



ISSN: 2447-3359

REVISTA DE GEOCIÊNCIAS DO NORDESTE

Northeast Geosciences Journal

v. 9, nº 2 (2023)

<https://doi.org/10.21680/244-3359.2023v9n2ID32658>



Descritores de Forma 3D para Classificação de Objetos em Nuvens de Pontos Lidar Terrestres

3d Shape Features for Objects Classification From Terrestrial Lidar Point Clouds

Jorge Antonio Silva Centeno¹; Elizabete Bugalski de Andrade Peixoto²

¹ Universidade Federal do Paraná/Departamento de Geomática, Curitiba/PR, Brasil. Email:centeno@ufpr.br

ORCID: <https://orcid.org/0000-0002-2669-7147>

² Lactec, Setor de Meio Ambiente, Curitiba/PR, Brasil. Email: elizabete.peixoto@lactec.com.br

ORCID: <https://orcid.org/0000-0001-7430-8727>

Resumo: O laser scanner móvel é uma ferramenta valiosa para coletar informações 3D, especialmente em regiões urbanas, onde objetos verticais, como paredes, postes e árvores, precisam ser mapeados. As nuvens de pontos coletadas podem ser usadas para segmentar objetos e classificá-los de acordo com sua forma. No entanto, as etapas de segmentação e classificação ainda precisam de ferramentas para analisar nuvens de pontos 3D. Neste artigo é apresentado um método para descrever a forma 3D a partir de nuvens de pontos obtidas por scanner laser móvel dentro do contexto de classificação de mobiliário urbano. O objetivo inicial é descrever a forma de objetos instalados em postes, mas a abordagem pode ser estendida a outros objetos. Para tanto, a distribuição dos pontos é analisada com o auxílio dos autovalores da matriz variância-covariância e os respectivos autovalores. Propõe-se a utilização de dois parâmetros, um relacionado à planaridade e outro ao alongamento, que são normalizados na faixa entre zero e um, o que permite uma descrição mais fácil da forma em termos de apenas dois termos bem conhecidos.

Palavras-chave: Análise de forma, Processamento de nuvens de pontos; LiDAR; Modelagem 3D.

Abstract: A mobile laser scanner is a valuable tool to collect 3D information especially in urban regions, where vertical objects, like walls, poles and trees, need to be mapped. The collected point clouds can be used to segment objects and classify them according to their shape. Nevertheless, the segmentation and classification steps still need tools to analyze 3D point clouds. In this paper it is introduces a method to describe 3D shape from point clouds obtained by mobile laser scanner within the context of classification of urban furniture. The initial aim is to describe the 3D shape of objects located at the top of poles, but the approach can be extended to other objects. For this purpose, the distribution of the points is analyzed with help of the eigenvalues of the variance-covariance matrix. It is proposed the use of two parameters, one related to planarity and another to elongation, that are normalized in the range between zero and one, which allows easier description of the shape in terms of just two well-known terms.

Keywords: Shape features; Point cloud processing; LiDAR; 3D Modelling.

Recebido: 23/05/2023; Aceito: 14/11/2023; Publicado: 22/11/2023.

1. Introdução

O cenário de levantamentos experimentou o efeito dos recentes desenvolvimentos em termos de sistemas móveis, como os sistemas móveis de laser scanner capazes de coletar uma densa nuvem de pontos 3D em uma grande área. Este desenvolvimento abriu novos desafios para a comunidade científica em termos de métodos para detectar e modelar objetos 3D, especialmente em áreas urbanas. Há estudos sobre modelagem de fachadas, como Faltýnová et al (2016) ou Haghghatgou et al (2022), árvores, como Sirmacek, e Lindenbergh (2015) ou Suwardhi et al (2022), e postes, como Fukano e Masuda (2015), Shi et al (2018) ou Li, e Cheng (2020). Em relação a este último, a tarefa é mapear os postes existentes e distinguir entre seus usos com base em sua forma e, principalmente, na forma dos objetos instalados no seu topo.

Os métodos de detecção de postes têm semelhança com métodos voltados para a detecção de árvores, elementos verticais da paisagem. Alguns trabalhos, como Yu et al (2015) ou Li e Cheng (2020) são exemplos de processamento de nuvens de pontos para detecção de postes com LiDAR terrestre. Os métodos de detecção e classificação de postes também estão incluídos na detecção mais geral do problema de detecção de infraestrutura urbana e são discutidos em trabalhos como Fukano e Masuda (2015), Li et al (2016) ou Li et al (2019).

De maneira similar a métodos para detectar e classificar o mobiliário urbano, os métodos de detecção de postes geralmente começam com a classificação dos pontos do terreno, o que permite calcular uma representação normalizada que armazena a altura dos objetos acima do terreno. Os métodos de filtragem do terreno a partir do LiDAR aéreo podem ser aplicados para este fim. Ao lidar com dados de laser scanner terrestre móvel, foram propostas soluções alternativas para extrair o terreno, como por exemplo em Ibrahim e Lichti (2012), que propõem dividir a nuvem de pontos em dois segmentos principais, terreno e não-terreno, analisando a densidade da nuvem de pontos. Assume-se que os pontos no terreno estão em regiões de menor densidade e, portanto, o número de pontos dentro de uma esfera com raio pré-definido é analisado. Yan et al (2016) também aplicam a filtragem de pontos do terreno com base na distribuição estatística dos pontos 3D. Uma abordagem mais complexa é descrita em Denis et al (2010), que propõem um algoritmo baseado em crescimento de regiões, tomando como semente o ponto com a altura mínima de cada linha digitalizada. Existem outras opções para isolar objetos semelhantes a postes na literatura. Por exemplo, Yang e Dong (2013) propuseram analisar a vizinhança de um ponto em busca de regiões planas que estariam associadas a muros e estradas e, portanto, podem ser descartadas. Em Yu et al (2015) os pontos terrestres foram segmentados dividindo a nuvem em voxels e computando sua altura. Com base em um limiar de altura, os pontos no terreno são detectados e os objetos acima do terreno separados para posterior classificação. Para facilitar a detecção de objetos semelhantes a postes, as paredes podem ser removidas com antecedência porque geralmente são grandes manchas planas localizadas à beira das ruas.

A partir deste ponto, as técnicas de detecção de postes variam. Entre as mais conhecidas estão as técnicas de fatiamento e aquelas baseadas na detecção de cilindros, como descrito em Huang e You (2005). O fatiamento consiste em definir uma superfície paralela ao terreno a uma altura especificada pelo usuário. Este método, também descrito em Luo e Wang (2005), assume que os postes são estruturas verticais e interceptarão essa superfície virtual. Para melhorar o método, várias superfícies são produzidas em diferentes alturas. Partindo do pressuposto de que os postes são cilíndricos, Press e Austin (2004) e Díaz-Vilarino et al (2015) propõem aplicar a transformada de Hough para identificar os pontos pertencentes a um círculo. Outra forma de modelar a seção dos postes é aplicando o método RANSAC para detecção de estruturas circulares, como descrito em Bolles e Fischler (1981). Uma abordagem diferente é descrita em Rodríguez-Cuenca et al (2015). Eles propõem o uso de um esquema de classificação baseado na distância de Mahalanobis. Primeiro, a nuvem de pontos é segmentada e os clusters verticais (pilares) são detectados usando voxels. Em seguida, o método de Reed e Yu (1990) (baseado na distância de Mahalanobis) é aplicado para detectar pilares que representam um elemento vertical.

Em termos de classificação, o foco é a análise do topo do poste, onde objetos como placas ou lâmpadas podem ser instalados. A abordagem pode ser muito simples, baseada no limiar de altura (Yu et al, 2015) ou mesmo incluir métodos de inteligência artificial, como mostrado em Guan et al (2015). A maioria das abordagens para extrair objetos semelhantes a postes são baseadas em características de forma, porque fornecem pistas geométricas importantes. Por exemplo, depois que os objetos semelhantes a postes são detectados, Fukano e Masuda (2015) propõem dividir a nuvem de pontos em partes espacialmente mais simples: poste e objeto no topo (placa, lâmpada, caixa, etc.). Quando se trata de analisar o objeto na parte superior, a nuvem de pontos dessa região é classificada usando as seguintes variáveis: Tamanhos da caixa delimitadora; Autovalores; Razões de autovalores: Números de subconjuntos (elementos); Distâncias entre elementos e a Razão entre as direções das bordas.

Outros estudos foram realizados com essa finalidade e apresentados na literatura. Alguns deles são discutidos abaixo. Uma prática comum é usar os autovalores ($\lambda_1, \lambda_2, \lambda_3$) calculados a partir da matriz de covariância das coordenadas 3D da nuvem de pontos. Um resumo das características propostas está listado nas tabelas 1, 2 e 3.

Tabela 1 – Comparação das características que descrevem o tamanho 3D da nuvem de pontos.

Característica	Fórmula	Fonte
Onivariância	$O = \lambda_1 \lambda_2 \lambda_3$	Weinmann et al. (2013)
soma dos autovalores	$Su = \lambda_1 + \lambda_2 + \lambda_3$	Weinmann et al. (2013)

Fonte: Os autores (2023).

Duas características utilizadas para descrever o volume são a soma dos autovalores e a onivariância (Tabela 1). Como a soma dos autovalores é igual à variância total, é razoável usar a soma dos autovalores como medida de volume ou tamanho. A onivariância é a média geométrica dos autovalores e descreve o tamanho médio da nuvem.

A descrição da forma é mais complexa e alguns estudos se dedicaram a propor parâmetros de forma baseados nos autovalores. Um aspecto comum destes estudos é o fato de que eles foram originalmente propostos para segmentar nuvens de pontos 2-1/2D. Portanto, características como curvatura e planaridade são comumente usadas. Para classificar e discutir estes descritores, aqueles encontrados mais frequentemente na literatura foram agrupados e listados na tabela 2. Embora possam receber nomes diferentes para uma mesma propriedade, procurou-se criar três categorias: uma relacionada ao alongamento, a segunda relacionada à planaridade e a última à variação volumétrica.

A linearidade também pode ser descrita como alongamento e é caracterizada pela dispersão relativamente maior em uma direção e dispersão muito pequena em torno desse eixo. Isso é descrito pelo tamanho relativo do primeiro autovalor, por exemplo, em Weinmann et al (2013), Li et al (2016) ou Fukano e Masuda (2015). Uma prática comum, observada na Tabela 2, é comparar o primeiro e o segundo autovalor.

Para descrever objetos planares, as abordagens variam, mas um aspecto comum é medir o contraste entre o segundo e o terceiro autovalor, como em Weinmann et al (2013), Li et al (2016) ou Ordoñez et al (2017). Por outro lado, Yokohama et al (2011) utilizam a diferença entre o primeiro e o último autovalor.

Descritores para descrever objetos que têm dimensão considerável ao longo dos três eixos principais (3D) também são propostas e basicamente utilizam o tamanho relativo do terceiro autovalor: Weinmann et al (2013) propõem o uso da esfericidade; Li et al (2016) ou Ordoñez et al (2017) o fator de volumetria. A variação da curvatura de uma superfície, proposta por Rusu (2009), baseia-se no tamanho relativo do menor autovalor, podendo também ser vinculada a uma medida para distinguir planaridade e volumetria. Essa característica de curvatura é apresentada como um descritor de forma em Teo e Chiu (2016). Yokohama et al (2011) preferem aplicar o valor do menor autovalor corrigido por um fator ajustado.

Existem outros descritores na literatura, resumidos na tabela 3, que podem auxiliar na etapa de classificação. Eles estão relacionados a outras propriedades, como anisotropia e autonomopia. Como a anisotropia descreve o fato da nuvem estar alinhada em uma direção, ela também pode ser incluída como uma medida de alongamento. A autonomopia pode estar ligada ao tamanho.

A comparação revela alguns fatos comuns, por exemplo, a linearidade é medida comparando o primeiro e o segundo autovalor. A planaridade é dada pela comparação do segundo e terceiro autovalor. Finalmente, a dispersão da nuvem em três dimensões é medida comparando-se o terceiro e o primeiro autovalor.

Avanços recentes em termos de *deep learning* também introduzem soluções para o problema. Mas, neste caso, as características são extraídas por uma rede neural. Exemplos podem ser encontrados em Guan et al (2018), que propuseram um classificador supervisionado baseado em um modelo de *deep learning* tipo máquina de Boltzmann Gaussian-Bernoulli, ou Huang J. e You (2016), que usaram Rede Neural Convolutiva 3D. A vantagem das abordagens de aprendizagem profunda é que elas não exigem características espaciais para serem propostas "a priori".

Na última década, as redes neurais profundas fizeram contribuições notáveis para a segmentação e classificação de imagens usando a estrutura raster de imagens e vídeos. Uma revisão abrangente e atualizada do uso de modelos de aprendizagem profunda para segmentar e classificar nuvens de pontos é apresentada em Fernandes et al (2020). Em um primeiro estágio, sua aplicação para processar nuvens de pontos LiDAR encontrou dificuldades porque tais nuvens de pontos têm distribuição irregular e não são estruturadas como imagens. Portanto, tornou-se difícil para os modelos de aprendizagem profunda estender o conceito de convolução para processamento de nuvem de pontos. Alguns esforços

foram feitos para aplicar o conceito de convolução aos voxels. Hrutka et al (2022) aplicaram o conceito de voxels para segmentar nuvens de pontos e comprovaram a vantagem de reduzir assim o número de pontos e, portanto, o tempo de processamento. Por outro lado, o detalhe é perdido em locais onde a densidade da nuvem é alta. Outros pesquisadores tentaram projetar a nuvem de pontos 3D em um espaço 2D para aplicar a convolução 2D, por exemplo, computando imagens da nuvem de pontos considerando diferentes pontos de vista, como Su et al (2015), ou projetando descritores 3D em um espaço 2D, como Alonso et al (2020). Conforme Alonso et al (2020), a projeção causa perda da acurácia dos dados originais, o que resulta em classificação imprecisa, embora tais métodos sejam mais rápidos.

Pesquisas mais recentes desenvolveram modelos de aprendizagem profunda que podem processar dados 3D esparsos para segmentar e classificar nuvens de pontos, como PointNet ou PointNet++, propostos por Qi et al (2017a) e Qi et al (2017b). O PointNet++, um aprimoramento do PointNet, agrupa pontos 3D em regiões e calcula descritores locais para cada região usando a rede convolucional PointNet. Para isso, a nuvem de pontos é normalizada em termos de orientação e tamanho e, em seguida, uma série de características é calculada para cada ponto de acordo com sua posição e contexto dentro da nuvem. Métodos que são baseados em modelos de aprendizagem profunda usam descritores computados pela máquina, desconhecidos para o usuário e, portanto, difíceis de entender. Tais parâmetros são derivados de um grande conjunto de amostras e são altamente dependentes da representatividade das amostras. Por outro lado, descritores propostos pelo ser humano também podem ser usados para alimentar redes neurais, como mostrado em Özdemir et al (2019), o que aceleraria o processo, mas reduziria o aspecto de automação. Nosso trabalho é uma contribuição dentro da última alternativa e se concentra na compreensão dessas características espaciais. Portanto, o presente estudo concentra-se na discussão das características espaciais para fins de classificação, uma vez que são uma prática comum em muitos estudos de classificação de postes.

Tabela 2 – Comparação de descritores da forma 3D.

Fonte	Linearidade	Planaridade	Volume
Weinman et al. (2013)	$1 - \frac{\sigma_2}{\sigma_1}$	$(\frac{\sigma_2 - \sigma_3}{\sigma_1})$	$\frac{\sigma_3}{\sigma_1}$
Li et al.(2016)	$1 - (\frac{\sigma_2}{\sigma_1})^{1/2}$	$(\frac{\sigma_2^{1/2} - \sigma_3^{1/2}}{\sigma_1^{1/2}})$	$(\frac{\sigma_3}{\sigma_1})^{1/2}$
Rusu (2009), Teo and Chie (2016)		$\frac{\sigma_3}{(\sigma_1 + \sigma_2 + \sigma_3)}$	
Ordoñez et al (2017)		$\frac{\sigma_3 / (\sigma_1 \sigma_2)}{\sigma_2 / \sigma_3}$	$\frac{\sigma_3 \sigma_1}{\sigma_2^2}$
Demantke et al (2011)	$(\frac{\sigma_1^{1/2} - \sigma_2^{1/2}}{\sigma_3^{1/2}})$	$(\frac{\sigma_2^{1/2} - \sigma_3^{1/2}}{\sigma_1^{1/2}})$	$(\frac{\sigma_3}{\sigma_1})^{1/2}$
Yokohama et al (2011) *a,b are adjustment coefficients	$\sigma_1 - a \sigma_2$	$\sigma_1 - \sigma_3$	$b \sigma_3$
Fukano and Masuda (2015)	σ_1 / σ_2	$\frac{\sigma_1}{\sigma_2}$ $\frac{\sigma_1}{\sigma_3}$	

Fonte: Os autores (2023).

Tabela 3 – Outras características 3D listadas na literatura.

Característica	Fórmula	Fonte
Anisotropia	$A = 1 - \frac{\sigma_3}{\sigma_1}$	Weinman et al. (2013)
Autoentropia	$E = \sigma_1 \ln(\sigma_1) + \sigma_2 \ln(\sigma_2) + \sigma_3 \ln(\sigma_3)$	Weinman et al. (2013)
Relação	$\frac{\sigma_2}{\sigma_3}$	Fukano and Masuda (2015)

Fonte: Os autores (2023)

2. Metodologia

Para derivar descritores espaciais de uma nuvem de pontos, a análise de componentes principais é aplicada. Considerando um conjunto de coordenadas 3D, a dispersão dos pontos em torno de seu centroide no espaço tridimensional ($x_1 x_2 x_3$) é dada pela matriz de variância-covariância (C). A matriz de variância-covariância é real, positiva, semidefinida e, portanto, seus autovalores são sempre maiores ou iguais a zero. Os autovalores são os escalares que satisfazem a equação 1.

$$\det (C - \lambda I) = 0 \quad (1)$$

Autovalores e autovetores podem ser usados para calcular os componentes principais das coordenadas da nuvem de pontos. Com os autovetores, a transformação dos componentes principais pode ser aplicada, de acordo com a equação 2, para obter a nuvem de pontos transformada.

$$Y = X * V \quad (2)$$

Onde:

X ($x_1 x_2 x_3$) são as coordenadas originais;

Y ($y_1 y_2 y_3$) são as coordenadas transformadas;

V é uma matriz 3x3 onde cada coluna armazena um autovetor.

O resultado é um novo sistema tridimensional, paralelo às direções principais da dispersão da nuvem de pontos, como mostra a Figura 1, onde são ilustradas três situações: a) um caso em que não há direção principal na dispersão da nuvem de pontos; b) uma nuvem de pontos alongada e c) uma dispersão plana.

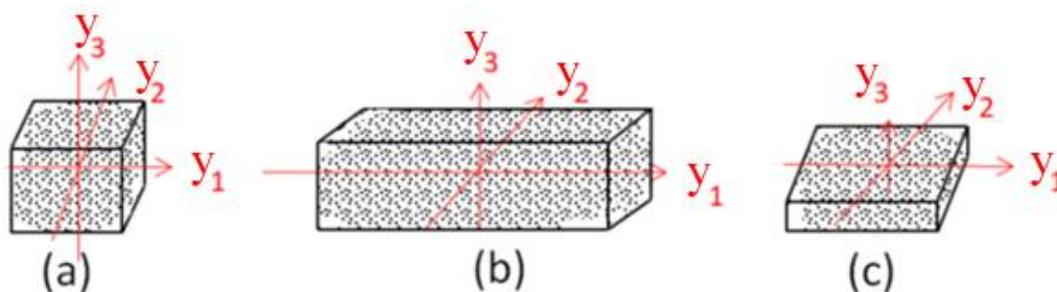


Figura 1 – Os autovetores de diferentes formas 3D.

Fonte: Os autores (2023).

A partir da teoria das componentes principais, sabe-se que a direção principal é orientada paralelamente ao autovetor calculado a partir do maior autovalor. A variância total no conjunto original é dada pela soma das variâncias em cada eixo e também é igual à soma dos autovalores. Alternativas para a descrição da variação global das coordenadas podem ser obtidas utilizando-se a média geométrica (onivariância).

Como a quantidade da variância total no conjunto original é dada pela soma dos autovalores, a porção relativa da variância explicada por cada componente é dada pela razão entre o tamanho do autovalor associado e a variância total:

$$a_i = \lambda_i / (\lambda_1 + \lambda_2 + \lambda_3) \quad (3)$$

com $\lambda_1 > \lambda_2 > \lambda_3$

Os autovalores normalizados (a) podem ser usados em vez dos autovalores originais, de acordo com a equação 3. Essa prática evita problemas de escala (El-Halawany, 2013) e a análise pode se concentrar na forma. A soma dos autovalores normalizados é sempre um, como mostra a equação 4. Esta é a equação de um plano no espaço tridimensional, como mostrado na figura 2, uma propriedade que pode ser usada para simplificar a análise.

$$a_1 + a_2 + a_3 = 1 \quad (4)$$

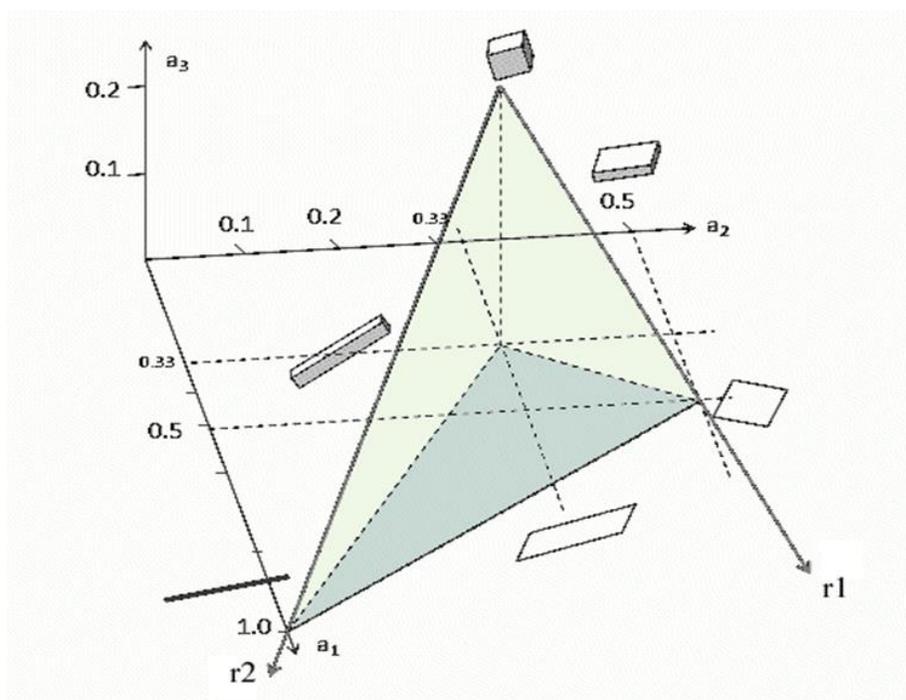


Gráfico 2 – Representação tridimensional do plano descrito na Equação 4.
 Fonte: Os autores (2023).

Como existem algumas restrições que derivam da definição dos autovalores ($1 > a_1 > a_2 > a_3 > 0$) há uma região limitada nesse plano que o triplete (a_1, a_2, a_3) pode ocupar. Por exemplo, enquanto a_1 , pode variar entre 0 e 1, a_2 varia entre 0 e 1/2 porque, por definição, não pode ser maior que a_1 . Da mesma forma, a_3 varia de zero a 1/3. Conforme ilustrado na figura 2, três casos extremos serão considerados:

- Isotrópico: Na situação extrema os autovalores são iguais (1/3, 1/3, 1/3)
- Anisotrópico, alongado: a forma é próxima a uma linha e o primeiro autovalor é maior que os demais. Uma linha ideal teria segundo e terceiro autovalores nulos (1,0,0)
- Anisotrópico, planar: O terceiro autovalor é relativamente muito pequeno. O caso extremo seria (1/2 1/2 0), um disco ou um quadrado. Dependendo da relação dos primeiros autovalores, a forma também pode ser alongada.

Considerando o ponto (1/3, 1/3, 1/3) como a nova origem, pode-se desenhar duas linhas (c_1 e c_2) que descrevem planaridade ou alongamento. Essas linhas são desenhadas na figura 2 como r_1 e r_2 .

$$r_1: (a_1, a_2, a_3) = (1/3, 1/3, 1/3) + d (1/6, 1/6, -1/3) \tag{5}$$

$$r_2: (a_1, a_2, a_3) = (1/3, 1/3, 1/3) + e (2/3, -1/3, -1/3) \tag{6}$$

O plano onde se encontram os pontos (a_1, a_2, a_3) pode ser parametrizado utilizando a origem (1/3, 1/3, 1/3) e os dois vetores direcionais r_1 e r_2 , conforme apresentado na equação 7. A localização do ponto no plano, em relação à origem seguindo as direções r_1 e r_2 é dada pelos escalares "s" e "t" e é restrita por $s+t \leq 1$;

$$(a_1, a_2, a_3) = (1/3, 1/3, 1/3) + s 1/6 (1,1,-2) + t 1/3 (2, -1, -1) \tag{7}$$

O agrupamento dos termos resulta na equação 8.

$$(a_1-1/3, a_2-1/3, a_3-1/3) = s 1/6 (1,1,-2) + t 1/3 (2, -1, -1) \tag{8}$$

A equação 8 é composta por duas operações básicas: um deslocamento e a soma de dois vetores, sendo um $1/6(1 \ 1 \ -2)$ responsável pela descrição da planaridade e o segundo $1/3(2 \ -1 \ -1)$ pela descrição do alongamento. Fazendo $b_i = a_i - 1/3$, obtém-se três equações (Equações 9-11), onde se pode provar que a terceira equação é uma combinação linear das outras duas. Isso não é surpreendente, pois a_3 também pode ser derivado de a_1 e a_2 , pois $a_3 = 1 - a_1 - a_2$.

$$b_1 = \frac{1}{6} s + \frac{2}{3} t \quad (9)$$

$$b_2 = \frac{1}{6} s - \frac{1}{3} t \quad (10)$$

$$b_3 = -\frac{1}{3} s - \frac{1}{3} t \quad (11)$$

Então, os parâmetros podem ser calculados resolvendo as equações 9 e 10. Chamamos de planaridade "s" e alongamento "t". Ambos os parâmetros variam entre zero e um, mas sua soma não pode ser maior que um.

$$s = 2 b_1 + 4 b_2 \quad (12)$$

$$t = b_1 - b_2 \quad (13)$$

ou em termos dos autovalores normalizados

$$s = 2 a_1 + 4 a_2 - 2 \quad (14)$$

$$t = a_1 - a_2 \quad (15)$$

As equações 14 e 15 permitem descrever a forma de uma nuvem de pontos 3D usando dois descritores fáceis de entender. O primeiro relacionado à planaridade da nuvem, quando duas dimensões são maiores que a terceira, e o outro relacionado às formas alongadas. Ambos os termos, planaridade e alongamento são fáceis de entender e, portanto, práticos para descrever formas.

3. Resultados e discussão

Para avaliar a eficiência dos descritores propostos, dois experimentos são apresentados. No primeiro, nuvens de pontos artificiais foram produzidas com diferentes formas. Esses objetos sintéticos podem ser usados para estudar e analisar o desempenho dos descritores. No segundo experimento, são analisadas nuvens pontuais reais de objetos presos a postes. Nas situações reais, as nuvens de pontos não cobrem os objetos inteiros, pois normalmente apenas um lado é varrido durante um levantamento com laser terrestre móvel (mobile mapping) móvel.

Experimento com nuvens de pontos artificiais

Para avaliar a validade dos descritores, foi produzida uma nuvem artificial de pontos com a equação da esfera com raio igual a um. Foram gerados sistematicamente 1000 pontos na superfície da esfera e, em seguida, foram introduzidas deformações paralelas ao eixo e ruído aleatório variando de 0 a 1 em cada eixo. Finalmente, a nuvem de pontos foi girada em relação ao eixo original. Na Figura 3 a nuvem de pontos de um elipsoide onde a dispersão x ao longo dos eixos tem uma proporção 4:3:1.

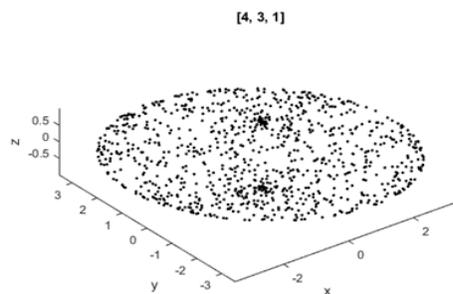


Figura 3 – Nuvem de pontos artificiais descrevendo a superfície de um elipsoide.

Fonte: Os autores (2023).

Variando o tamanho relativo das dispersões, diferentes elipsoides foram computados e classificados como "planas" se $s > 0,5$ e "alongadas" se $t > 0,5$. Alguns exemplos estão listados na tabela 1, para fins de ilustração. As nuvens que não foram classificadas como planas ou alongadas foram omitidas (Não definido).

Tabela 4 – Características estáticas computadas para elipses com proporção variável.

[proporção]	s	t	forma	[proporção]	s	t	forma
[1 0 0]	0.000	1.000	alongado	[4 1 1]	0.101	0.743	alongado
[1 1 0]	0.990	0.010	Planar	[4 2 0]	0.395	0.605	alongado
[2 1 0]	0.395	0.605	alongado	[4 2 1]	0.183	0.551	alongado
[2 2 0]	0.990	0.010	Planar	[4 3 0]	0.713	0.287	Planar
[3 1 0]	0.197	0.803	alongado	[4 3 1]	0.517	0.266	Planar
[3 1 1]	0.161	0.592	alongado	[4 3 2]	0.074	0.218	Não definido
[3 2 0]	0.609	0.391	Planar	[5 4 2]	0.331	0.190	Não definido
[4 1 0]	0.116	0.884	alongado	[5 4 3]	0.067	0.128	Não definido

Fonte: Os autores (2023).

Teste com dados reais do scanner terrestre 3D

Neste experimento, são classificados os objetos localizados no topo de postes em uma cena urbana. Um levantamento LiDAR terrestre no campus da Universidade Federal do Paraná foi usado para obter nuvens de pontos de objetos reais. Os dados utilizados neste estudo foram captados por meio do Sistema Móvel Pegasus One e estão descritos em Peixoto (2016). O sistema calcula a trajetória com base no GNSS e IMU a bordo e, em seguida, permite computar uma nuvem de pontos também com informações de intensidade. A área de estudo está localizada dentro do campus da Universidade Federal do Paraná, no município de Curitiba, Brasil. O scanner móvel levou duas horas para varrer 2,3 quilômetros lineares. A densidade média de pontos para a área de estudo foi de 2.400 pontos por m² e foram considerados suficientes para detalhar os postes e placas.

Primeiramente, os pontos do terreno foram classificados pelo método *Classify Hard Surface*. Os demais pontos, associados a prédios, postes, carros e outros objetos, foram projetados no plano horizontal, utilizando-se uma grade como estrutura básica. O tamanho da malha foi estabelecido de acordo com a relação entre a resolução espacial da nuvem de pontos e o diâmetro esperado dos postes. A ideia é que, se muitos pontos caírem em um poste ou outra estrutura vertical, eles serão projetados na mesma célula da grade. Assim, o número de pontos em cada célula foi calculado e armazenado como um valor de grade. Na etapa seguinte, os valores da malha foram separados de acordo com a concentração de pontos (densidade de pontos), possibilitando a identificação de estruturas verticais. As regiões obtidas foram marcadas usando o algoritmo de componentes conectados. Na etapa seguinte, o poste é segmentado de acordo com a variação do diâmetro e o topo do poste é obtido.

Depois que a parte superior é separada, uma nuvem de pontos reduzida está disponível. Assume-se que o conjunto de pontos contém apenas pontos do poste. Embora, em alguns casos, o topo possa ser misturado com outros objetos, como vegetação. A Figura 4 exibe um exemplo da nuvem de pontos (em vermelho) de um escudo localizado na parte superior de um polo (preto).

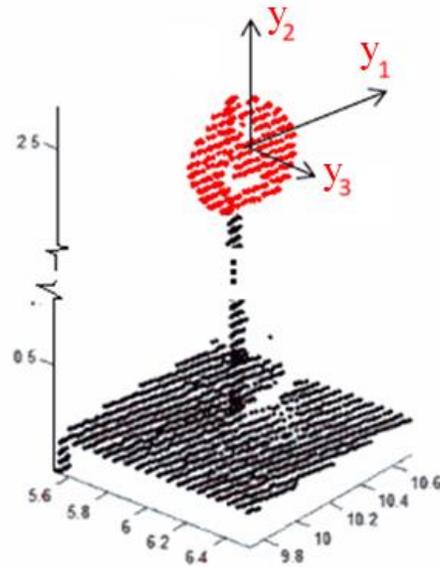


Figura 4 – Exemplo de um polo segmentado com um objeto ligado a ele (vermelho) e a direção dos autovetores principais.

Fonte: Os autores (2023).

Cinco objetos diferentes foram considerados na etapa de classificação. Eles são exibidos na Figura 5. e1) Lâmpada com caixa; (e2) Lâmpada com quatro elementos; (e3) Lâmpada com bola de vidro; (e4) Escudo redondo; (e5) Escudo quadrado. A terceira classe de lâmpadas consiste em uma esfera de vidro e, portanto, é difícil de modelar a partir da nuvem de pontos, por causa de sua transparência. A primeira classe é uma estrutura mais complexa porque é composta por dois elementos, uma caixa e uma pequena lâmpada horizontal.

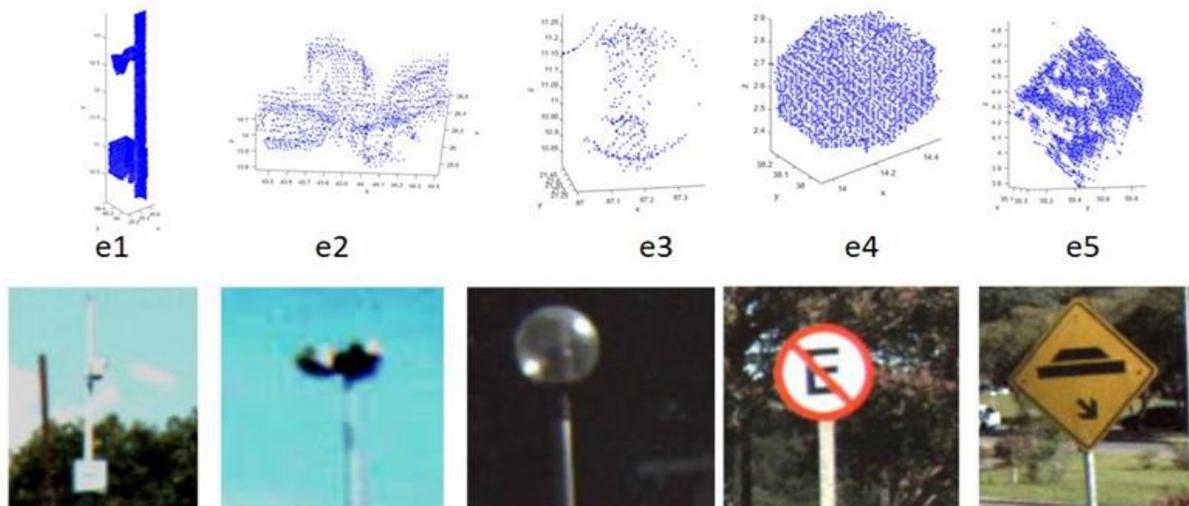


Figura 5 – Tipos de objetos no topo dos postes: (A) Lâmpada A; (B) Lâmpada com quatro elementos; (C) Lâmpada com esfera de vidro; (d) Escudo redondo; (E) Escudo quadrado.

Fonte: Adaptado de Peixoto (2016).

Os autovalores normalizados foram calculados para sete amostras de cada classe. As características de linearidade e planaridade resultantes estão plotadas na figura 6 para ilustrar a discussão.

A primeira classe (e1) é composta por objetos alongados, portanto a característica s que os descreve é muito alta e o fator t quase nulo. Por outro lado, as classes e4 e e5 (placas redondas e quadradas) apresentam descritores st muito diferentes, com o parâmetro s alto e o parâmetro t baixo. Os objetos pertencentes às classes e2 e e3 não são planos, nem lineares. Isso é visível no espaço st porque eles têm fatores st abaixo de 0,8. No entanto, eles não são suficientemente arredondados para representar um volume significativo. As lâmpadas com esfera de vidro (classe e3) podem ser descritas como redondas. Mas como o vidro é transparente para o pulso de laser, menos pontos são retroespalhados, e a forma não é caracterizada. Os elementos interiores da lâmpada são mais visíveis, dando a esta classe uma forma alongada. A lâmpada que é composta por quatro elementos é plana e horizontal. Portanto, é mais planar, e esse fato é visível no gráfico, pois os valores de st estão próximos ao canto inferior direito.

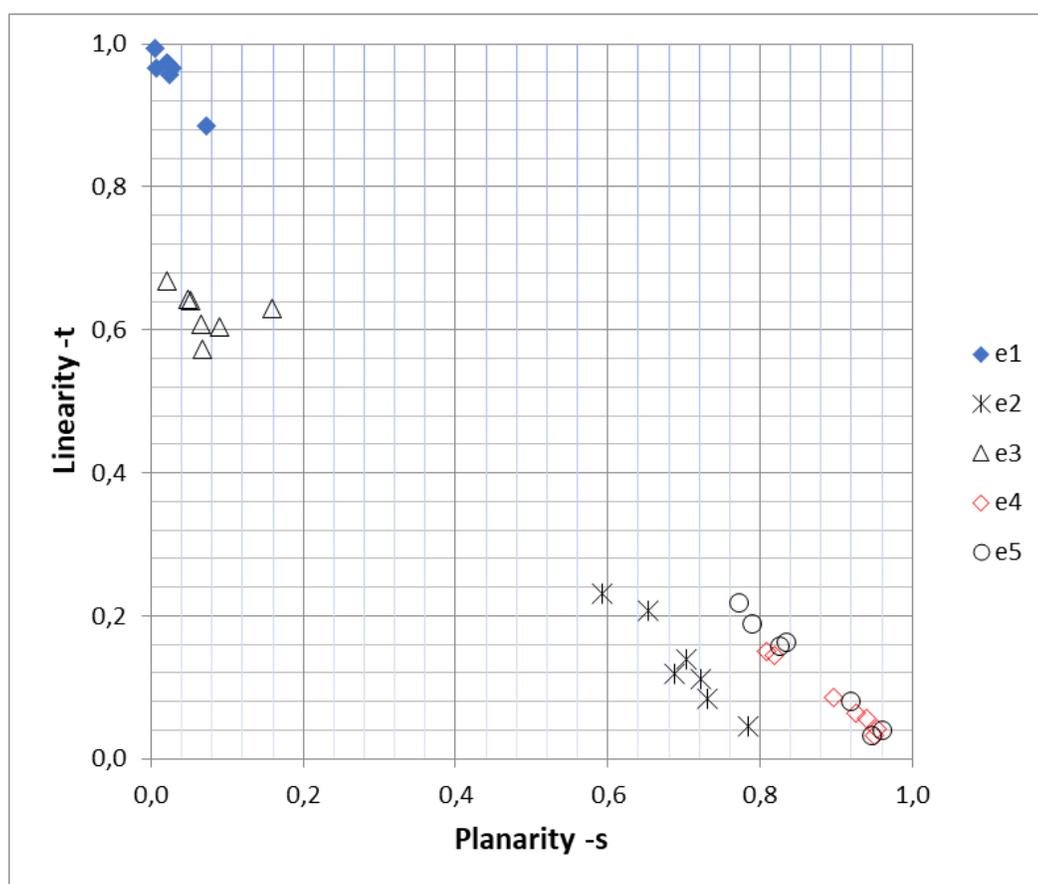


Figura 6 – Posição de cinco grupos de objetos diferentes no espaço st .

Fonte: Os autores (2023).

A forma real dos objetos não é reproduzida na nuvem de pontos porque, em alguns casos, partes das superfícies não são visíveis. Isso pode ocorrer devido à oclusão como mostrado na nuvem de pontos e5 da figura 5; ou, em alguns casos, apenas um lado do objeto é representado devido ao procedimento de digitalização. No entanto, os resultados refletem as diferenças entre esses objetos.

Vale ressaltar que a variação dentro das classes é paralela à reta que passa por (1,0) e (0,1). Isso significa que, para uma determinada classe, a soma das características tende a ser uma constante, como mostra a tabela 5. Valores médios extremamente altos são visíveis para classes de objetos com forma mais definida, alongadas ou planas (classes e1, e4 e e5). Por outro lado, a soma dos descritores é menor para os objetos que são mais tridimensionais. No entanto, o desvio

padrão ainda é pequeno. O maior desvio padrão da classe e3 pode ser explicado pela forma variável das nuvens de pontos desse grupo. A variação é causada pela falta de pontos refletidos e distribuição irregular dos pontos refletidos por causa da esfera de vidro.

Os experimentos com nuvens de pontos sintéticas e dados reais permitiram verificar a adequação do uso das características de "alongamento" e "planaridade" propostas para classificar nuvens de pontos de acordo com a forma. Ambos os parâmetros não consideram o tamanho da nuvem, pois são calculados a partir dos autovalores normalizados. Para completar a descrição, a soma dos autovalores pode ser incluída.

Tabela 5 – Média e desvio padrão da soma das características estáticas.

classe	Média(s+t)	Std(s+t)
E1	0.984	0.015
e2	0.830	0.018
e3	0.696	0.045
e4	0.981	0.015
e5	0.999	0.009

Fonte: Os autores (2023).

Comparando-se as características propostas "alongamento" e "planaridade" com aquelas listadas na literatura e mostradas na tabela 2, algumas semelhanças podem ser encontradas. A característica de planaridade "s" é a soma ponderada do primeiro e segundo autovalores, dando peso duplo ao segundo. Como a soma dos autovalores normalizados é igual a um, essa característica compara indiretamente os dois primeiros autovalores com o terceiro e se assemelha às equações propostas na literatura, como Rusu (2009), Teo e Chie (2016) e Ordoñez et al (2017). O traço de linearidade "t" é a diferença entre o primeiro e o segundo autovalores normalizados, que também está presente nas formulações utilizadas por Weinman et al (2013), Demantke et al (2011) ou Yokohama et al (2011). A vantagem é que as características "s" e "t" são invariantes de escala e variam entre zero e um.

A opção de usar dois recursos e o entendimento de seu domínio permite reduzir o tamanho do vetor de entrada no processo de classificação. Por exemplo, Özdemir et al (2019) usam pelo menos 11 descritores espaciais, mais de altura, calculadas a partir de LiDAR aerotransportado, para alimentar Redes Neurais Recorrentes e Redes Convolucionais para classificar dois conjuntos de dados públicos (Vaihingen e Dortmund). O uso de 11 descritores inclui redundância que precisa ser suprimida nas primeiras camadas da rede. A redução das características selecionadas aceleraria a classificação.

4. Conclusões

Neste artigo, são apresentados dois descritores para descrever a forma de objetos 3D digitalizados por um LiDAR móvel terrestre. O par de descritores descreve a planaridade e o alongamento e é coerente com outros descritos na literatura. Foi mostrado que, normalizando os autovalores, o efeito do tamanho dos objetos pode ser eliminado e os descritores podem descrever melhor a forma. Também é mostrado que dois descritores são suficientes para descrever a forma e que essas características são combinações lineares simples dos autovalores. A vantagem dos descritores propostos é que eles permitem a escolha de limiares, pois são normalizados na faixa entre zero e um. Isso permite uma descrição mais fácil da forma em termos de apenas dois termos bem conhecidos. O método proposto permite a descrição precisa da superfície do objeto por dois parâmetros relacionados à planaridade e alongamento. A combinação desses parâmetros permite classificar nuvens de pontos em objetos lineares, planares e esféricos. Os resultados dos testes com objetos simulados e reais validaram a proposta e mostram que as características derivadas podem ser usadas para classificar topos de polos a partir de um levantamento LiDAR terrestre. Os resultados são fortemente afetados pela densidade pontual em relação ao tamanho do objeto e oclusão. Como esperado, melhores resultados foram obtidos quando os objetos estavam mais próximos do medidor.

Agradecimentos

Os autores agradecem à ESTEIO Engenharia e Levantamentos S.A por permitir a utilização dos dados e à CAPES e CNPq (processo nº: 307086/2021) pelo apoio.

Referências

- ALONSO, I.; Riazuelo, L.; Montesano, L.; Murillo, A.C. 3D-MiniNet: Learning a 2D Representation from Point Clouds for Fast and Efficient 3D LIDAR Semantic Segmentation. *IEEE Robot. Autom. Lett.*, 5, pp. 5432–5439, 2020.
- BOLLES, R. C.; Fischler, M. A. A RANSAC-based approach to model fitting and its application to finding cylinders in range data. *In Int. Joint Conf. on Art. Intelligence*, Vancouver, Canada, pp. 637–643, 1981.
- DENIS, E.; Burck, R.; Baillard, C. Towards road modeling from terrestrial laser points, *The International Archives of the Photogrammetry*, Vol. XXXVIII, Part 3A, pp.293-298, 2010.
- DEMANTKE, J.; Mallet, C.; David, N.; Vallet, B. Dimensionality based scale selection in 3D LiDAR point clouds. *ISPRS Workshop on Laser Scanning 2011*, Calgary, Canada, 29–31 August, 6p (on CDROM), 2011.
- DIAZ-VILARINO, L.; Conde, B.; Lagüela, S.; Lorenzo, H., Automatic Detection and Segmentation of Columns in As-Built Buildings from Point Clouds. *Remote Sensing*, 7(11), pp.15651-15667, 2015.
- EL-HALAWANY, S. *Detection of Road Furniture from Mobile Terrestrial Laser Scanning Point Clouds*, Ph.D. thesis, Department of Geomatics Engineering, University of Calgary, Canada, 2013.
- FALTÝNOVÁ, M.; Matoušková, E.; Šedina, J. ; Pavelka, K. Building facade documentation using laser scanning and photogrammetry and data implementation into BIM. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B3, 2016. XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic, 2016.
- FERNANDES, D.; Silva, A.; Névoa, R.; Simões, C.; Gonzalez, D.; Guevara, M.; Novais, P.; Melo-Pinto, P. Point-cloud based 3D object detection and classification methods for self-driving applications: A survey and taxonomy. *Information Fusion*, 68, pp. 161-191, 2021.
- FUKANO, K.; Masuda, H. Detection and classification of pole-like objects from mobile mapping data. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1, pp. 57-64, 2015.
- GUAM, H.; Yu, Y.; Ji, Z.; Li, J. Zhang, Q. Deep learning-based tree classification using mobile LiDAR data, *Remote Sensing Letters*, 6:11, pp.864-873, 2015.
- GUAM, H.; Yan, W.; Yu, Y.; Zhong, L.; Li, D. Robust traffic-sign detection and classification using mobile lidar data with digital images. *IEEE journal of selected topics in applied earth observations and remote sensing*, vol. 11, no. 5, 2018.
- HAGHIGHATGOU, N.; Daniel, S.; Badard, T. A method for automatic identification of openings in buildings facades based on mobile LiDAR point clouds for assessing impacts of floodings, *International Journal of Applied Earth Observation and Geoinformation*, Volume 108, 2022.
- HRUTKA, B.P.; Z. Siki, Z.; Takács, B. Voxel-based point cloud segmentation and building detection. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLVIII-4/W1-2022. Free and Open Source Software for Geospatial (FOSS4G) 2022 – Academic Track, Florence, Italy, 22–28 August 2022.
- HUANG, J.; You, S. Pole-like object detection and classification from urban point clouds. *IEEE International Conference on Robotics and Automation (ICRA)*, pp. 1-7, 2005.

- HUANG, J.; You, S. Point Cloud Labeling using 3D Convolutional Neural Network. 23rd *International Conference on Pattern Recognition (ICPR)*, Cancún Center, Cancún, México, December 4-8, 2016.
- IBRAHIM, S.; Lichti, D. Curb-based street floor extraction from mobile terrestrial LiDAR point cloud. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XXXIX-B5, 2012. XXII ISPRS Congress, Melbourne, Australia, 25 August – 01 September 2012.
- LI, F.; Elberink, S. O.; Vosselman, G. Pole-like street furniture decomposition in mobile laser scanning data. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume III-3, 2016. XXIII ISPRS Congress, Prague, Czech Republic, 12–19 July 2016.
- LI, J.; Cheng, X. Supervoxel-based extraction and classification of pole-like objects from MLS point cloud data. *Optics & Laser Technology*, Volume 146, February, 2020.
- LI, Y.; Wang, W.; Li, X.; Xie, L.; Wang, Y.; Guo, R.; Xiu, W.; Tang, S. Pole-Like Street Furniture Segmentation and Classification in Mobile LiDAR Data by Integrating Multiple Shape-Descriptor Constraints. *Remote Sensing* 11(24), 2019.
- LUO D.; Wang Y. Rapid extracting pillars by slicing point clouds, *International Archives of the Photogrammetry Remote Sensing*, vol.36-8, pp.71-75, 2008.
- ORDONES, C.; Cabo, C.; Sanz-Ablanedo, E. Automatic detection and classification of pole-like objects for urban cartography using mobile LASER scanning data. *Sensors*, 17, 1465; pp 1-10, 2017.
- ÖZDEMİR, E.; Remondino, F.; Golkar, A. Aerial point cloud classification with deep learning and machine learning algorithms. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-4/W18, 2019 GeoSpatial Conference 2019 – Joint Conferences of SMPR and GI Research, Karaj, Iran, 12–14 October 2019.
- PEIXOTO, E.B.A., *Deteção e identificação automática de postes utilizando nuvem de pontos do sistema laser terrestre móvel*. Dissertação de mestrado no Programa de Pós-Graduação em Ciências Geodésicas da Universidade Federal Do Paraná, pp. 109-110, 2016.
- PRESS P.; Austin, D. Approaches to pole detection using ranged laser data. *Proceedings of Australasian Conference on Robotics and Automation*, Citeseer. pp.1–8, 2004.
- QI, C.R.; Su, H.; Mo, K.; Guibas, L.J. PointNet: deep learning on point sets for 3D classification and segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 652-660, 2017.
- QI, C.R., Yi, L. K.; Su, H.; Guibas, L.J. Pointnet++: Deep hierarchical feature learning on point sets in a metric space, *Adv. Neur. Inform. Process. Syst.* Pp. 5099–5108, 2017.
- REED, I.S.; Yu, X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution. *IEEE Trans. Acoust. Speech Signal Process.* 1990, 38, 1760–1770, 1990.
- RODRÍGUEZ-CUENCA, B., García-Cortés, S., Ordóñez, C., Alonso, M. C. Automatic detection and classification of pole-like objects in urban point cloud data using an anomaly detection algorithm. *Remote Sensing* 2015, 7, 12680-12703, 2015.
- RUSU, R. B. *Semantic 3D object maps for everyday manipulation in human living environments*. PhD thesis, Computer Science department, Technische Universität München, Germany, 2009.
- SHI, Z.; Kang, Z.; Lin, Y.; Liu, Y.; Chen, W. Automatic Recognition of Pole-Like Objects from Mobile Laser Scanning Point Clouds. *Remote Sensing* 2018, 10(12), p.1891, 2018.
- SIRMACEK, B.; Lindenbergh R. Automatic classification of trees from laser scanning point clouds. *SPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume II-3/W5, 2015. ISPRS Geospatial Week 2015, La Grande Motte, France, 28 Sep – 03 Oct 2015.

-
- SUWARDHI, D.; Fauzan, K.N.; Harto, A.B.; Soeksmantono, B.; Virtriana, R.; Murtiyoso, A. 3D Modeling of Individual Trees from LiDAR and Photogrammetric Point Clouds by Explicit Parametric Representations for Green Open Space (GOS) Management. *ISPRS Int. J. Geo-Inf.* 2022, 11(3), 174, 2022.
- SU, H.; Maji, S.; Kalogerakis, E.; Learned-Miller, E., Multi-view Convolutional Neural Networks for 3D Shape Recognition. In Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 7–13 December 2015; pp. 945–953.2015.
- TEO, T.-A.; Chiu, C.-M. Pole-like road object detection from mobile Lidar system using a coarse-to-fine approach. *IEEE Journal of selected topics in applied earth observations and remote sensing*, vol. 8, no. 10, 2015.
- WEINMANN, M.; Jutzi, B.; Mallet, C. Feature relevance assessment for the semantic interpretation of 3d point cloud data. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume II-5/W2, 2013 ISPRS Workshop Laser Scanning 2013, Antalya, Turkey, 11 – 13 November 2013.
- YAN, W. Y.; S. Morsy, A. Shaker, and M. Tulloch. Automatic Extraction of Highway Light Poles and Towers from Mobile LiDAR Data. *Optics & Laser Technology*, Vol. 77, pp. 162–168, 2016.
- YANG, B., Dong, Z., 2013. A shape-based segmentation method for mobile laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 81 pp. 19–30, 2013.
- YOKOYAMA, H.; Date, H.; Kanai, S.; Takeda, H. Pole-like objects recognition from mobile laser scanning data using smoothing and principal component analysis. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XXXVIII-5/W12, 2011. ISPRS Calgary 2011 Workshop, 29-31 August 2011.
- YOKOYAMA, H.; Date, H.; Kanai, S.; Takeda, H. Detection and classification of pole-like objects from mobile laser scanning data of urban environments. *International Journal of CAD/CAM* Vol. 13, No. 2, pp. 31–40, 2013.
- YU, Y., Li, J., Guan, H., Wang, C., Yu, J. Semiautomated extraction of street light poles from mobile lidar point-clouds. *IEEE transactions on geoscience and remote sensing*, vol. 53, no. 3, 2015.