em uma matriz 2D a posição, em relação à essa base, dos outros pontos da superfície do objeto (HAN et al., 2018). Recentemente, uma otimização deste descritor, denominada de *Salient Spin Image*, foi proposta por H’rouira et al. (2018) com o objetivo de reduzir a complexidade computacional do algoritmo e melhorar a sua performance em áreas oclusas e desordenadas (*cluttered*). Outro exemplo de descritor comumente aplicado é o baseado na distribuição de formas (*Shape Distribution*) que consiste em amostrar aleatoriamente relações geométricas como distância e ângulo entre os pontos de uma certa vizinhança, visando caracterizar localmente uma região (BLOMLEY et al., 2014). Özdemir et al. (2021) 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. Itakura, Miyatani e Hosoi (2022), por sua vez, 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 *Fast Point Feature Histogram* – FPHP aplicado a um conjunto de pontos previamente filtrado e normalizado em relação ao terreno.

Uma variedade de outros descritores podem ser encontrados, principalmente aqueles que se baseiam nas relações analíticas dos autovalores da estrutura formada pelos pontos de uma vizinhança. Os autovalores ( $\lambda_1, \lambda_2, \lambda_3$ ) são obtidos pela decomposição de uma matriz de variância-covariância local definida por pontos de uma região de suporte e são ordenados em função da magnitude ( $\lambda_1 > \lambda_2 > \lambda_3$ ) (HAN et al., 2018). 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; DOS SANTOS et al., 2019; WEINMANN et al., 2015, 2017). Dentre os inúmeros descritores existentes pode-se destacar os seguintes: planaridade ( $P_\lambda$ ), esfericidade ( $S_\lambda$ ), omnivariância ( $O_\lambda$ ), anisotropia ( $A_\lambda$ ), entropia dos autovalores ( $E_\lambda$ ), linearidade ( $L_\lambda$ ) e a curvatura ( $C_\lambda$ ), cujas equações são apresentadas na sequência.

$$P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (1)$$

$$S_\lambda = \frac{\lambda_3}{\lambda_1} \quad (2)$$

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

$$A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1} \quad (4)$$

$$E_\lambda = - \sum_{i=1}^3 (\lambda_i \times \log \lambda_i) \quad (5)$$

$$L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (6)$$

$$C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (7)$$

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. No entanto, Oliveira e Galo (2017) utilizaram as altitudes dos pontos numa certa vizinhança para definir um descritor baseado na entropia das altitudes, conforme mostra a Eq. (8):

$$E_h = \frac{\sum_{i=1}^n [-(h_i - h_{min} + \Delta) \ln (h_i - h_{min} + \Delta)]}{n} \quad (8)$$

onde  $h_i$  é a altitude de um dado ponto da vizinhança,  $h_{min}$  é a altitude mínima da vizinhança, e  $\Delta$  uma constante utilizada para evitar a indeterminação no cálculo do logaritmo nos casos em que  $h_i - h_{min} = 0$ .

### 3 USO DA INFORMAÇÃO DE INTENSIDADE DO PULSO LASER

É de amplo conhecimento que os sistemas LiDAR são sistemas ativos que produzem e emitem um pulso LASER em um comprimento de onda específico do espectro eletromagnético, localizado na região do infravermelho próximo (SHAN; TOTH, 2009). Os sistemas LiDAR que operam na região do infravermelho próximo são os sistemas topográficos. Além desses, tem-se os sistemas batimétricos que operam na região verde do espectro eletromagnético, como pode-se ver em Nascimento et al. (2021). Ao interagir com os objetos da superfície iluminada e ser retroespalhado, o sistema realiza uma série de processamentos para determinar a intensidade do pulso medido para cada ponto. Essa intensidade é registrada juntamente com as coordenadas tridimensionais do ponto. De acordo com Kashani et al. (2015), a aplicabilidade do dado LiDAR aumenta quando se tem disponível as informações de intensidade dos pontos, a qual pode ser usada individualmente ou como um suplemento para outros dados, espaciais e/ou espectrais, obtidos por sensoriamento remoto.

As aplicações da 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 e Lodha (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 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. Com este propósito 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. Adicionalmente, os autores consideraram características da estrutura das árvores, visando detectá-las na nuvem de pontos LiDAR.

No mesmo sentido, este trabalho também levou em consideração a informação de intensidade presentes no dado LiDAR, além dos descritores geométricos. Todos esses atributos foram testados para avaliar a capacidade da discriminação da vegetação entre os demais elementos da área.

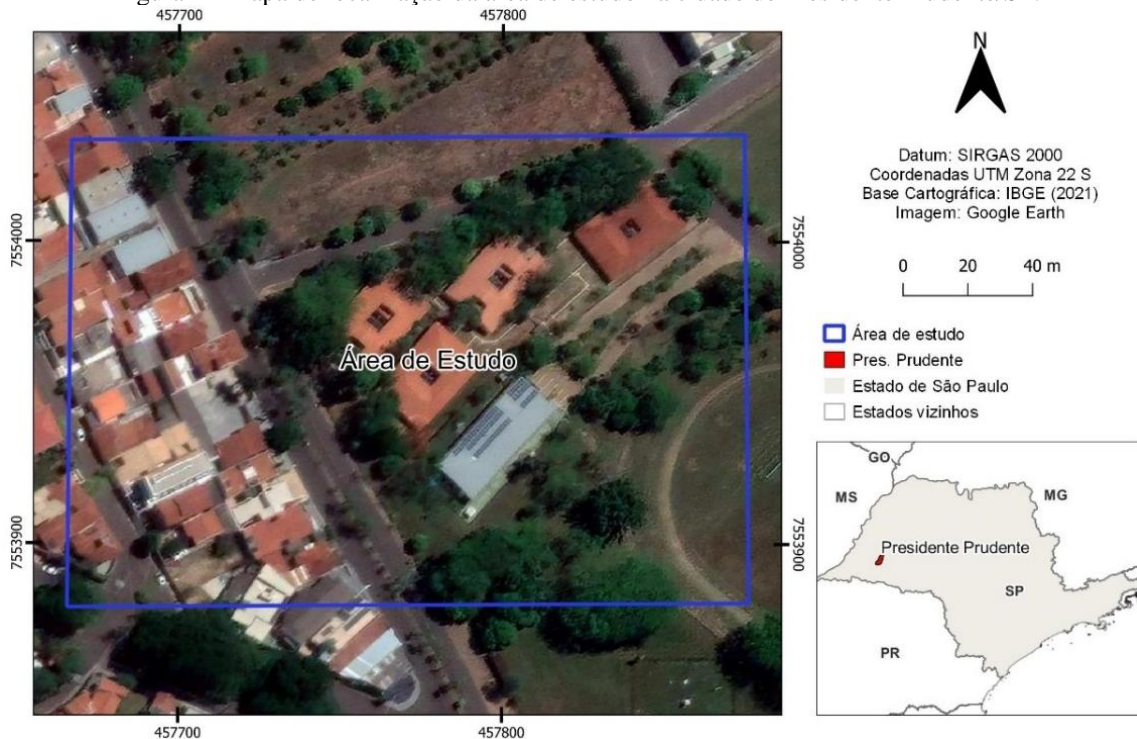
## 4 MATERIAIS E MÉTODOS

### 4.1 Materiais

Com o intuito de avaliar o desempenho dos descritores diante da variabilidade de características

geométricas, uma área de estudo localizada em um ambiente urbano foi selecionada. A área de estudo selecionada possui características importantes para avaliar a capacidade dos descritores geométricos de detectar árvores. Dentre elas estão a diversidade de espécies, padrões de copa e altura das árvores, bem como a presença intensa ou moderada de outros elementos urbanos não arbóreos (edificações, linhas de transmissão, ruas, etc.), além do próprio terreno. A Figura 1 mostra a área selecionada localizada na cidade de Presidente Prudente, Estado de São Paulo, Brasil, que abrange parte do campus da FCT Unesp e possui dimensões aproximadas de 200 m por 138 m, totalizando 27.622 m<sup>2</sup>.

Figura 1 - Mapa de localização da área de estudo na cidade de Presidente Prudente/SP.

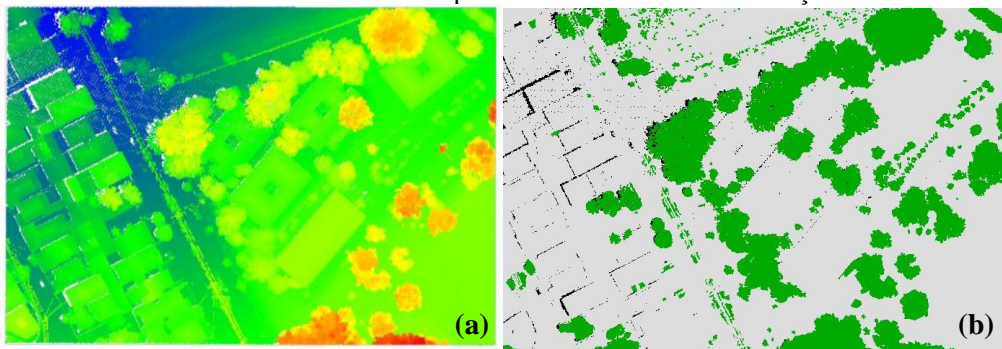


Fonte: Os Autores (2023).

A área selecionada corresponde a uma região altamente urbanizada que contém edificações residenciais, barracões, linhas de transmissão, ruas asfaltadas, mas também contém grande quantidade de árvores de médio e grande porte. As espécies de árvores são variadas, assim como o tipo de folhagem, formato do tronco e o padrão das copas.

Uma nuvem de pontos LiDAR adquirida na região da área de estudo foi usada no desenvolvimento do trabalho (Figura 2a). A nuvem foi obtida por um sistema de varredura a LASER da RIEGL LMS-Q680i embarcado em uma aeronave, e faz parte do conjunto de dados de acesso público denominado “Unesp Photogrammetric Data Set” (TOMMASELLI et al., 2018) que também conta com outros dados fotogramétricos como imagens aéreas de alta resolução (disponível em: <https://ieee-dataport.org/> e <http://www.fct.unesp.br/#!/unespdataset>), parâmetros de orientação exterior e pontos de apoio com coordenadas geodésicas conhecidas. O sistema de aquisição operou a uma altura de voo média de 550 m, resultando em uma nuvem com densidade média de 13,5 pts/m<sup>2</sup> e espaçamento médio entre os pontos em torno de 0,3 m. Além dos dados LiDAR foram utilizados dados de referência para a classificação dos pontos, o qual foi editado manualmente de forma que houvesse apenas a classe de árvores (classe 1 - verde) e a classe “não-árvore” (classe 0 - cinza), conforme ilustrado na Figura 2b.

Figura 2 – Visualização da nuvem de pontos LiDAR inicial colorida com base na altura dos pontos (a) e do dado de referência para classificação (b) contendo as classes árvore (verde) e “não-árvore” (cinza). As regiões na cor preta são áreas de oclusão e indicam pontos com ausência de informação.

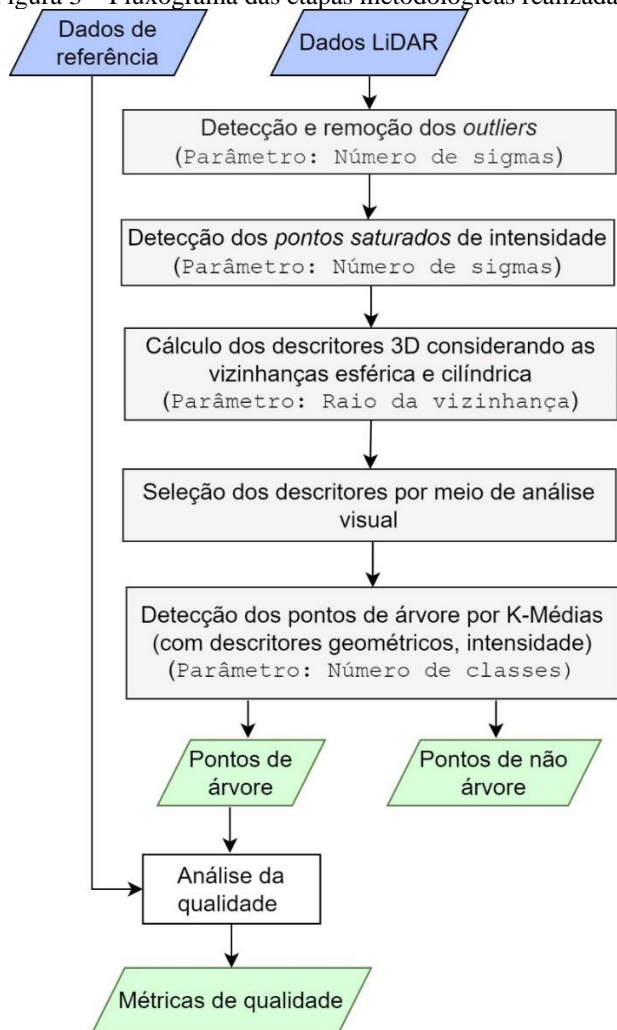


Fonte: Os Autores (2023).

## 4.2 Método

Antes de verificar a aplicabilidade de alguns descritores 3D na tarefa de detecção de árvores em dados LiDAR, buscou-se avaliar a influência do tipo de vizinhança no resultado desses atributos. Na sequência, selecionou-se os atributos mais adequados, além da informação de intensidade, por meio de análise visual e aplicou-se o classificador K-Médias para classificar os pontos entre “árvore” e “não-árvore”. Os resultados da classificação foram posteriormente comparados com dados de referência, rotulados manualmente, e então uma análise quantitativa usando métricas de qualidade foi efetuada. A Figura 3 ilustra, de modo simplificado, a sequência de etapas realizadas neste estudo.

Figura 3 – Fluxograma das etapas metodológicas realizadas.




Fonte: Os Autores (2023).

#### 4.2.1 DETECÇÃO DE ÁRVORES USANDO AS INFORMAÇÕES DE INTENSIDADE

Nesta seção é discutida a capacidade de detecção de árvores usando somente a informação de intensidade. Na Figura 4, é mostrada a nuvem de pontos LiDAR da área de estudo em escala de cinza (Figura 4a) e com uma escala de cores arbitraria (Figura 4b), que realça os diferentes objetos da cena. É possível notar que os tons mais escuros estão associados aos pontos localizados em árvores, 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 - 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: Os Autores (2023).

Entretanto, ao analisar a nuvem de pontos é possível notar a presença de pontos cujo valor de intensidade estava muito maior que a média para a região próxima a ele (pontos destacados por uma circunferência na Figura 4). Isso pode ter ocorrido devido a diferentes fatores, tais como o ângulo de incidência em relação à normal da superfície no ponto, o comprimento de onda do pulso LASER e o 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.

Assim, especialmente para os processos de segmentação e classificação de dados LiDAR obtidos por um SVLA, a normalização da intensidade ou mesmo a mitigação dos valores “saturados” é importante para evitar o uso de possíveis pontos espúrios, que podem ser associados a *outliers* neste caso. Então, antes de realizar a classificação dos pontos usando o algoritmo K-Médias, foi necessário corrigir os valores de intensidade saturados. Os pontos saturados foram detectados com base na média ( $\mu$ ) e desvio-padrão ( $\sigma$ ) da intensidade, onde os valores superiores a  $\mu+4*\sigma$  foram substituídos pelo valor do próprio limiar ( $\mu+4*\sigma$ ).

#### 4.2.2 INFLUÊNCIA DO TIPO DE VIZINHANÇA NO CÁLCULO DOS DESCRITORES

Como já mencionado, 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 (DEMANTKÉ et al., 2012; FILIN; PFEIFER, 2005; LEE; SCHENK, 2002; 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. No caso deste trabalho, foram consideradas as definições de vizinhança esférica e cilíndrica de raios ( $r$ ) constantes, pelo fato de serem simples de implementar e não necessitarem de operações prévias para determinar as características da região local de cada ponto da nuvem.

Os códigos computacionais usados no cálculo dos atributos e posterior classificação foram implementados na linguagem Python 3.9. Assim, em cada ponto da nuvem foi definida a vizinhança de raio igual a 1 m ( $r = 1$  m) e então, para aqueles onde o número de vizinhos fosse maior que 1 ( $N > 1$ ), foram calculados os descritores 3D planaridade ( $P_\lambda$ ), esfericidade ( $S_\lambda$ ), omnivariância ( $O_\lambda$ ), anisotropia ( $A_\lambda$ ), entropia dos autovalores ( $E_\lambda$ ), linearidade ( $L_\lambda$ ), curvatura ( $C_\lambda$ ) e entropia das altitudes ( $E_h$ ), conforme as Eqs. (1) a (8). O tamanho do raio foi definido de forma empírica após algumas análises visuais dos resultados para diferentes tamanhos, onde  $r = 1$  m se mostrou mais adequado para a detecção de pontos sobre as árvores. Nos pontos em que o número de vizinhos foi menor ou igual a 1 ( $N \leq 1$ ), os descritores não foram calculados.

Após calcular os descritores, realizou-se uma análise visual dos resultados (ver Seção 5) onde foi possível verificar quais eram os descritores e o tipo de vizinhança com potencial para a detecção de árvores. Na sequência, utilizou-se o classificador K-médias, o qual é amplamente aplicado devido a sua facilidade de implementação e robustez (JOHNSON; WICHERN, 2007). O K-Médias foi aplicado na nuvem de pontos para formar duas classes distintas, uma contendo os pontos de árvores e a outra os pontos de não árvore, com base em alguns dos descritores mencionados e na informação de intensidade utilizados separadamente. O algoritmo utilizado foi implementado com base na biblioteca *sklearn* do Python (<https://scikit-learn.org/stable/>), onde foi utilizada a função *KMeans* definindo o número de classes como sendo 2.

#### 4.2.3 ANÁLISE DE QUALIDADE DA CLASSIFICAÇÃO

Os resultados das classificações da nuvem de pontos foram analisados com base nos dados de referência disponíveis para a área de estudo (Figura 2b). Além das análises visuais, realizou-se uma avaliação quantitativa da classificação. Para tanto, foram calculados alguns indicadores de qualidade comumente adotados em trabalhos do mesmo escopo, tais como: completudeza (*completeness*), que indica a taxa de pontos de árvores detectados; nível de acerto (*correctness*), que representa o número de pontos de árvores corretamente detectados e; *F-Score* que mede a acurácia geral da detecção, sendo a média harmônica entre completudeza e nível de acerto (LU et al., 2014; MONGUS; ŽALIK, 2015; BARBOSA, 2017). Os indicadores citados são obtidos por meio da matriz de confusão composta pelos elementos: verdadeiro positivo (TP – *True Positive*), verdadeiro negativo (TN – *True Negative*), falso positivo (FP – *False Positive*) e falso negativo (FN – *False Negative*). Os indicadores de qualidade adotados são calculados com as Eq(s). 9 a 11 (SOKOLOVA, JAPKOWICZ e SZPAKOWICZ, 2006).

$$\text{Completudeza} = \frac{TP}{TP + FN} \quad (9)$$

$$\text{Nível de acerto} = \frac{TP}{TP + FP} \quad (10)$$

$$F - \text{Score} = \frac{2 \times \text{Nível de acerto} \times \text{Completudeza}}{\text{Nível de acerto} + \text{Completudeza}} \quad (11)$$

Após a execução do classificador K-Médias, para diferentes atributos, foram obtidas as classes de cada ponto da nuvem de pontos, sendo estes pontos rotulados como sendo 1 para árvores detectadas e 0 para “não-árvore”. A classificação usando o algoritmo K-Médias foi realizada separadamente para cada um dos quatro atributos geométricos selecionados.



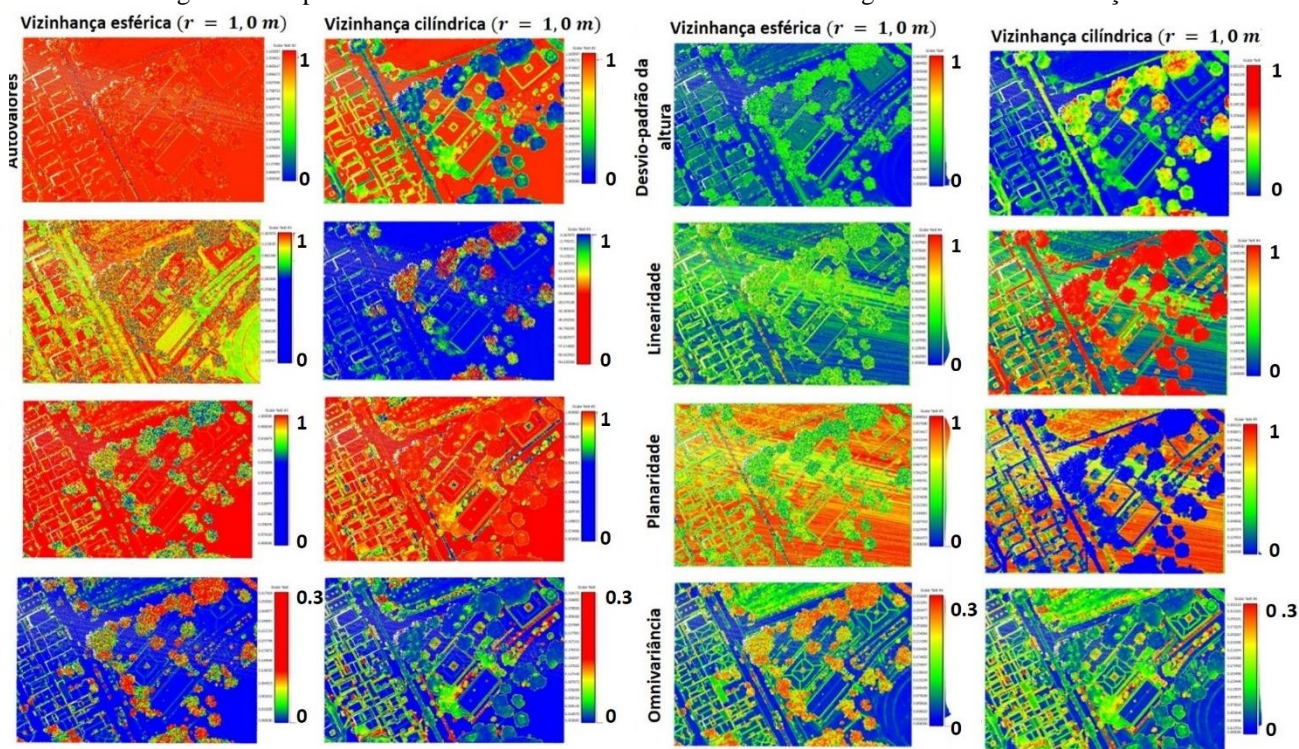
## 5 RESULTADOS E DISCUSSÃO

Como descrito na Seção 4.2, primeiramente fez-se uma análise visual para seleção dos descritores e da vizinhança mais adequados para o objetivo do trabalho e depois fez-se a classificação da nuvem de pontos usando os descritores selecionados e a intensidade por meio do algoritmo K-Médias.

### 5.1 Análise dos descritores 3D

A Figura 5 mostra o resultado dos descritores  $E_\lambda$ ,  $E_h$ ,  $A_\lambda$ ,  $C_\lambda$ ,  $L_\lambda$ ,  $P_\lambda$  e  $O_\lambda$ , citados na Seção 2 e o desvio-padrão da altura ( $\sigma_h$ ), calculados para os dois tipos de vizinhança definidas por um raio  $r = 1$  m. Este raio foi escolhido após a análise visual dos resultados obtidos, bem como pelo que foi indicado em DOS SANTOS et al. (2020, 2021). A escolha do tamanho do raio foi realizada de forma empírica e a ideia é mostrar apenas a influência do tipo de vizinhança. Assim, as análises visuais foram pautadas no comportamento dos valores dos descritores nas regiões próximas aos pontos localizados em árvores. Para o cálculo de  $E_h$  foi utilizada a Eq. 8 adotando-se para  $\Delta$  o valor 0,0001 m.

Figura 5 - Mapa dos atributos considerando diferentes descritores geométricos e vizinhanças.




Fonte: Os Autores (2023).

Ao comparar visualmente as imagens dos descritores, nota-se que alguns sofrem mais influência da vizinhança do 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 cilíndrica. Dessa forma, os valores mais altos de entropia se distribuíram por toda a área, o que acabou limitando as diferenças entre objetos mais planos (telhados, ruas, terreno) da área e os objetos mais volumétricos 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, a definição do cilindro 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. 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 planos e não planos 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 a tarefa de detectar e reconhecer as árvores presentes em uma nuvem de pontos LiDAR, verificou-se uma 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, como pode ser observado na Figura 6.

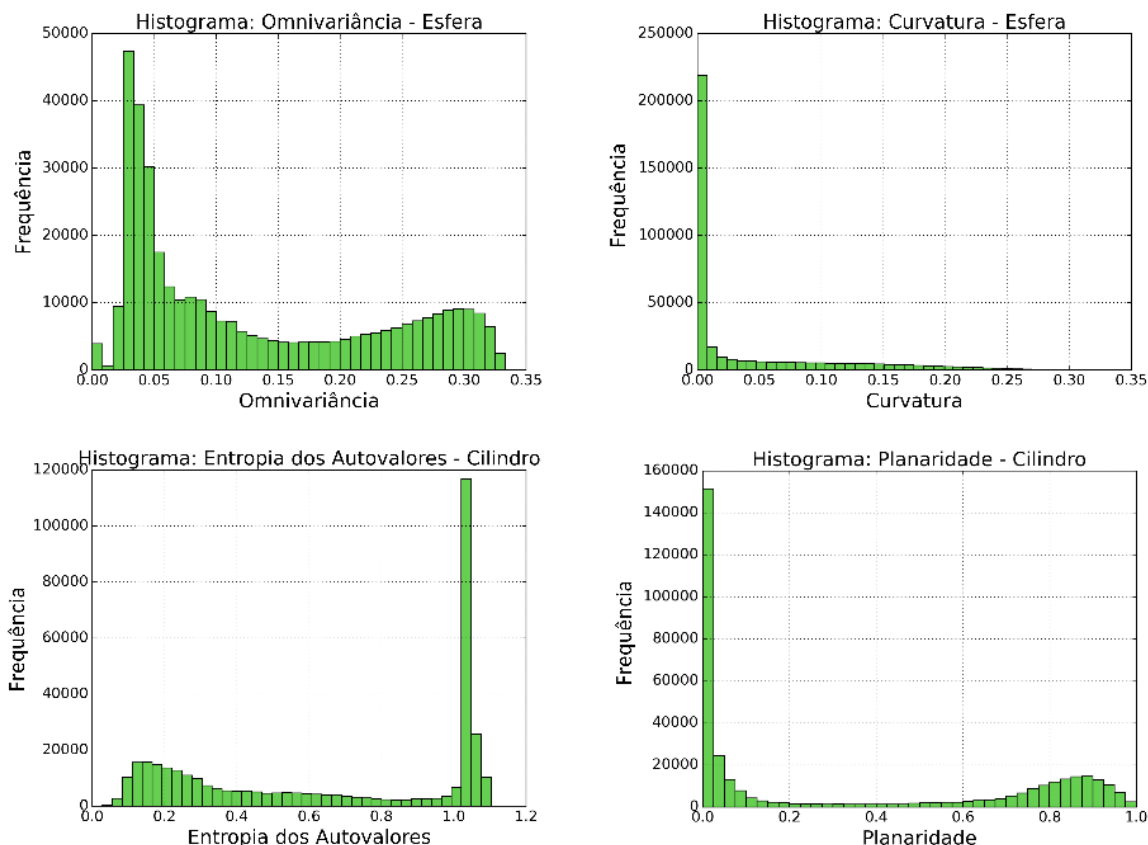
Figura 6 - Comparação entre os resultados dos descritores omnivariância ( $O_{\lambda_{esfera}}$ ), curvatura ( $C_{\lambda_{esfera}}$ ), entropia dos autovalores ( $E_{\lambda_{cilindro}}$ ) e planaridade ( $P_{\lambda_{cilindro}}$ ).



Fonte: Os Autores (2023).

Na Figura 7 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 a aplicação de classificadores baseados em medidas de similaridade.

Figura 7 - Histogramas dos valores de omnivariância e curvatura para uma vizinhança esférica, e entropia dos autovalores e planaridade para uma vizinhança cilíndrica.




Fonte: Os Autores (2023).

A partir das análises realizadas pode-se notar que a seleção da vizinhança é um fator importante a ser considerado no cálculo dos atributos que caracterizam localmente uma região utilizando dados LiDAR. Além do tipo de vizinhança é natural que 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 as métricas de qualidade (nível de acerto, completude e naturalmente o *F-Score*) da classificação dos pontos (BLOMLEY et al., 2014).

## 5.2 Análise da classificação usando o algoritmo K-Médias

Os resultados da classificação são apresentados na Figura 8. Em verde estão representados os pontos da classe árvore e em cinza claro os pontos da classe “não-árvore”. Além dos descritores geométricos citados, optou-se por avaliar também a classificação da nuvem de pontos usando somente a intensidade como atributo (Figura 8e). Nas Figuras 8a e 8b, o retângulo preto traçado na diagonal destaca uma região contendo linha de transmissão. Na Tabela 1 são apresentadas as métricas de qualidade mencionadas, para os diferentes descritores geométricos e para a intensidade.

Figura 8 - Resultados da aplicação do K-Médias usando a omnivariância, curvatura, entropia dos autovalores, planaridade e intensidade (vista superior da nuvem 3D).



Fonte: Os Autores (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  $h$  (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 são mais bem definidas quando os descritores  $O_{\lambda_{esfera}}$  e  $E_{\lambda_{cilindro}}$  são utilizados. No entanto, no segundo caso as linhas de transmissão presentes na área foram consideradas como um grande aglomerado de árvores, o que não ocorreu com o uso da omnivariância devido a vizinhança do tipo esférica considerada no cálculo desse descritor. A explicação está no fato de que a vizinhança cilíndrica é mais abrangente e inclui pontos que estão no terreno, além dos pontos sobre árvores e sobre as linhas de transmissão, fazendo com que a variação local e o grau de desordem dos pontos fossem semelhantes ao das regiões com árvores. 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 analisar visualmente a aplicação do atributo intensidade, é possível notar que a grande maioria dos pontos de árvore foram classificados corretamente pelo K-Médias, o que reflete a análise feita na Seção 5.1. Porém, como também era esperado, as respostas geradas pelos pontos de árvore foram semelhantes às respostas do asfalto, o que provocou a inserção desses elementos na mesma classe. De acordo com estudos de Charaniya et al. (2004) e Kashani et al. (2015), a reflectância do asfalto e árvores são similares para laser infravermelho.

Tabela 1 – Parâmetros de qualidade da classificação utilizando diferentes atributos diferentes.

|                          | Completeza (%) | Nível de acerto (%) | F-Score (%)  |
|--------------------------|----------------|---------------------|--------------|
| $O_{\lambda_{esfera}}$   | 92,47          | 73,48               | <b>81,89</b> |
| $C_{\lambda_{esfera}}$   | 67,14          | <b>88,24</b>        | 76,25        |
| $E_{\lambda_{cilindro}}$ | 92,39          | 54,98               | 68,94        |
| $P_{\lambda_{cilindro}}$ | 99,19          | 45,59               | 62,46        |
| Intensidade              | <b>98,93</b>   | 50,76               | 67,10        |

Fonte: Os autores (2023).

Ao comparar os parâmetros de qualidade apresentados, percebe-se que os valores de completeza foram mais altos que o 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 que os atributos adotados têm boa capacidade de atribuir os pontos de árvore à sua classe correta, ou seja, eles são confiáveis para detectar esse tipo de feição. Logo, estes resultados estão coerentes com o observado na Figura 7, onde foi notado que grande parte dos pontos supostamente localizados em árvores foram classificados corretamente.

No caso do parâmetro de qualidade nível de acerto, em geral, os resultados foram menos satisfatórios para os atributos entropia dos autovalores, planaridade e intensidade, uma vez que os números de falsos positivos - pontos classificados como árvore, mas que pertencem à classe “não-árvore” - foram expressivos. Verificou-se que os atributos planaridade (para a vizinhança cilíndrica) e intensidade forneceram os melhores resultados em termos de completeza, sendo próximos à 99%. Já os atributos omnivariância e curvatura apresentaram resultados melhores, sendo acima dos 70%. Isso mostra que estes dois descritores possuem maior grau de sensibilidade para detectar árvores que os demais descritores. Esses resultados refletiram positivamente no parâmetro *F-Score*, o qual representa a acurácia geral da classificação a ordem de 81,89% para a omnivariância e 76,25% para a curvatura.

Ao comparar com os resultados médios obtidos por outros trabalhos da literatura (Tabela 2), é possível notar que a ordem de grandeza do *F-Score* é menor que os trabalhos desenvolvidos. No entanto, devemos destacar que a abordagem proposta realiza a detecção usando apenas um descritor e o classificador utilizado não requereu amostras de treinamento e nem treinamento prévio, o que pode ser considerado como uma grande vantagem em relação aos métodos baseados em aprendizagem de máquina. Além disso, destaca-se que a completeza estimada com base na intensidade e planaridade (para a vizinhança cilíndrica), para o método proposto, atingiu valores próximos a 99%, superiores aos mostrados na Tabela 2 para outras abordagens.

Tabela 2 – Média dos parâmetros de qualidade da detecção de árvores obtidos por outras abordagens da literatura.

| Trabalhos                         | Completeza (%) | Nível de acerto (%) | F-Score (%) |
|-----------------------------------|----------------|---------------------|-------------|
| Özdemir et al. (2021)             | 86,82          | 93,07               | 89,83*      |
| Itakura; Miyatani; e Hosoi (2022) | 98,37**        | 97,08**             | 97,72**     |

\* Estimado a partir dos valores de completeza e nível de acerto determinados para dois conjuntos de dados.

\*\* Valores estimados considerando TP, FP e FN para sete conjuntos de dados.

Fonte: Os autores (2023).

## 6 CONCLUSÃO

O presente trabalho avaliou o uso de descritores geométricos 3D e, de forma complementar, o uso das informações de intensidade na detecção de árvores em dados LiDAR obtidos com SVLA. Por meio da análise dos resultados verificou-se que a seleção do tipo de vizinhança exerce grande influência nos resultados de alguns deles, principalmente as entropias dos autovalores e da altura. 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. Adicionalmente, notou-se que a omnivariância, curvatura, planaridade e entropia dos autovalores se destacaram em detectar mais pontos de vegetação que os demais.

O uso da intensidade também se mostrou eficaz na tarefa de distinguir os pontos de árvores dos demais, resultando em uma taxa de detecção (completeza) de aproximadamente 99% em comparação com os dados de

referência da classificação. No entanto, este atributo deve ser adotado de maneira complementar, levando em consideração as informações fornecidas por outros descritores. Por exemplo, uma classificação em duas etapas utilizando a intensidade e um atributo geométrico pode trazer resultados satisfatórios para a detecção de árvores.

Logo, a realização deste trabalho abriu espaço para outras investigações acerca da combinação de descritores na detecção de árvores em dados LiDAR. Além disso, estudos a respeito da possível influência do tamanho da vizinhança nos resultados dos descritores podem ser explorados.

## Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES; ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pela concessão da bolsa de Mestrado ao primeiro autor (proc. nº 132843/2020-0); e à Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP (Proc. 2019/05268-8 e 2020/12481-7).

## Contribuição dos Autores

O autor C.J.A foi responsável pela curadoria dos dados, metodologia, desenvolvimento do software, análise e redação (minuta inicial, revisão e edição). Os autores M.G. e R.C.S. foram responsáveis pela conceptualização, metodologia, análise, revisão de texto e administração do projeto.

## Conflitos de Interesse

Os autores declaram que não há conflito de interesse.

## Referências

- 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, SP, 88p, 2017.
- BLOMLEY, R. et al. 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.
- 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. et al. 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.
- DEMANTKÉ, J. et al. 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, T. et al. 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. et al. 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, jun. 2019.

- DOS SANTOS, R. C. et al. Automatic Building Change Detection Using Multi-Temporal Airborne Lidar Data. **2020 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. et al. The use of Otsu algorithm and multi-temporal airborne LiDAR data to detect building changes in urban space. **Applied Geomatics**, 24 abr. 2021.
- EL-SHEIMY, N.; VALEO, C.; HABIB, A. **Digital terrain modeling: acquisition, manipulation, and applications**. Boston: Artech House, 2005.
- 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. et al. Distinctive 3D surface entropy features for place recognition. 2013 European Conference on Mobile Robots. **2013 EUROPEAN CONFERENCE ON MOBILE ROBOTS (ECMR)**. Barcelona, Catalonia, Spain: IEEE, set. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6698843/>>. Acesso em: 25 mar. 2021
- GRUBER, T.; WILLBERG, M. Signal and error assessment of GOCE-based high resolution gravity field models. **Journal of Geodetic Science**, v. 9, n. 1, p. 71–86, 1 jan. 2019.
- GUO, T. et al. Research on Point Cloud Power Line Segmentation and fitting algorithm. **2019 IEEE 4<sup>TH</sup> ADVANCED INFORMATION TECHNOLOGY, ELECTRONIC AND AUTOMATION CONTROL CONFERENCE (IAEAC)**. Chengdu, China: IEEE, dez. 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8997632/>>. Acesso em: 6 ago. 2021
- HAN, X.-F. et al. A comprehensive review of 3D point cloud descriptors. **ArXiv**, v. abs/1802.02297, 2018.
- H'ROURA, J. et al. Salient Spin Images: A Descriptor for 3D Object Recognition. In: 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. et al. 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. et al. 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, A. **Spin-Images A Representation for 3-D Surface Matching**. PhD Thesis—Pittsburgh, PA: Carnegie Mellon University, ago. 1997.
- JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 6th ed 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. et al. 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, I.; SCHENK, T. Perceptual organization of 3D surface points. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Vol. XXXIV, Part 3A. 2002.
- LIU, H. et al. Individual tree identification using a new cluster-based approach with discrete-return airborne LiDAR data. **Remote Sensing of Environment**, v. 258, p. 112382, jun. 2021.
- LIU, Y. et al. 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, Australia: IEEE, 2009. Disponível em: <<http://ieeexplore.ieee.org/document/5384913/>>. Acesso em: 5 ago. 2021
- LU, X. et al. 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.
- MARTINS-NETO, R. P. **Extração de variáveis dendrométricas em árvores de Pinus taeda L. a partir de dados TLS e ALS**. 2016. 187p. Dissertação (Mestrado em Engenharia Florestal). Centro de Ciências Agroveterinárias, Universidade do Estado de Santa Catarina, Lajes, SC.
- 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.
- NASCIMENTO, G.A.G.; GALO, M. 2021, Aplicabilidade dos Dados Obtidos por Sistema LASER Batimétrico Aerotransportado à Cartografia Náutica: Estudo de Caso para o Arquipélago de Fernando de Noronha. **Anuário do Instituto de Geociências**, vol. 44: 37487. [https://doi.org/10.11137/1982-3908\\_2021\\_44\\_37487](https://doi.org/10.11137/1982-3908_2021_44_37487).
- OLIVEIRA, G. R. K.; GALO, M. Extração de contornos de telhados de edificações através da combinação de dados LiDAR e imagens aéreas. **Revista Brasileira de Cartografia**, v. 70, n. 4, p. 1378–1408, 2018.
- OLIVEIRA, R. A.; GALO, M. Classificação de feições na superfície a partir de dados LiDAR e medidas de entropia e desvio padrão das altitudes. **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto**, Campinas, Galoá, 2017. Disponível em: <<https://proceedings.science/sbsr/papers/classificacao-de-feicoes-na-superficie-a-partir-de-dados-lidar-e-medidas-de-entropia-e-desvio-padrao-das-altitudes>> Acesso em: 31 ago. 2021.
- OLIVEIRA, R. A. R. de **Extração de redes de distribuição aéreas 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) do Programa de Pós-Graduação em Ciências Cartográfica, Unesp - Univ. Estadual Paulista, Campus de Presidente Prudente, 2022.
- ÖZDEMİR, S.; AKBULUT, Z.; KARSLI, F.; ACAR, H. 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.
- 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.
- RIBAS, R. P.; ELMIRO, M. A. T. Individualização de Árvores em Ambiente Florestal Nativo Utilizando Métodos de Segmentação em Modelos Digitais Produzidos a partir da Tecnologia Lidar. **Revista Brasileira de Cartografia**, v. 65, n. 4, 31 dez. 2013.
- SHAN, J.; TOTH, C. K. **Topographic LASER Ranging and Scanning - Principles and Processing**. Boca Raton: CRC Press, Taylor & Francis Group, 2009.
- SHAO, J. et al. 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.
- SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. In: SATTAR, A. et al. (Eds.). **AI 2006: Advances in Artificial Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. v. 4304p. 1015–1021.
- SOUSA, L. A. S. E; CENTENO, J. A. S. Modelagem Geométrica de Fachadas usando Nuvens de Pontos LiDAR. **Revista Brasileira de Cartografia**, v. 73, n. 3, p. 870–884, 8 jul. 2021.
- TOMMASELLI, A. M. G. et al. 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, 2018.
- WEINMANN, M. et al. 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. et al. 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.
- 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.
- 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.

### Biografia do autor principal



Cleber Junior Alencar nasceu em Presidente Prudente – SP, no ano de 1997. Possui grau Técnico em Agrimensura (2015) pela ETEC Prof. Dr. Antônio Eufrásio de Toledo. Possui graduação em Engenharia Cartográfica (2019) e mestrado em Ciências Cartográficas (2023) pela Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP. Possui interesse pelos seguintes temas: Sistemas de Varredura a Laser Aerotransportado, Sensoriamento Remoto e Fotogrametria.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.