



Um Estudo de Caso sobre o Emprego da Técnica de Voxelização como Método para Generalização 3D de Arborização Urbana em Dados LiDAR Aerotransportado

A Case Study about the Use of Voxelization Technique for Urban Afforestation 3D Generalization in ALS Data

Daniel Luís Andrade e Silva ¹ e Daniel Rodrigues dos Santos ²

¹ Universidade Federal do Paraná, Departamento de Geomática, Curitiba, Brasil. daniel.luis@ufpr.br.

ORCID: <https://orcid.org/0000-0003-0167-1036>

² Instituto Militar de Engenharia, Seção de Engenharia Cartográfica, Rio de Janeiro, Brasil. daniel.rodrigues@ime.eb.br.

ORCID: <https://orcid.org/0000-0001-7977-7426>

Recebido: 06.2021 | Aceito: 11.2021

Resumo: Buscando reduzir o esforço computacional na extração de informações a partir de dados geoespaciais tridimensionais (3D), uma opção é realizar a generalização 3D. Configurando um processo subjetivo de derivação de dados em que são estabelecidos critérios e regras, a generalização 3D permite criar modelos de representação espacial 3D compactos e realísticos, impactando menores requisitos de armazenamento, visualização e análise dos dados. Nesse contexto, o presente artigo tem como objetivo geral avaliar o emprego da técnica de voxelização como um método para generalizar árvores urbanas delimitadas em nuvem de pontos LiDAR (*Light Detection and Ranging*). Adquiridos em plataforma aerotransportada, os dados utilizados são referentes ao bairro da Pituba no município de Salvador-BA e apresentam densidade média de 8 pontos/m². Para a delimitação das árvores, os dados foram filtrados e classificados com auxílio de rotinas de processamento implementadas em softwares próprios para nuvens de pontos. Para a voxelização, foram definidas quatro diferentes dimensões mínimas de célula: 0,5 m, 1 m, 1,5 m e 2 m. Os resultados obtidos mostraram a diminuição do número de unidades elementares e a redução do espaço de armazenamento computacional, mantida a eficácia para a extração de informações sobre a localização e a distribuição espacial das árvores delimitadas. Valida-se assim a voxelização como um eficaz método para generalização 3D de arborização urbana em dados ALS.

Palavras-chave: Eficiência. Delimitação de arborização urbana. Reamostragem 3D. Nível de detalhe.

Abstract: Reducing computational effort for extraction of information from three-dimensional (3D) geospatial data, one option is to perform 3D generalization. Featuring a subjective process of data derivation in which criteria and rules are established, 3D generalization allows to create compact and realistic models for 3D representation, impacting lower data storage, visualization and analysis requirements. In this context, the present paper aims to evaluate use of voxelization technique as a method to generalize delimited urban trees in LiDAR (*Light Detection and Ranging*) point cloud. Acquired on an airborne platform, data used refer to Pituba district in Salvador city, Bahia state, have an average density of 8 points/m². In order to delimit trees, data were filtered and classified by processing routines implemented in pointcloud softwares. For voxelization, four different minimum cell dimensions were defined: 0.5 m, 1 m, 1.5 m and 2 m. The obtained results showed decrease in number of elementary units and reduction in computational storage space, kept efficiency for extraction of information about delimited trees location and spatial distribution. Voxelization is thus validated as an effective 3D generalization method for urban afforestation from ALS data.

Keywords: Efficiency. Urban afforestation's delimitation. 3D resampling. Level of detail.

1 INTRODUÇÃO

Com o avanço geotecnológico, as aquisições de dados geoespaciais tridimensionais (3D) têm se tornado mais ágeis e flexíveis, impactando o ativo de realidade digital gerado (POUX, 2019). Embora possibilite análises espaciais mais acuradas, o aumento no volume de dados adquiridos implica um maior custo operacional (OHORI et al., 2015), sendo exigidos maiores requisitos computacionais de armazenamento, gerenciamento, acesso, manipulação, processamento e visualização (LI et al., 2015; ROBINSON et al., 2017).

Para mitigar esse problema, deve-se buscar eficiência na extração de geoinformações 3D, unindo eficácia com diminuição do esforço computacional (FERLIN; REZENDE, 2019). Nesse sentido, uma opção a ser realizada é a generalização 3D, entendida como uma abstração da realidade (ROBINSON et al., 1995) que consiste na aplicação de operadores de transformações espaciais e de atributos (MCMMASTER; SHEA, 1992) com a finalidade de reduzir os níveis de detalhes (LoD - *level of details*) geométrico e semântico dos objetos existentes em representações 3D, mas preservando a coerência espacial original (SCHMIDT, 2012).

Configurando um processo subjetivo de derivação de dados que requer estratégias de implementação, a generalização 3D permite a construção de modelos de representação 3D compactos com um suficiente realismo funcional (OVIEDO, 2014) que atenda a um propósito de uso definido (BILJECKI, 2017), impactando menores requisitos computacionais principalmente de armazenamento, visualização e análise dos dados (KADA, 2006).

Segundo Hornung et al. (2013), modelos espaciais 3D compactos podem ser gerados por meio de um processo de construção de grade regular composta por volumes cúbicos (voxels) de igual dimensão. Tal processo, conhecido como voxelização, pode ser vantajoso para representações do tipo nuvem de pontos 3D em virtude da homogeneização da densidade de informação espacial, embora acarrete redução do número de unidades elementares e, conseqüentemente, do nível de detalhes dos objetos representados. Pode-se ter assim uma adaptação teórica e metodológica (MACKANESS; RUAS; SARJAKOSKI, 2011) do operador simplificação (ROBINSON; SALE; MORRISON, 1978) para o domínio 3D, haja vista a redução do número de coordenadas armazenadas computacionalmente devido ao cômputo do conjunto de voxels reamostrados, que quantificam o grau de generalização atingido (GLANDER; DÖLLNER, 2008).

Considerando ser recente e pouco abrangente a abordagem da temática de generalização 3D para vegetação urbana (ORTEGA-CÓRDOVA, 2018), o presente artigo tem como objetivo geral avaliar o emprego da técnica de voxelização como um método para generalizar árvores urbanas delimitadas em dados LiDAR adquiridos em plataforma aerotransportada (ALS – *airborne laserscanning*). Possuindo caráter investigativo, este artigo contém um estudo de caso no qual foram aplicadas diferentes reamostragens 3D para árvores urbanas representadas em uma nuvem de pontos ALS referente ao bairro da Pituba (município de Salvador-BA), variando os tamanhos mínimos dos voxels computados.

Fator relevante para o sucesso da voxelização, a desafiadora tarefa de delimitação das árvores foi realizada com o auxílio de algoritmos de filtragem e classificação implementados em softwares de processamento de nuvens de pontos, tendo sido usada de maneira auxiliar uma imagem óptica correspondente à área de estudo.

O conteúdo deste artigo está organizado da seguinte maneira: na seção 2, a descrição dos dados utilizados e das etapas metodológicas desenvolvidas; na seção 3, os resultados obtidos e as discussões; na seção 4, as conclusões e recomendações para trabalhos futuros.

2 MATERIAL E MÉTODOS

2.1 Dados utilizados e área de estudo

Os dados ALS utilizados foram adquiridos pelo sensor laser RIEGL VQ480-II (Quadro 1), sendo disponibilizados no site de Cartografia da Prefeitura Municipal de Salvador (PMS, 2021) no formato *.LAS* (*LIDAR Data Exchange Format*).

Quadro 1 – Informativo da aquisição LiDAR RIEGL VQ480-II.

Mês/Ano de aquisição	Altura de operação (m)	Velocidade da plataforma (Km/h)	Densidade média da nuvem de pontos obtida (pontos/m ²)	Acurácia em range (cm)	Comprimento de onda do pulso (nm)	Mecanismo
Agosto/2016- Fevereiro/2017	450	120	8	2	1550	Espelho oscilante

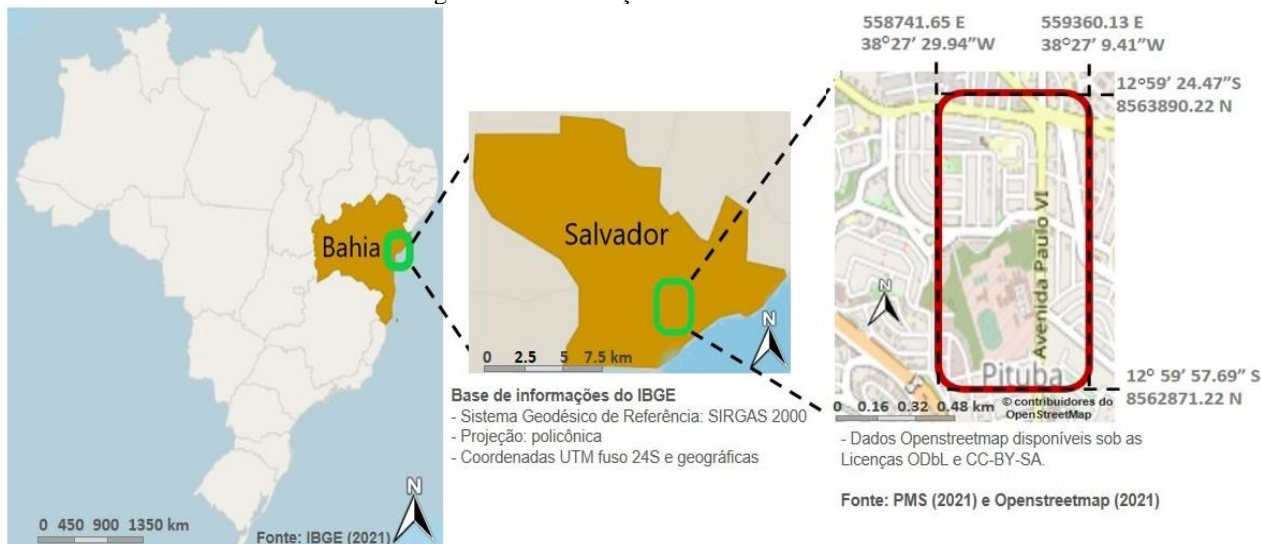
Fonte: RIEGL (2019) e PMS (2021).

De maneira auxiliar, utilizou-se uma composição RGB de uma ortoimagem obtida por levantamento

aerofotogramétrico que empregou a câmera métrica UltraCam Lprime da fabricante Vexcel. Também disponibilizada pela PMS (2021), a ortoimagem apresenta resolução espacial de 10 cm e acurácia posicional correspondente à classe A no PEC-PCD (Padrão de Exatidão Cartográfica para Produtos Cartográficos Digitais) Planimétrico.

Os dados utilizados foram adquiridos com diferença temporal de 3 dias (PMS, 2021) e são referentes a uma área cuja extensão aproximada é 0,63 km² (618,65 m x 1019,05 m), localizada entre as longitudes 38° 27' 9,41" W - 38° 27' 29,94" W e latitudes 12° 59' 24,47" S - 12° 59' 57,69" S, no bairro da Pituba, município de Salvador-BA (Figura 1).

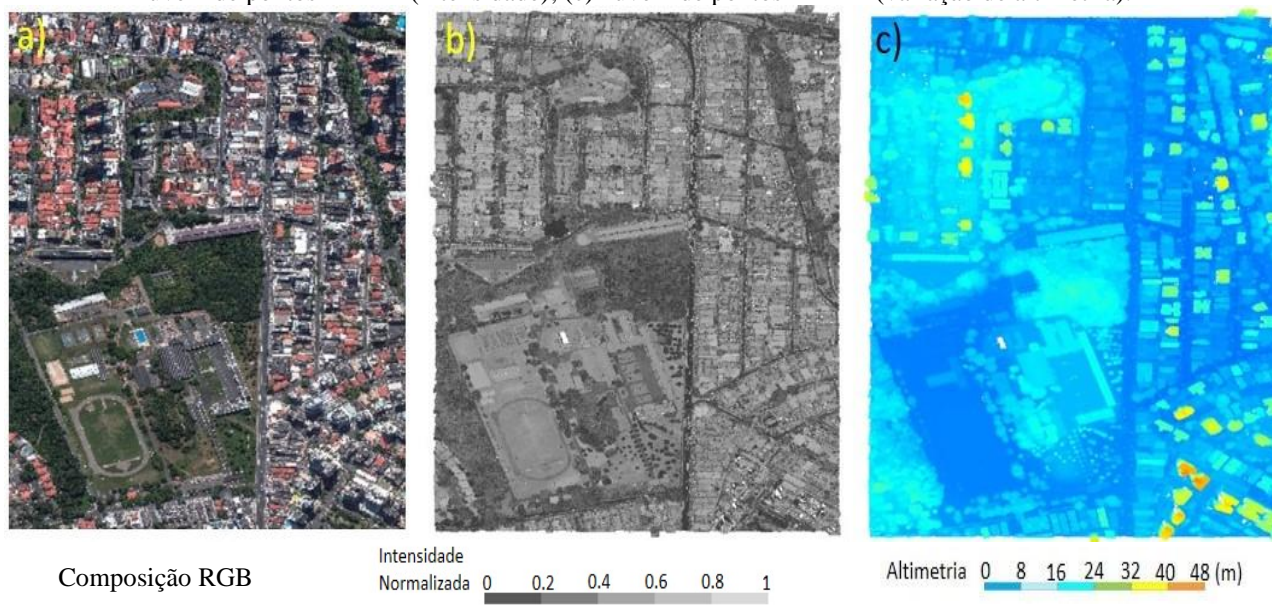
Figura 1 – Localização da área de estudo.



Fonte: Os autores (2022).

A área em questão (Figura 2) apresenta uma paisagem heterogênea, composta por elementos naturais, arruamentos e diferentes tipos de edificações. Segundo Roque et al. (2020), a flora existente nessa região é diversificada, contendo espécies arbóreas, arbustivas e sub-arbustivas de diferentes estruturas vegetais, encontradas em praças e jardins públicos, propriedades particulares e de acesso restrito, e também plantadas em calçadas (arborização de ruas).

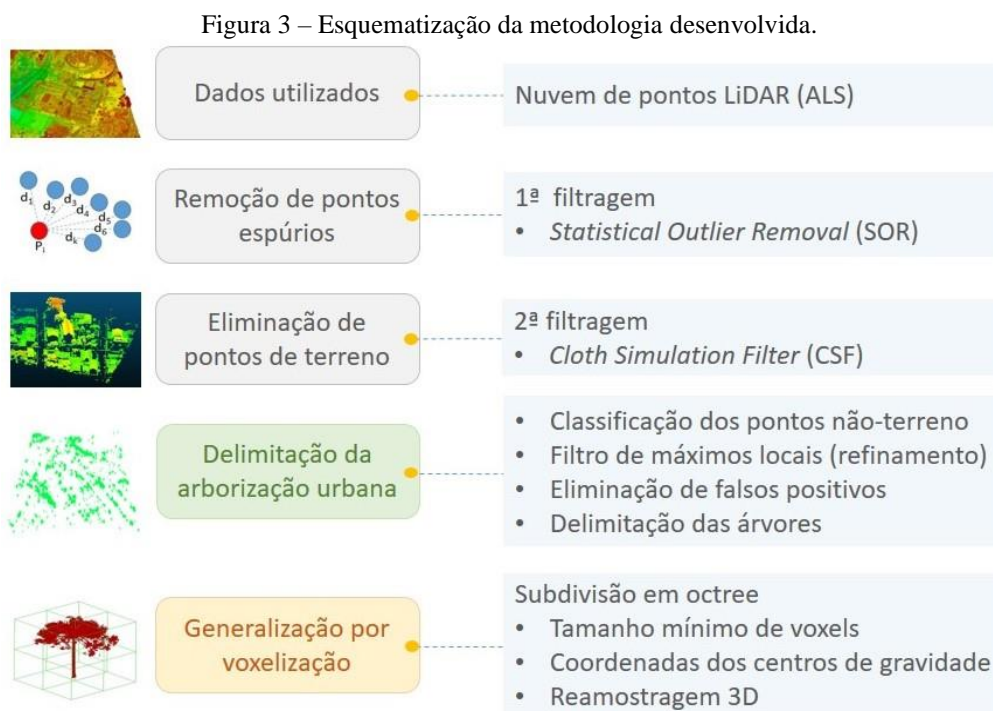
Figura 2 – Área de estudo visualizada em três modos distintos: (a) ortoimagem (resolução espacial de 10 cm); (b) nuvem de pontos LiDAR (intensidade); (c) nuvem de pontos LiDAR (variação de altimetria).



Fonte: Os autores (2022).

2.2 Metodologia empregada

A metodologia empregada neste artigo (Figura 3) combinou diferentes técnicas de processamento de nuvens de pontos, a fim de obter resultados geometricamente representativos de arborização urbana.



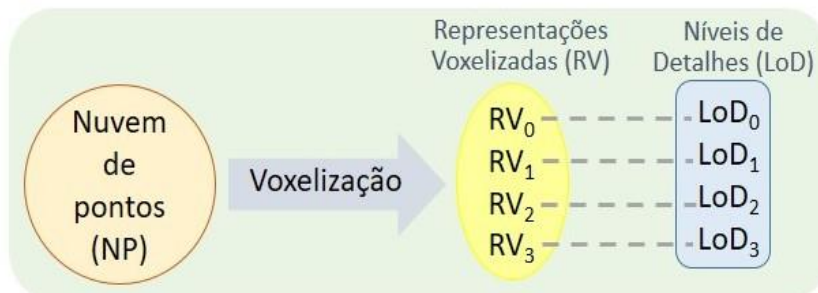
Fonte: Os autores (2022).

Inicialmente, filtrou-se a nuvem de pontos LiDAR para remover os pontos espúrios (*outliers*) devidos a fatores intrínsecos e extrínsecos (CARRILHO; GALO, 2017) que causam erros na varredura a laser. Buscando otimizar o desempenho computacional (acurácia e velocidade) dos processamentos subsequentes, foi realizada uma segunda filtragem, eliminando os pontos terreno, já que a classe de interesse é a arborização urbana.

Após as duas filtragens, todos os pontos “não-terreno” foram classificados a fim de se delimitar as árvores médias e altas. Os pontos rotulados como vegetação foram selecionados e inspecionados visualmente com auxílio da ortoimagem correspondente, com o intuito de verificar a existência de possíveis falsos positivos decorrentes de erros de classificação. Uma terceira filtragem eliminou os falsos positivos detectados automaticamente para auxiliar a delimitação das árvores.

Obtida a nuvem de pontos contendo as árvores delimitadas, a voxelização ocorreu conforme quatro tamanhos mínimos de células estabelecidos (Figura 4).

Figura 4 – Generalização por voxelização.




Fonte: Os autores (2022).

Nos itens a seguir, são detalhadas as etapas metodológicas desenvolvidas.

2.2.1 REMOÇÃO DE PONTOS ESPÚRIOS (1ª FILTRAGEM)

Para a detecção e remoção de *outliers*, foi utilizado o filtro *Statistical Outlier Removal* (SOR) implementado no software *CloudCompare 2.10*. Desenvolvido por Rusu e Cousins (2011), o algoritmo computa, para cada ponto N_i testado em uma determinada vizinhança ($k + 1$ pontos), as k distâncias em relação aos seus vizinhos (Figura 5), além da média das distâncias entre cada um dos $\frac{k!}{2!(k-2)!}$ pares de pontos formados pelos k vizinhos (distância média amostral) e seu desvio-padrão amostral.

Figura 5 – Distâncias de um ponto em sua vizinhança (algoritmo SOR).



Fonte: Os autores (2022).

Conforme a Eq. (1), a condição estabelecida por Rusu e Cousins (2011) para que um ponto N_i seja considerado *outlier*, e conseqüentemente seja removido da nuvem de pontos, é apresentar distância em relação a um de seus k vizinhos maior do que uma distância máxima permitida entre pontos, definida como a média das distâncias entre os pontos amostrais acrescida de um valor escalar α multiplicado pelo desvio-padrão amostral das distâncias (s).

$$d_{N_i} > \bar{d} + \alpha \cdot s, \text{ sendo: } \bar{d} = \frac{\sum d_i}{k}; s = \sqrt{\frac{\sum (d_i - \bar{d})^2}{k-1}} \quad (1)$$

onde:

d_{N_i} = distância do ponto testado ao vizinho mais próximo na amostra;

d_i = distância i entre dois pontos amostrais quaisquer;

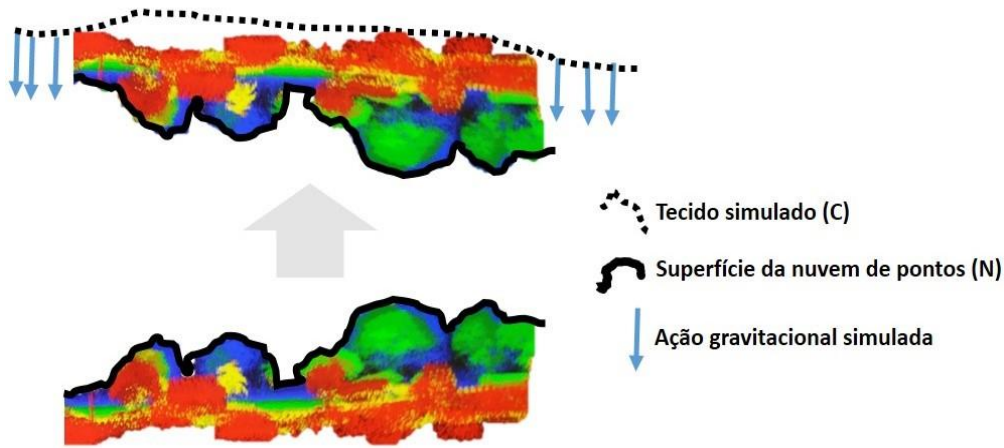
\bar{d} = média das distâncias entre todos os pontos amostrais.

Para a filtragem SOR realizada, os parâmetros k e α solicitados foram definidos como os valores padrões adotados pelo software utilizado, respectivamente o número de pontos vizinhos igual a 6 e o fator multiplicativo do desvio-padrão amostral igual a 1.

2.2.2 ELIMINAÇÃO DOS PONTOS DE TERRENO (2ª FILTRAGEM)

Para a eliminação dos pontos de terreno, foi utilizado o filtro simulador de tecidos (*cloth simulation filter-CSF*), que se mostra vantajoso pela possibilidade de aplicação em dados LiDAR referentes a paisagens urbanas complexas (heterogeneidade de feições). Desenvolvido por Zhang et al. (2016), o algoritmo consiste num filtro que simula um pedaço de tecido C que recobre uma nuvem de pontos LiDAR N invertida, conforme visualizado na Figura 6.

Figura 6 – Visão geral do algoritmo CSF.



Fonte: Os autores (2022).

A seguir, é descrito o algoritmo CSF (Zhang et al., 2016).

A simulação do tecido C se baseia em uma grade formada por c partículas de massas m_c , que determinam, de maneira conectada, a forma e a posição tridimensional (X, Y, Z) do tecido em um instante t . Por ação gravitacional simulada, as partículas da grade simulada que interceptam a nuvem invertida são tratadas como pontos fixos, e assumem as coordenadas dos pontos de interseção. As outras partículas, ainda móveis, são ajustadas de acordo com a deposição do tecido sobre a superfície, ocorrendo também a simulação de forças internas resultantes de colisões entre as partículas, sendo obedecida a Lei de Hooke (1660) para a determinação das deformações elásticas proporcionais às forças atuantes (HALLYDAY; RESNIK; KRANE, 2004).

A posição $P_c(t)$ de cada partícula c no instante t é calculada pela integração numérica da Eq. (2).

$$m_c \frac{\partial^2 P_c(t)}{\partial t^2} = F_{ext}(P_c(t), t) + F_{int}(P_c(t), t) \quad (2)$$

onde $\frac{\partial^2 P_c(t)}{\partial t^2}$ é o operador de derivação de segunda ordem da posição P_c em relação à variável t , $F_{ext}(P_c(t), t)$ e $F_{int}(P_c(t), t)$ são respectivamente as forças resultantes simuladas externa e interna que atuam na partícula.

A simulação é iterativa, sendo interrompida quando a variação em altura Z das partículas for igual ou inferior a um threshold δ definido ($\Delta Z_c \leq \delta$) ou quando atingir o número máximo de iterações preestabelecido. Finalizada a simulação, os pontos da nuvem N cuja distância ao tecido C for inferior ao limiar δ são classificados como pontos de terreno T_i e os demais como pontos não-terreno X_i .

Dada uma nuvem de n pontos $N = \{N_1, N_2, N_3, \dots, N_n\}$ e o tecido simulado $C = \{m_1, m_2, \dots, m_c\}$, o resultado da filtragem CSF atende às condições estabelecidas nas Eq. (3) e (4):

$$\text{se } Z_n - Z_c \leq \delta, \text{ então } N_n \in T \quad (3)$$

$$\text{se } Z_n - Z_c > \delta, \text{ então } N_n \in X \quad (4)$$

onde T é a nuvem de pontos terreno e X a nuvem de pontos não-terreno.

A filtragem CSF também foi realizada no *CloudCompare 2.10*, definidos os seguintes parâmetros: - tipo de terreno plano, pois a área de estudo não apresenta significativos declives em sua extensão; - resolução da grade (espaçamento entre os nós do tecido simulado) de 1,0 m, a fim de tornar a filtragem adequada à densidade de pontos da nuvem e evitar superamostragem e subamostragem; número máximo de iterações para a simulação do ajuste do tecido simulado e limiar de classificação (tolerância para a distância final calculada entre os nós do tecido simulado e os pontos da nuvem invertida) os valores padrões definidos pelo software, respectivamente 500 e 0,5 m. Foi também selecionada a opção “*Slope processing*”, a fim de computar variações altimétricas locais que pudessem ser identificadas pelo algoritmo.

2.2.3 DELIMITAÇÃO DA ARBORIZAÇÃO URBANA

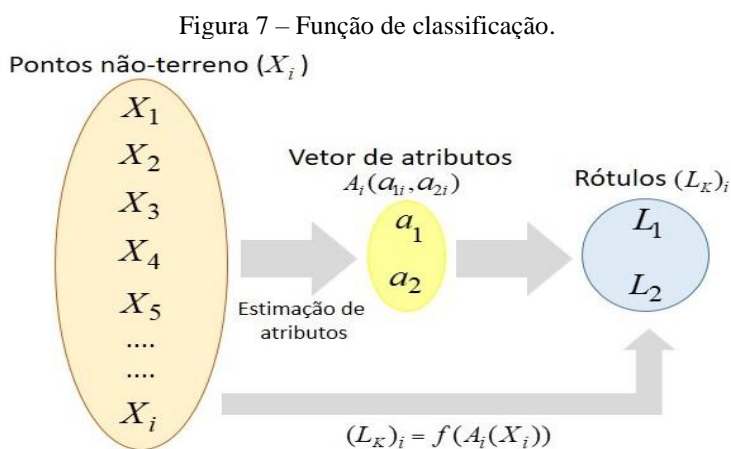
Nesta etapa, houve a necessidade de fazer uma classificação preliminar dos pontos não-terreno obtidos após a filtragem CSF, para posterior separação dos pontos rotulados como vegetação e eliminação dos falsos positivos.

2.2.3.1 Classificação

O procedimento foi realizado com auxílio de três rotinas de processamento implementadas no software *lastools* (ISENBURG, 2011), frequentemente usado para manipular, processar e visualizar dados LIDAR: *lasground*, *lasheight* e *lasclassify*.

A rotina *lasground* criou um atributo de classificação inicial para todos os pontos, sendo atribuído aos pontos terreno o valor 2, e aos pontos não-terreno o valor 1, seguindo a padronização ASPRS (Sociedade Americana de Fotogrametria e Sensoriamento Remoto); a rotina *lasheight* calculou a altura de todos os pontos não-terreno para auxiliar a tarefa de classificação; a rotina *lasclassify* rotulou os pontos em edificações ou vegetação. Visando reduzir a quantidade de pontos a serem classificados, optou-se por remover pontos com valores de altura superiores a 25 m, considerando haver na paisagem urbana estudada apenas árvores com este limite de altura.

Desejando identificar pontos de edificações e de vegetação, a classificação foi tratada como uma função matemática $(L_k)_i = f(A_i(X_i))$ que atribuiu um rótulo L_k (vegetação ou edificações) a cada um dos i pontos não-terreno $\{X_1, X_2, X_3, \dots, X_i\}$, considerando seus vetores de atributos ou características $A_i = (a_{1i}, a_{2i})$. A Figura 7 ilustra a função de classificação realizada pelo software *lastools*, que explorou dois atributos descritores locais: planaridade (a_1) e espalhamento volumétrico (a_2).



Fonte: Os autores (2022).

Descritos em Weinmann, Jutzi e Mallet (2013), Weinmann et al. (2015) e Weinmann (2016), a_1 e a_2 se relacionam à forma e à dimensionalidade dos objetos. A planaridade (a_1) mede o grau de pertencimento de um ponto a um ajustado plano determinado por seus vizinhos, propiciando a detecção de telhados e fachadas de edificações, enquanto o espalhamento volumétrico (a_2) retrata a variação da altura de um ponto em relação às alturas de seus vizinhos, favorecendo assim a detecção de copas de árvores.

A estimação dos atributos a_1 e a_2 para cada um dos pontos X_i se baseou nos autovalores $(\lambda_1, \lambda_2, \lambda_3)$ calculados a partir das matrizes de covariância 3D obtidas em suas vizinhanças locais (PAULY; KEISER; GROSS, 2003; WEST et al., 2004; WEINMANN; JUTZI; MALLET, 2013), conforme as Eq. (5) e (6).

$$a_1 = \frac{\lambda_2 - \lambda_3}{\lambda_1} \tag{5}$$

$$a_2 = \frac{\lambda_3}{\lambda_1} \tag{6}$$

onde $\lambda_1, \lambda_2, \lambda_3$ são os autovalores correspondentes a um sistema ortogonal de autovetores estabelecido por componentes principais, sendo $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$.

A estimação de ambos os atributos considerou uma tolerância medida em desvio-padrão, que foi definida como 0,1 para a planaridade e 0,4 para o espalhamento volumétrico (valores estabelecidos como padrões pelo *lastools*). Ressalta-se que maiores valores de tolerância podem aumentar a existência de falsos positivos para as duas classes.

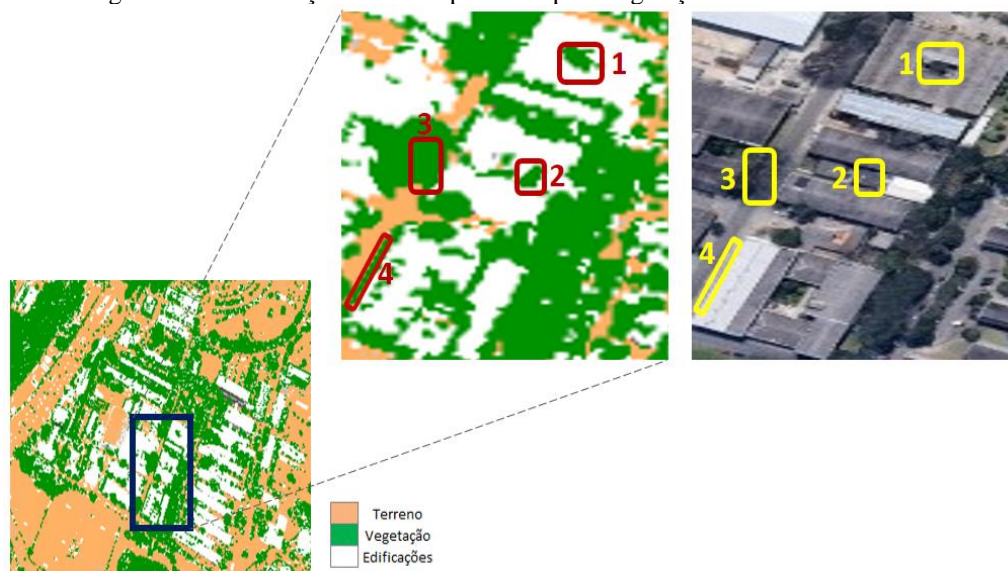
Para executar a rotina *lasclassify*, também foram definidos outros parâmetros:

- tamanho da janela de vizinhança de 3 m, intermediário entre o valor padrão do software (2 m) e o valor máximo recomendado nos arquivos “*readme*” do *lastools* para o caso de nuvens esparsas, para evitar superamostragem e subamostragem na estimação dos parâmetros de planaridade e não-suavidade;
- valor mínimo de altura para a classificação (*off-set*) de 3 m, a fim de desconsiderar pontos de menores alturas (calçadas, muros e portões) que não seriam rotulados como vegetação média e alta;
- ocorrência de simulação de bordas de edificações, visando corrigir a ausência de pontos vizinhos para a estimação da planaridade;
- existência de pequenos edifícios (considerando diferentes tipos de construções, não só edifícios altos, mas também mansões, casebres, lojas, estacionamentos, garagens, etc);
- existência destacada de vegetação, evitando sobreposição a edificações.

2.2.3.2 Refinamento de classificação e delimitação das árvores urbanas

Após a classificação dos pontos não-terreno, selecionou-se somente os pontos rotulados como vegetação. Para verificar a existência de possíveis falsos positivos decorrentes de erros de classificação, foi feita uma inspeção visual utilizando a ortoimagem auxiliar, conforme exemplificado na Figura 8, que mostra quatro falsos positivos identificados na comparação visual entre o resultado de uma genérica classificação de nuvem de pontos e sua correspondente imagem óptica.

Figura 8 – Identificação de falsos positivos para vegetação classificada.

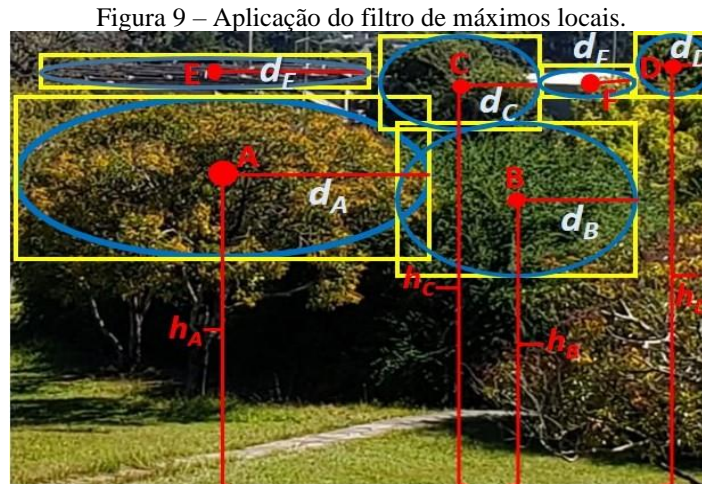


Fonte: Os autores (2022).

Para refinar o resultado da classificação e eliminar os existentes falsos positivos de vegetação, aplicou-se nessa nuvem de pontos uma adaptação do filtro de máximos locais (*local maximum filter* – *lmf*) implementado na função *find-trees* da biblioteca *lidR* (ROUSSEL et al., 2020). A escolha desse filtro é justificada pelo fato de que, em princípio, pontos pertencentes a regiões planares horizontais não apresentam variações altimétricas em relação aos seus vizinhos e, portanto, pontos falsos positivos de vegetação que fossem falsos negativos de edificações não seriam detectados num filtro de máximo local, e por isso seriam eliminados.

Bastante empregado para identificar árvores individuais em povoamentos florestais (POPESCU, 2002; POPESCU; WYNNE, 2004; SILVA et al. 2013; MLENEK, 2020), o algoritmo verificou, por meio de uma janela de busca de dimensão 0,5 m (*window size* [ws] = 0,5) que percorreu toda a nuvem de pontos, a existência de pontos de maior altura em todas as vizinhanças locais. Todos os pontos selecionados como máximos locais foram validados como vegetação, enquanto os pontos que não apresentaram uma suficiente variação de altura em relação aos seus vizinhos que permitisse selecioná-los como máximos locais foram tratados como falsos negativos e eliminados da nuvem classificada.

Simulando a aplicação do filtro de máximos locais, a Figura 9 mostra janelas de busca para cada um dos seis pontos identificados, sendo suas alturas verificadas nas respectivas vizinhanças. A, B, C e D são selecionados como pontos máximos, ao passo que E e F não apresentam variação de altura em relação aos seus vizinhos, sendo então considerados pontos não-vegetação.



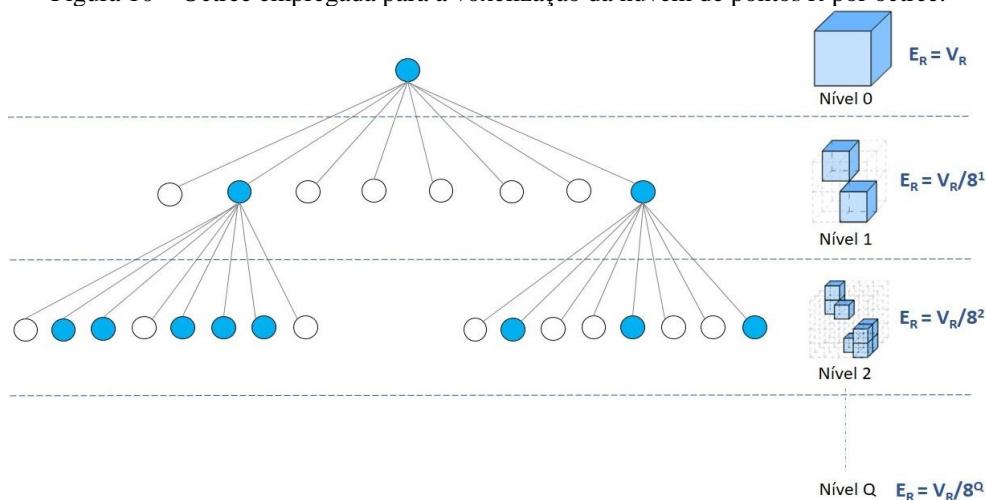
Fonte: Os autores (2022).

Como resultado da filtragem de máximos locais, restaram apenas os r pontos verdadeiros positivos classificados como vegetação, sendo assim delimitadas as árvores urbanas que compõe a nuvem de pontos $R = \{r_1, r_2, \dots, r_r\}$.

2.2.4 GENERALIZAÇÃO POR VOXELIZAÇÃO

Para a voxelização da nuvem de pontos R , utilizou-se outra rotina implementada no *lastools: laxvoxel*. Essa rotina usa como critério de derivação a *octree*, uma árvore computacional hierárquica que permite a estruturação de dados de nuvens de pontos 3D para operações de particionamento espacial de dados (PCL, 2021). A Figura 10 ilustra resumidamente a *octree* empregada para a voxelização da nuvem de pontos R .

Figura 10 – Octree empregada para a voxelização da nuvem de pontos R por octree.




Fonte: Adaptada de Vo et al. (2015).

O volume ocupado pela nuvem R foi inicialmente delimitado por uma “caixa cúbica” (V_R), considerada o nó-raiz da *octree*. Sua decomposição espacial ocorreu, de maneira recursiva e congruente, em oito subvolumes cúbicos (8^Q), até ser gerada a grade tridimensional regular cujo tamanho mínimo de célula foi definido como o E_R desejado. Ao longo do particionamento recursivo, todos os voxels amostrados têm um mesmo tamanho em cada nível Q de profundidade. Voxel vazios (sem pontos em seu interior) não foram subdivididos.

Ao final das voxelizações, as coordenadas espaciais (x_m, y_m, z_m) dos m pontos da nuvem contidos em cada célula amostrada são substituídas por uma trinca de coordenadas (x_E, y_E, z_E) , sendo assim obtida a simplificação 3D das árvores, como é exemplificado na Figura 11.

Figura 11 – Simplificação 3D de árvores: (a) representação original em dados LiDAR; (b) representação voxelizada com célula de 0.5 m.



Fonte: Adaptada de Hornung et al. (2013).

Para as voxelizações realizadas na *lasvoxel*, foram estabelecidos quatro valores de E_R : 0,5 m; 1 m; 1,5 m; 2 m. O cômputo das coordenadas (x_E, y_E, z_E) para cada voxel considerou como referência os centros de gravidade das células, de acordo com as Eq. (7), (8) e (9).

$$x_E = \frac{\sum_1^m(x_m)}{m} \tag{7}$$

$$y_E = \frac{\sum_1^m(y_m)}{m} \tag{8}$$

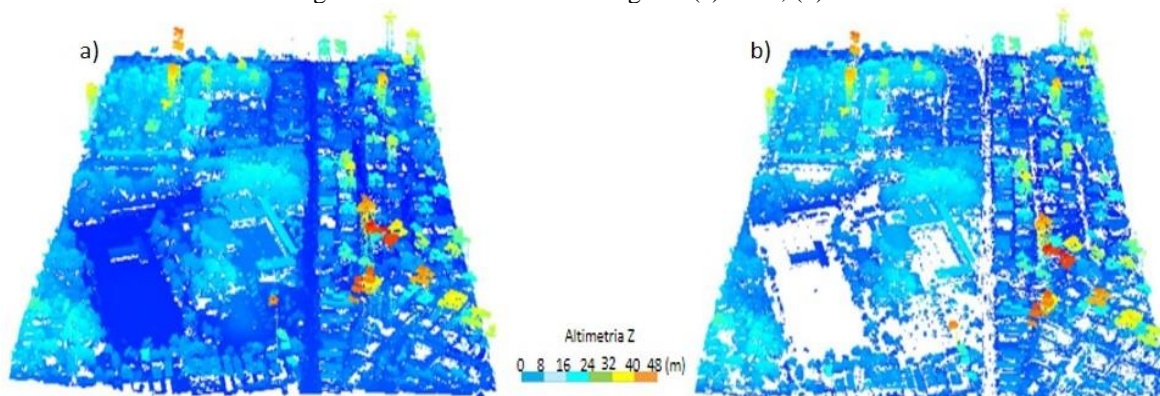
$$z_E = \frac{\sum_1^m(z_m)}{m} \tag{9}$$

3 RESULTADOS E DISCUSSÕES

3.1 Filtragem

Os resultados obtidos nas duas filtragens realizadas (SOR e CSF) são mostrados na Figura 12.

Figura 12 – Resultado das filtragens: (a) SOR; (b) CSF.



Fonte: Os autores (2022).

Conforme se observa na Tabela 1, ao término das duas filtragens (SOR + CSF) houve uma redução total de 47,02% em relação à nuvem LiDAR original, sendo obtida uma nuvem filtrada com remanescentes 2.914.714 pontos não-terreno.

Tabela 1 – Redução da quantidade de pontos (Nuvem original x Nuvem filtrada SOR + CSF).

Nuvem de pontos	Quantidade de pontos	Porcentagem em relação à aos dados originais
Original	5.502.165	100%
Pontos espúrios	515.491	9,37%
Pontos de terreno	2.071.960	37,65%
Filtrada (SOR + CSF)	2.914.714	52,98%

Fonte: Os autores (2022).

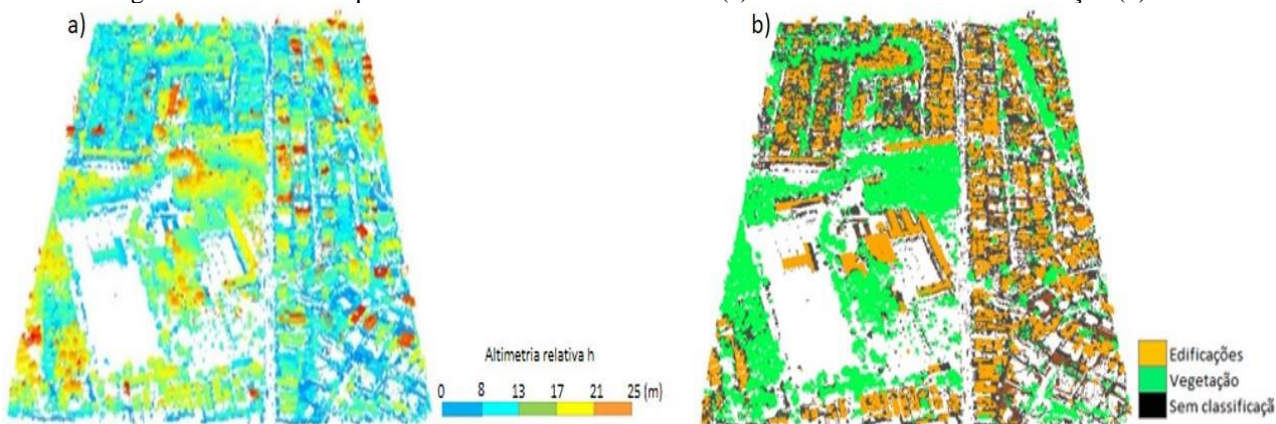
A significativa redução da quantidade de pontos pela filtragem CSF é satisfatória para o cenário urbano estudado pois está em conformidade com a existência de feições sem informação de altura tais como arruamentos, terrenos com solo exposto, campos gramados, etc. Ressalta-se que outros valores adotados para os parâmetros explorados pelos dois algoritmos de filtragem poderiam alterar a quantidade total de pontos indesejados descartados pelas filtragens.

3.2 Classificação dos pontos não-terreno e delimitação das árvores

Antes do procedimento de classificação dos pontos não-terreno, foram eliminados, com auxílio da rotina *lasheight*, 210.302 pontos de altura superior a 25 m, provavelmente correspondentes a edifícios altos, já que se considerou haver na paisagem urbana estudada apenas árvores com este limite de altura, segundo a descrição da flora da região feita por Roque et al. (2020).

Os 2.704.412 pontos de altimetria igual ou inferior a 25 m foram classificados pela rotina *lasclassify*, cujo resultado é mostrado na Figura 13.

Figura 13 – Nuvem de pontos com altura inferior a 25 m (a) e o resultado de sua classificação (b).



Fonte: Os autores (2022).

Na Tabela 2 são informadas as quantidades de pontos rotulados em cada classe.

Tabela 2 – Quantidades de pontos rotulados.

Nuvem de pontos	Quantidade de pontos	Porcentagem em relação à nuvem classificada
Pontos com altura igual ou inferior a 25 m	2.704.412	100%
Pontos rotulados como Vegetação	806.960	29,83%
Pontos rotulados como Edificações	938.894	34,71%
Pontos sem rótulo	958.558	35,46%

Fonte: Os autores (2022).

Nota-se uma quantidade significativa de pontos sem rótulos (cerca de 35%). Tal fato pode ser atribuído ao *off-set* de 3 m definido na rotina *lasclassify* para eliminar pontos de baixas alturas que não seriam rotulados

como vegetação, além da omissão de prováveis pontos de vegetação pertencentes a árvores sobrepostas a algum tipo de edificação, uma vez que a opção “existência de vegetação sobreposta a edificações” foi desabilitada na rotina utilizada.

Em relação aos pontos rotulados como vegetação, a inspeção visual preliminar feita com auxílio da ortoimagem apontou a existência de falsos positivos, tendo sido eliminados após o filtro lmf 76.118 pontos detectados como falsos positivos de vegetação (9,43% dos 806.960 pontos rotulados originalmente como vegetação), restando somente os 730.842 pontos de vegetação validados (verdadeiros positivos).

Pela matriz de confusão da classificação realizada (Quadro 2), em que se considera como verdade referência para a vegetação o resultado do refinamento obtido após a inspeção visual e o filtro lmf, estima-se um erro de inclusão aproximado de 10,42% para a vegetação. Tal como nas filtragens SOR e CSF, outros valores adotados para os parâmetros da rotina *lasclassify* poderiam alterar esse percentual.

Quadro 2 – Matriz de confusão (Verdadeiros x falsos positivos para vegetação).


		Verdade Referência		
		Vegetação	Não-vegetação (Edificações + sem classificação)	Total
Classificação	Vegetação	730.842 pontos	76.118 pontos	806.960 pontos
	Não-vegetação (Edificações + sem classificação)	----	1.897.452 pontos	1.897.452 pontos
Total		730.842 pontos	1.973.570 pontos	2.704.412 pontos

Fonte: Os autores (2022).

Vale ressaltar que na inspeção visual auxiliar não foram detectados pontos falsos negativos para vegetação, e por essa razão não houve refinamento da classificação dos pontos rotulados originalmente como edificações.

A Figura 14 mostra o resultado do refinamento da classificação após a filtragem lmf em comparação à classificação original.

Figura 14 - Pontos rotulados como vegetação: (a) classificação inicial; (b) refinamento da classificação.



Fonte: Os autores (2022).

Os 730.842 pontos resultantes da filtragem lmf (Figura 14b) formaram a nuvem de pontos refinada *R*, que contém as árvores delimitadas.

3.3 Voxelização

Realizadas as quatro reamostragens da nuvem de pontos *R*, foi possível estabelecer um comparativo para os resultados obtidos, conforme se nota na Tabela 3.

Tabela 3 – Comparativo das voxelizações (redução da quantidade de unidades elementares e do espaço de armazenamento).

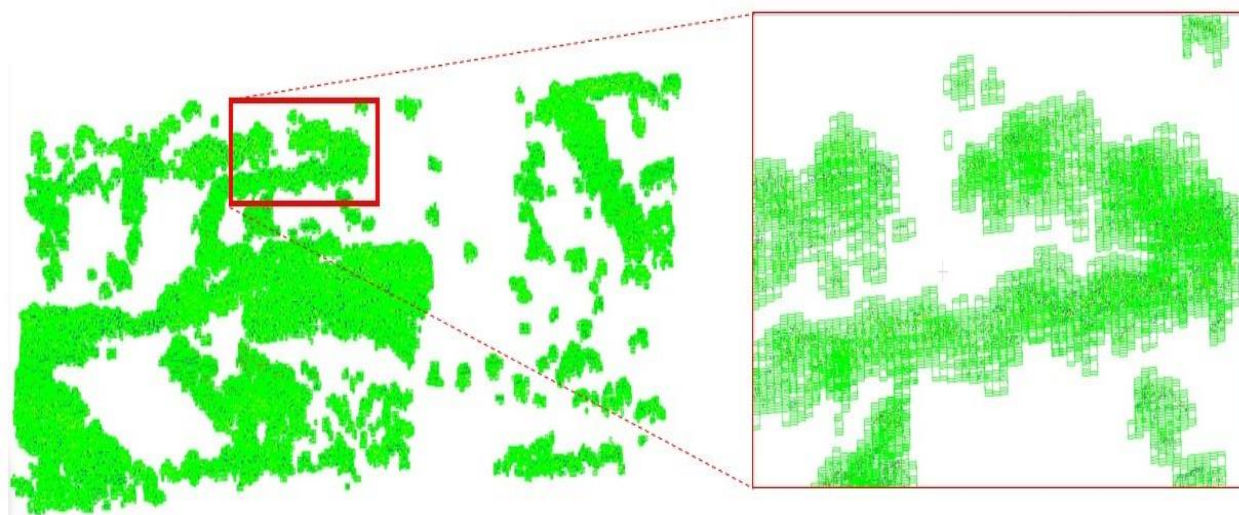
	Nuvem refinada (R)	Voxelização $E_R = 2\text{m}$	Voxelização $E_R = 1,5\text{ m}$	Voxelização $E_R = 1\text{ m}$	Voxelização $E_R = 0,5\text{ m}$
Número de unidade elementares	730.842 pontos	70.636 voxels	115.066 voxels	218.207 voxels	517.145 voxels
Redução do número de unidades em relação à representação original R (%)	0%	90,33%	84,25%	70,14%	29,23%
Espaço de armazenamento	24, 267 Mb	81 Kb	124 Kb	225 Kb	550 Kb
Redução do espaço de armazenamento relação à representação original R (%)	0%	99,66%	99,48%	99,07%	97,73%

Fonte: Os autores (2022).


Constata-se simultaneamente a redução da quantidade de unidades elementares e do espaço de armazenamento computacional para todas as representações voxelizadas em relação à nuvem de pontos R . Foi verificada uma proporcionalidade inversa entre os grandezas avaliadas, embora sem uma relação linear, já que menores armazenamentos computacionais foram associados aos maiores tamanhos de voxels amostrados.

Tal análise está em conformidade com o que se espera para uma reamostragem 3D por *octree*. Admitindo ser V_R um valor fixo, E_R e 8^Q são inversamente proporcionais, como se observou na Figura 10. Um aumento de E_R implicou uma diminuição do número de subdivisões 8^Q , ou seja, ocorreram menos reamostragens nessa condição, e consequentemente menos coordenadas (x_E, y_E, z_E) foram armazenadas.

Para facilitar a visualização dos resultados obtidos nas voxelizações, as Figuras 15 e 16 mostram correspondentemente partes destacadas das grades regulares geradas com os tamanhos mínimos de células $E_R = 2\text{m}$ (volume cúbico de 8 m^3) e $E_R = 1\text{m}$ (volume cúbico de 1 m^3) respectivamente.

Figura 15 – Resultado da voxelização (tamanho de célula $2 \times 2 \times 2\text{ m}^3$).

Fonte: Os autores (2022).

Figura 16 – Resultado da voxelização (tamanho de célula 1 x 1 x 1 m³).

Fonte: Os autores (2022).

Apesar da diminuição do número de unidades elementares e da homogeneização da densidade de informação espacial decorrentes do processo de construção das grades regulares por meio das reamostragens 3D, em que foram reduzidos os níveis de detalhes da forma dos objetos representados, as coordenadas computadas para os voxels amostrados permitiram a preservação das informações de localização e distribuição espacial das árvores, mantendo assim a coerência espacial original.

4 CONCLUSÕES

Motivado pela busca de uma solução de generalização 3D para arborização urbana em dados LIDAR aerotransportado, o presente artigo tratou de um estudo de caso onde se verificou o emprego da voxelização como uma adaptação 3D do operador simplificação aplicado no domínio do mapeamento tradicional. Tendo como propósito de uso a extração de informações de localização e distribuição espacial de árvores urbanas, o método empregado foi avaliado sob os seguintes aspectos: redução dos níveis de detalhes, diminuição do armazenamento computacional e eficácia.

Os resultados obtidos para os graus de generalização atingidos permitiram confirmar a hipótese de que a voxelização pode ser empregada de maneira eficaz como um método de generalização 3D, se mostrando simples e vantajosa para generalizar árvores urbanas em dados LiDAR aerotransportado, pois permite solucionar dois problemas inerentes ao fenômeno do *Bigdata* geoespacial: volume e variabilidade dos dados.

Além da validação do emprego da voxelização como um método eficaz de generalização 3D, outra contribuição deste artigo foi a apresentação de uma solução para o problema da delimitação de árvores urbanas em dados ALS. A fim de obter resultados geometricamente representativos de arborização urbana, diferentes técnicas de processamento de nuvens de pontos foram empregadas. As filtragens SOR e CSF se mostraram indispensáveis para a adequação dos dados ao procedimento de classificação realizado, pois descartaram pontos indesejados que poderiam causar superamostragem na estimação dos atributos de planaridade e espalhamento volumétrico e, conseqüentemente, reduzir a acurácia da classificação.

Ressalta-se também a importância da inspeção visual auxiliar, que apontou a existência de falsos positivos para a vegetação, e do filtro de máximos locais, que foi essencial para o refinamento da classificação realizada. Ambos contribuíram para a acurácia da delimitação das árvores voxelizadas. A fim de aumentar a acurácia da tarefa de delimitar árvores urbanas, sugere-se a testagem de outros valores para os parâmetros explorados pelas rotinas de processamento utilizadas.

Dadas a relevância e a complexidade da temática de generalização 3D destacadas neste artigo, e considerando ser incipiente e ainda limitada a sua abordagem para a vegetação urbana, espera-se que os experimentos realizados neste trabalho possam servir como base para novos estudos que objetivem propor métodos de generalização 3D para árvores urbanas.

Contribuição dos Autores

D. L. A. e Silva contribuiu na conceptualização, curadoria dos dados, análise formal, investigação, metodologia e redação do texto. D. R. dos Santos contribuiu na supervisão e na revisão do texto.

Conflitos de Interesse

Os autores informam não haver conflitos de interesse.

Referências

- BILJECKI, F. **Level of detail in 3D city models**. 2017. 353 p. Doctoral dissertation - Delft University of Technology, 2017.
- CARRILHO, A.; GALO, M. Remoção de pontos espúrios em dados LiDAR aerotransportado a partir da análise estatística das altitudes. In: IV SIMPÓSIO BRASILEIRO DE GEOMÁTICA, 2017, Presidente Prudente. **Anais...** Presidente Prudente: 2017. p. 323-327.
- FERLIN, E. P.; REZENDE, D.A. Big data aplicado à cidade digital estratégica: estudo sobre o volume de dados das aplicações smart city. **Revista Gestão & Tecnologia**, Pedro Leopoldo, v. 19, n. 2, p. 175-194, abr./jun. 2019.
- GLANDER, T; DÖLLNER J. Automated cell based generalization of virtual 3D city models with dynamic landmark highlighting. In: 11TH ICA WORKSHOP ON GENERALIZATION AND MULTIPLE REPRESENTATION, 2008, Montpellier, France. **Proceedings...** Montpellier: 2008. p. 1–14.
- HALLIDAY, D.; RESNIK, R.; KRANE, D. S. **Física 2**. 5^a ed. Rio de Janeiro: LTC, 2004.
- HORNUNG, A.; WURM, K. M.; BENNEWITZ, M.; STACHNISS, C.; BURGARD, M. OctoMap: an efficient probabilistic 3D mapping framework based on octrees. **Auton Robot**, v. 34, p.189–206, 2013. DOI 10.1007/s10514-012-9321-0.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Cidades e Estados**. 2021. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/ba.html>>. Acesso em 26 abr. 2021.
- ISENBURG, M. **LASTools Software Suite**. 2011. Disponível em: <<http://rapidlasso.com/lastools/download>>. Acesso em 20 maio 2021.
- KADA, M. 3D building generalization based on half-space modeling. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. 2, p. 58-64. 2006.
- LI, S; HAWORTH, J.; STEIN, A.; CHENG, T. Geospatial big data handling theory and methods: A review and research challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 119-133, 2015. DOI: 10.1016/j.isprsjprs.2015.10.012.
- MACKANESS, W. A.; RUAS, A.; SARJAKOSKI, L. T. **Generalisation of Geographic Information: Cartographic Modelling and Applications**. 2^a ed. Amsterdam: Elsevier, 2011.
- McMASTER, R. B.; SHEA, K. S. **Generalization in Digital Cartography**. 1^a ed. Washington: Association of American Geographers, 1992.
- MLENEK, D. C. **Métodos semiautomáticos para contagem de árvores em plantios de pinus taeda I. derivados de dados LiDAR aerotransportado**. 2020. 99 p. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná, Curitiba, 2020.
- OHORI, K.; LEDOUX, H.; BILJECKI, F.; STOTER, J. Modeling a 3D city model and its levels of detail as a True 4D Model, **ISPRS International Journal GeoInformation**, v. 4, p. 1055 – 1075, 2015. DOI:10.3390/ijgi4031055.
- OPENSTREETMAP. © **contribuidores do OpenStreetMap**. 2021. Disponível em: <<https://www.openstreetmap.org/>>/ Acesso em: 07 out. 2021.
- ORTEGA-CÓRDOVA, L.M. **Urban vegetation modeling 3D levels of detail**. 2018. 96 p. Master of Science

Thesis – Department of Urbanism, Delft University of Technology, 2018.

- OVIEDO, S. P. D. **Verificação do uso das variáveis visuais tom de cor e textura em representações 3D de ambientes indoor**. 2014. 92 p. Dissertação de Mestrado - Programa de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná, Curitiba, 2014.
- PAULY, M.; KEISER, R.; GROSS, M. 2003. Multi-scale feature extraction on point-sampled surfaces. In: COMPUTATION GRAPHIC FORUM. 2003. Granada. **Proceedings...** Granada: 2003. p. 281–289.
- PREFEITURA MUNICIPAL DE SALVADOR (PMS). **Mapeamento Cartográfico de Salvador**. 2021. Disponível em: <<http://cartografia.salvador.ba.gov.br/index.php/dados-geoespaciais/baixar-dados-geoespaciais>>. Acesso em: 2 maio 2021.
- POINT CLOUD LIBRARY (PCL). Module Octree. **Overview**. 2021. Disponível em: <https://pointclouds.org/documentation/group__octree.html>. Acesso em: 15 out. 2021.
- POPESCU, S.C. **Estimating Plot-Level Forest Biophysical Parameters Using Small-Footprint Airborne Lidar Measurements**. 2002. 145 p. Dissertation - Department of Forestry, Virginia Polytechnic Institute and State University, Virginia, 2002.
- POPESCU, S. C.; WYNNE, R. H. Seeing the trees in the forest. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 5, p. 589-604, 2004. DOI: 10.14358/PERS.70.5.589
- POUX, F. **The smart pointcloud: structuring 3D intelligent point data**. 2019. 268 p. Doctoral dissertation – Department of Geography, University of Liège, 2019.
- RIEGL LASER MEASUREMENT SYSTEMS GmbH (RIEGL). Products. **Airborne scanning**. Horn, 2019. Disponível em: <http://riegl.com/uploads/tx_pxpriegl/downloads/RIEGL_VQ-480II_Datasheet_2019-10-16.pdf>. Acesso em 04 jun. 2021.
- ROBINSON, A. H.; SALE, R. D.; MORRISON, J. L. **Elements of Cartography**. 4ª ed. Nova York: John Wiley & Sons, 1978.
- ROBINSON, A. H.; MORRISON, J. L.; MUEHRCKE, P. C.; KIMERLING, A. J.; GUPTILL, S. C. **Elements of Cartography**. 6ª ed. Nova York: John Wiley & Sons, 1995.
- ROBINSON, A. C.; DEMSAR, U.; MOOREC, A.B.; BUCKLEYD, A.; JIANGE, B.; FIELD, K.; KRAAK, M.J.; CAMBOIM, S.P.; SLUTER, C.R. Geospatial big data and cartography: research challenges and opportunities for making maps that matter. **International Journal of Cartography**, v. 3, n.1, p. 32-60, 2017. DOI: 10.1080/23729333.2016.1278151.
- ROQUE, N.; GUEDES, M. L. S.; CAMPOS, L.; CONTI, L. M.; JESUS, J. C.; JESUS, A. R. R.; CARVALHO, G. M.; REBOUÇAS, I. C. P. **Flora das áreas verdes de Ondina, Salvador, Bahia**. 1ª ed. Salvador: Editora da Universidade Federal da Bahia, 2020.
- ROUSSEL, J. R.; AUTYB, D.; COOPSC, N. C.; TOMPALSKIC, P.; GOODBODYC, T. R. H.; MEADOR, A. S.; BOURDOND, J. F.; BOISSIEUE, F.; ACHIMA, A. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote sensing of environment**, v. 251, 2020. DOI: 10.1016/j.rse.2020.112061
- RUSU R. B.; COUSINS S. 3D is here: Point Cloud Library (PCL). In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION, 2011, Shanghai. **Proceedings...** Shanghai: IEEE, 2011. p. 1–4. DOI: 10.1109/ICRA.2011.5980567.
- SCHMIDT, M. A. R. **Uso de mapas 3D para navegação virtual: uma abordagem cognitiva**. 2012. 188 p. Tese de Doutorado - Programa de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná, Curitiba, 2012.
- SILVA, C. A.; KLAUBERG, C.; HUDAK, A.; LIEBERMANN, R.; CARVALHO, S. P. C.; RODRIGUEZ, L. C. E. Aplicando filtro local máximo (LM) através dos métodos da janela fixa e variável em dados LIDAR para identificação de árvores individuais em um povoamentos de Eucalyptus sp. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR), 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu: 2013. p. 6081-6088.
- VO, A. V.; TRUONG-HONG, L.; LAEFER, D. F.; BERTOLOTTO, M. Octree-based region growing for point

- cloud segmentation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.104, p. 88-100. 2015.
- WEINMANN, M. **Reconstruction and Analysis of 3D Scenes: From Irregularly Distributed 3D Points to Object Classes**. 1^a ed. Switzerland: Springer, 2016. DOI 10.1007/978-3-319-29246-5.
- WEINMANN, M.; JUTZI, B.; MALLET, C. Feature relevance assessment for the semantic interpretation of 3d point cloud data. In: ISPRS WORKSHOP LASER SCANNING, 2013, Antalya-Turkey. **Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. II-5/W2, p. 313–318. 2013. DOI: 10.5194/isprsannals-II-5-W2-313-2013.
- WEINMANN, M.; JUTZI, B.; HINZ, S.; MALLET, C. 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, 2015. DOI: 10.1016/j.isprsjprs.2015.01.016.
- WEST, K. F.; WEBB, B. N.; LERSCH, J. R.; POTHIER, S.; TRISCARI, J. M.; IVERSON, A. E. Context-driven automated target detection in 3-D data. IN: SPIE AUTOMATIC TARGET RECOGNITION XIV, 12 April 2004, Orlando, USA. **Proceedings...** Orlando: 2004. p. 133– 143. DOI: 10.1117/12.542536.
- ZHANG, W.; QI, J.; WAN P.; WANG, H.; XIE, D.; WANG, X.; YAN, G. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. **Remote Sensing**, v. 8, n. 6, 2016. DOI: 10.3390/rs8060501.

Biografia do autor principal



Daniel Luís Andrade e Silva, Ponta Porã/MS – Brasil, 1980. Engenheiro cartógrafo formado pelo Instituto Militar de Engenharia (IME), Rio de Janeiro/RJ, mestre em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos/SP. Militar do Exército Brasileiro, integrante da Diretoria de Serviço Geográfico. Tem experiência em processamento digital de imagens de radar para fins de classificação de cobertura da terra. Seu interesse de pesquisa atual é na área de mapeamento e modelagem 3D de vegetação urbana a partir de dados laser.



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.