




UNIVERSIDADE FEDERAL DO PARANÁ

DANIEL LUÍS ANDRADE E SILVA

GENERALIZAÇÃO 3D PARA ARBORIZAÇÃO URBANA A PARTIR DE DADOS  
LIDAR

CURITIBA-PR

2022

DANIEL LUÍS ANDRADE E SILVA

GENERALIZAÇÃO 3D PARA ARBORIZAÇÃO URBANA A PARTIR DE DADOS  
LiDAR

Tese apresentada ao curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Prof. Dr. Daniel Rodrigues dos Santos

Coorientadora: Prof<sup>a</sup> Dr<sup>a</sup> Silvana Philippi Camboim

CURITIBA-PR

2022

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)  
UNIVERSIDADE FEDERAL DO PARANÁ  
SISTEMA DE BIBLIOTECAS – BIBLIOTECA CIÊNCIA E TECNOLOGIA

Silva, Daniel Luís Andrade e

Generalização 3D para arborização urbana a partir de dados LiDAR /  
Daniel Luís Andrade e Silva. – Curitiba, 2022.

1 recurso on-line : PDF.

Tese (Doutorado) – Universidade Federal do Paraná, Setor de  
Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas.

Orientador: Prof. Dr. Daniel Rodrigues dos Santos  
Coorientadora: Profª Drª Silvana Philippi Camboim

1. Arborização das cidades 2. Modelagem de dados (CityGML 3.0).  
3. Sensoriamento remoto (Tecnologia LiDAR). I. Santos, Daniel  
Rodrigues dos. II. Camboim, Silvana Philippi. III. Universidade Federal  
do Paraná. Programa de Pós-Graduação em Ciências Geodésicas. IV.  
Título.

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE CIÊNCIAS DA TERRA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO CIÊNCIAS  
GEODÉSICAS - 40001016002P6

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **DANIEL LUÍS ANDRADE E SILVA** intitulada: **GENERALIZAÇÃO 3D PARA ARBORIZAÇÃO URBANA A PARTIR DE DADOS LIDAR**, sob orientação do Prof. Dr. DANIEL RODRIGUES DOS SANTOS, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 17 de Maio de 2022.

Assinatura Eletrônica

18/05/2022 09:56:34.0

DANIEL RODRIGUES DOS SANTOS

Presidente da Banca Examinadora

Assinatura Eletrônica

18/05/2022 09:07:54.0

HIDEO ARAKI

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

18/05/2022 09:21:11.0

IVANILDO BARBOSA

Avaliador Externo (INSTITUTO MILITAR DE ENGENHARIA)

Assinatura Eletrônica

18/05/2022 12:31:00.0

JOÃO VITOR MEZA BRAVO

Avaliador Externo (UNIVERSIDADE FEDERAL DE UBERLÂNDIA)

Dedico este trabalho aos meus pais Renato (*in memoriam*) e Ana Maria, meus maiores incentivadores desde 15 de julho de 1980.

## AGRADECIMENTOS

A Deus, por esta gratificante etapa concluída.

Ao Exército Brasileiro e, em particular, à Diretoria de Serviço Geográfico e ao Instituto Militar de Engenharia, pela grande oportunidade que me foi dada de cursar o Doutorado e, dessa forma, aperfeiçoar a minha formação profissional;

À minha querida mãe, Ana Maria Andrade e Silva, por toda uma vida de incentivos;

Ao orientador professor Dr. Daniel Rodrigues dos Santos e à co-orientadora professora Dra. Silvana Philippi Camboim pela orientação, pela colaboração e pela confiança depositada;

Aos integrantes da banca avaliadora do exame de Qualificação (professores Hideo e João Bravo) pelas valorosas considerações e sugestões que permitiram um refinamento da abordagem teórica e metodológica desta pesquisa;

A todos os demais professores do PPGCG/UFPR, pelos conhecimentos transmitidos ao longo destes anos;

A todos os amigos e colegas do PPGCG/UFPR, em especial aos ex-integrantes do LAPE (Alex “ome”, Bossola, Rubens “Piauí”, Fabiano, Kauê, Fluhr e Pedrosa), pela convivência acadêmica, futebolística, gastronômica e por ajudas “computacionais” ao longo de todo o curso;

Ao CEPAG (Centro de Pesquisas Aplicadas em Geoinformação), nas pessoas dos professores Ercolin e Luciene, pela disponibilização dos dados LiDAR VANT utilizados;

Aos amigos Felipe Costa e Guimarães Filho pela constante troca de ideias sobre assuntos e contextos técnicos e administrativos pertinentes ao desenvolvimento desta pesquisa;

Aos amigos Ramon (Júnior), Benincasa (Pinball), Luciano e Henrique e à professora Andréa (Expressão Gráfica) pelos *feedback* sobre o entendimento sobre parte do texto e/ou várias das figuras elaboradas nesta tese;

A todos que direta ou indiretamente contribuíram, de maneira não menos importante, para a realização desta tese.

“Toda a generalização é uma hipótese.”  
Henri Poincaré

## RESUMO

Com o avanço das tecnologias geoespaciais, as aquisições LiDAR (*light detection and ranging*) têm se tornado mais ágeis e flexíveis, impactando o volume de dados espaciais tridimensionais (3D) e, consequentemente, o seu custo operacional. Buscando eficiência no mapeamento de arborização urbana utilizando dados LiDAR, uma opção é realizar a generalização 3D, que objetiva a redução operacional do volume de dados sem causar perda de eficácia. Nesse contexto, a presente pesquisa é motivada pela busca de uma solução de generalização 3D que permita obter informações sobre a localização, o porte e a distribuição espacial de árvores urbanas a partir de dados LiDAR adquiridos em plataformas aéreas. Como estratégia de generalização, é adotada uma combinação dos operadores 2D agregação e simplificação adaptados para o domínio 3D, sendo estabelecidas condições que exploram medidas espaciais associadas aos princípios-Gestalt da proximidade e semelhança, além da aplicação de duas técnicas de compressão de nuvens de pontos: partição espacial por *octree* e aprendizado não-supervisionado profundo (*autoencoder*). Anteriormente à generalização, foram empregadas sequencialmente, com a finalidade de delimitar automaticamente as árvores de interesse, as seguintes técnicas de processamento de nuvens de pontos: filtragem, classificação e segmentação. Os experimentos foram realizados com dados LiDAR referentes a dois cenários urbanos distintos (Salvador-BA e Curitiba-PR), adquiridos respectivamente em plataforma aerotransportada convencional e não-tripulada. Os resultados obtidos pela generalização 3D das árvores são compatíveis com o nível de detalhe 2 das classes SVO e PC do módulo *Vegetation*, e representados de acordo com o módulo *PointCloud* do padrão internacional *CityGML 3.0*, permitindo assim validar a metodologia desenvolvida nesta pesquisa.

Palavras-chave: Arborização urbana. Tecnologia LiDAR. Agregação 3D. Simplificação 3D. CityGML 3.0.

## **ABSTRACT**

Due to geotechnological advances, LiDAR (light detection and ranging) acquisitions have become more agile and flexible, impacting volume of three-dimensional (3D) spatial data and, consequently, its operational cost. Seeking efficiency in urban afforestation mapping using LiDAR data, one option is to perform 3D generalization, which aims to reduce volume of data without causing loss of effectiveness. In this context, the present thesis is motivated by search for a 3D generalization solution that allows obtaining information about location, size and spatial distribution of urban trees from LiDAR data acquired on aerial platforms. As a generalization strategy, a combination of 2D aggregation and simplification operators adapted for 3D domain is adopted, establishing conditions that explore spatial measures associated to proximity and similarity Gestalt-principles, in addition to application of two pointcloud compression techniques: partition by octree and unsupervised deep learning (autoencoder). Prior to generalization, pointcloud processing techniques were used sequentially, in order to automatically delimit trees of interest: filtering, classification and segmentation. Experiments were carried out with LiDAR data referring to two distinct urban scenarios (Salvador-BA and Curitiba-PR), respectively acquired in conventional and unmanned airborne platforms. Results obtained after 3D generalization are compatible with level of detail 2 for SVO and PC classes of Vegetation module, and represented according to PointCloud module of international standard CityGML 3.0, thus allowing to validate methodology developed in this research.

**Keywords:** Urban afforestation. LiDAR technology. 3D aggregation. 3D simplification. CityGML 3.0.

## LISTA DE FIGURAS

|                                                                                                                                                                                          |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1 – EXEMPLO DE VEGETAÇÃO URBANA .....                                                                                                                                             | 21 |
| FIGURA 2 - MAPA ILUSTRATIVO DE IDENTIFICAÇÃO DE ÁRVORES URBANAS<br>INVENTARIADAS .....                                                                                                   | 22 |
| FIGURA 3 – DISCRIMINAÇÃO DE VEGETAÇÃO ALTA EM NUVEM DE PONTOS<br>LIDAR .....                                                                                                             | 23 |
| FIGURA 4 – RESUMO DO ESCOPO DA PESQUISA .....                                                                                                                                            | 28 |
| FIGURA 5 - SISTEMA ÓPTICO-MECÂNICO DE VARREDURA LASER.....                                                                                                                               | 31 |
| FIGURA 6 - MECANISMO DE GEORREFERENCIAMENTO DIRETO PARA DADOS<br>LIDAR .....                                                                                                             | 32 |
| FIGURA 7 - PENETRABILIDADE DE PULSOS LASER NA VEGETAÇÃO .....                                                                                                                            | 34 |
| FIGURA 8 - PONTOS ESPÚRIOS IDENTIFICADOS EM UMA NUVEM DE PONTOS<br>.....                                                                                                                 | 36 |
| FIGURA 9 - ELIMINAÇÃO DE PONTOS DE TERRENO: (A) NUVEM DE PONTOS<br>LIDAR ORIGINAL; (B) PONTOS DE TERRENO ELIMINADOS; (C)<br>NUVEM DE PONTOS LIDAR FILTRADA SEM PONTOS DE<br>TERRENO..... | 37 |
| FIGURA 10 - SEMANTIZAÇÃO DE NUVEM DE PONTOS.....                                                                                                                                         | 38 |
| FIGURA 11 - FUNÇÃO DE CLASSIFICAÇÃO REALIZADA NA PESQUISA.....                                                                                                                           | 39 |
| FIGURA 12 - IDENTIFICAÇÃO DE FALSOS POSITIVOS PARA VEGETAÇÃO<br>CLASSIFICADA .....                                                                                                       | 40 |
| FIGURA 13 - MATRIZ DE CONFUSÃO (RESULTADO X REFERÊNCIA) .....                                                                                                                            | 41 |
| FIGURA 14 - ÁRVORES SEGMENTADAS (VARIAÇÃO DE CORES DE ACORDO<br>COM OS ID'S).....                                                                                                        | 43 |
| FIGURA 15 - VISÃO GERAL DA SEGMENTAÇÃO DE ÁRVORES PELO<br>ALGORITMO DE LI ET AL. (2012) .....                                                                                            | 45 |
| FIGURA 16 - MODELO DE REPRESENTAÇÃO 3D COMPACTO .....                                                                                                                                    | 47 |
| FIGURA 17 – GENERALIZAÇÃO 3D COMO UM PROCESSO SUBJETIVO DE<br>DERIVAÇÃO DE DADOS .....                                                                                                   | 48 |
| FIGURA 18 – OPERAÇÃO DE AGREGAÇÃO.....                                                                                                                                                   | 49 |
| FIGURA 19 - AGREGAÇÃO DE DUAS ÁRVORES INDIVIDUAIS (A, B).....                                                                                                                            | 49 |
| FIGURA 20 - PRINCÍPIOS GESTALT: (A) PROXIMIDADE; (B) SEMELHANÇA.....                                                                                                                     | 50 |
| FIGURA 21 - EXEMPLOS DE ÁRVORES PRÓXIMAS E PRÓXIMAS-SIMILARES .....                                                                                                                      | 51 |

|                                                                                                                                                                                                               |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 22 - OPERADOR SIMPLIFICAÇÃO.....                                                                                                                                                                       | 51 |
| FIGURA 23 – SIMPLIFICAÇÃO 3D DE ÁRVORE INDIVIDUAL: (A)<br>REPRESENTAÇÃO ORIGINAL; (B) REPRESENTAÇÃO<br>SIMPLIFICADA. ....                                                                                     | 52 |
| FIGURA 24 - VISÃO GERAL DO <i>CITYGML 3.0</i> .....                                                                                                                                                           | 57 |
| FIGURA 25 – DIAGRAMA UML DO MÓDULO <i>POINTCLOUD</i> DO <i>CITYGML 3.0</i> ....                                                                                                                               | 58 |
| FIGURA 26 - ESQUEMATIZAÇÃO GERAL DA METODOLOGIA EMPREGADA.....                                                                                                                                                | 59 |
| FIGURA 27 - LOCALIZAÇÃO DA ÁREA DE ESTUDO 1 (DADOS ALS) .....                                                                                                                                                 | 61 |
| FIGURA 28 - ÁREA DE ESTUDO 1 EM TRÊS MODOS DISTINTOS: (A)<br>ORTOIMAGEM (RESOLUÇÃO ESPACIAL DE 10 CM); (B) NUVEM<br>DE PONTOS LIDAR (INTENSIDADE); (C) NUVEM DE PONTOS<br>LIDAR (VARIAÇÃO DE ALTIMETRIA)..... | 62 |
| FIGURA 29 - LOCALIZAÇÃO DA ÁREA DE ESTUDO 2 (DADOS ULS) .....                                                                                                                                                 | 63 |
| FIGURA 30 - ÁREA DE ESTUDO 2 VISUALIZADA EM TRÊS MODOS DISTINTOS:<br>(A) NUVEM DE PONTOS LIDAR (RGB); (B) NUVEM DE PONTOS<br>LIDAR (INTENSIDADE); (C) NUVEM DE PONTOS LIDAR<br>(VARIAÇÃO DE ALTIMETRIA). .... | 64 |
| FIGURA 31 - DISTÂNCIAS DE UM PONTO $N_i$ EM SUA $K$ -VIZINHANÇA<br>(ALGORITMO SOR) .....                                                                                                                      | 65 |
| FIGURA 32 – SIMULAÇÃO DE TECIDO (ALGORITMO CSF) .....                                                                                                                                                         | 67 |
| FIGURA 33 - SEQUÊNCIA DE PROCEDIMENTOS PARA A DELIMITAÇÃO DAS<br>ÁRVORES.....                                                                                                                                 | 69 |
| FIGURA 34 - ROTINAS LASTOOLS UTILIZADAS PARA CLASSIFICAÇÃO DOS<br>PONTOS NÃO-TERRENO.....                                                                                                                     | 70 |
| FIGURA 35 - CRITÉRIOS PARA A ANÁLISE E O REFINAMENTO DA<br>CLASSIFICAÇÃO .....                                                                                                                                | 74 |
| FIGURA 36 - ROTINA LASCOLOR PARA COLORIZAÇÃO DA NUVEM DE<br>PONTOS ALS .....                                                                                                                                  | 75 |
| FIGURA 37 - CRITÉRIO DO MÁXIMO LOCAL .....                                                                                                                                                                    | 77 |
| FIGURA 38 – VISÃO GERAL DO MÉTODO DE SEGMENTAÇÃO ADOTADO .....                                                                                                                                                | 79 |
| FIGURA 39 - OPERADORES APLICADOS NA GENERALIZAÇÃO 3D .....                                                                                                                                                    | 82 |
| FIGURA 40 - VISÃO GERAL DA AGREGAÇÃO 3D .....                                                                                                                                                                 | 83 |
| FIGURA 41 - CONDIÇÕES ESPACIAIS PARA A AGREGAÇÃO 3D .....                                                                                                                                                     | 87 |

|                                                                                                                                                                                                                                |     |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| FIGURA 42 – DEFINIÇÃO DO LIMIAR DE DISTÂNCIA ENTRE AS ÁRVORES<br>(MÁXIMO E MÍNIMO) .....                                                                                                                                       | 88  |
| FIGURA 43 – VISÃO GERAL DA SIMPLIFICAÇÃO 3D.....                                                                                                                                                                               | 91  |
| FIGURA 44 – PARTIÇÃO ESPACIAL POR <i>OCTREE</i> .....                                                                                                                                                                          | 92  |
| FIGURA 45 – VISÃO GERAL DA ARQUITETURA <i>AUTOENCODER (DEPOCO)</i> .....                                                                                                                                                       | 93  |
| FIGURA 46 - <i>KERNEL</i> CONVOLUCIONAL 3D APLICADO.....                                                                                                                                                                       | 94  |
| FIGURA 47 - RESULTADO DAS FILTRAGENS PARA OS DADOS ALS: (A) SOR;<br>(B) CSF .....                                                                                                                                              | 97  |
| FIGURA 48 - (A) NUVEM DE PONTOS ALS COM ALTIMETRIA ENTRE 5 E 30 M;<br>(B) RESULTADO VISUAL DE SUA CLASSIFICAÇÃO INICIAL. ....                                                                                                  | 99  |
| FIGURA 49 – PONTOS DE VEGETAÇÃO ROTULADOS NOS DADOS ALS: (A)<br>CLASSIFICAÇÃO INICIAL; (B) CLASSIFICAÇÃO REFINADA.....                                                                                                         | 101 |
| FIGURA 50 - RESULTADO VISUAL DA SEGMENTAÇÃO DE ÁRVORES NOS<br>DADOS ALS (VISUALIZAÇÃO EM CORES POR ID) .....                                                                                                                   | 102 |
| FIGURA 51 - ATRIBUTOS MÉTRICOS EXTRAÍDOS DAS ÁRVORES<br>DELIMITADAS NOS DADOS ALS (VISUALIZAÇÃO EM TABELA).....                                                                                                                | 102 |
| FIGURA 52 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE<br>PONTOS ALS RESULTANTE DA SEGMENTAÇÃO (A) E O<br>RESULTADO DE SUAS COMPRESSÕES POR <i>OCTREE</i> COM 10<br>(B) E 9 SUBDIVISÕES (C).....                           | 109 |
| FIGURA 53 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE<br>PONTOS ALS RESULTANTE DA SEGMENTAÇÃO (A) E O<br>RESULTADO DE SUAS COMPRESSÕES POR <i>AUTOENCODER</i><br>COM DENSIDADE DE 2 (B) E 1 PONTO/M <sup>2</sup> (C)..... | 110 |
| FIGURA 54 - BANCO DE DADOS PARA ÁRVORES GENERALIZADAS<br>(CONJUNTO A) .....                                                                                                                                                    | 113 |
| FIGURA 55 - RESULTADO DAS FILTRAGENS PARA OS DADOS ULS: (A) SOR;<br>(B) CSF .....                                                                                                                                              | 114 |
| FIGURA 56 - (A) NUVEM DE PONTOS ULS COM ALTURA ENTRE 5 E 30 M; (B)<br>RESULTADO VISUAL DA CLASSIFICAÇÃO.....                                                                                                                   | 116 |
| FIGURA 57 - PONTOS DE VEGETAÇÃO ROTULADOS NOS DADOS ULS: (A)<br>CLASSIFICAÇÃO INICIAL; (B) CLASSIFICAÇÃO REFINADA.....                                                                                                         | 118 |
| FIGURA 58 - RESULTADO VISUAL DA SEGMENTAÇÃO DE ÁRVORES NOS<br>DADOS ULS (VISUALIZAÇÃO EM CORES POR ID).....                                                                                                                    | 119 |

|                                                                                                                                                                                                                                 |     |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| FIGURA 59 - ATRIBUTOS MÉTRICOS EXTRAÍDOS DAS ÁRVORES<br>DELIMITADAS NOS DADOS ULS (VISUALIZAÇÃO EM TABELA)                                                                                                                      | 119 |
| FIGURA 60 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE<br>PONTOS ULS RESULTANTE DA SEGMENTAÇÃO (A) E O<br>RESULTADO DE SUAS COMPRESSÕES POR <i>OCTREE</i> COM 10<br>(B) E 9 SUBDIVISÕES (C).....                            | 125 |
| FIGURA 61 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE<br>PONTOS ULS RESULTANTE DA SEGMENTAÇÃO (A) E O<br>RESULTADO DE SUAS COMPRESSÕES POR <i>AUTOENCODER</i><br>COM DENSIDADE DE 2 (B) E 1 PONTO/M <sup>2</sup> (C) ..... | 127 |

## LISTA DE GRÁFICOS

|                                                                                                                                     |     |
|-------------------------------------------------------------------------------------------------------------------------------------|-----|
| GRÁFICO 1 – REDUÇÃO DO NÚMERO DE ÁRVORES POR AGREGAÇÃO 3D<br>(DADOS ALS/ÁREA DE ESTUDO 1).....                                      | 105 |
| GRÁFICO 2 – REDUÇÃO DO GRAU DE FRAGMENTAÇÃO DO CONJUNTO DE<br>ÁRVORES POR AGREGAÇÃO 3D (DADOS ALS/ÁREA DE ESTUDO<br>1).....         | 107 |
| GRÁFICO 3 – DADOS ALS (ÁREA DE ESTUDO 1): AUMENTO DO GRAU DE<br>DISPERSÃO DO CONJUNTO DE ÁRVORES (ADA) POR<br>AGREGAÇÃO 3D .....    | 107 |
| GRÁFICO 4 – DADOS ULS (ÁREA DE ESTUDO 2): REDUÇÃO DO NÚMERO DE<br>ÁRVORES (RNA) POR AGREGAÇÃO 3D .....                              | 122 |
| GRÁFICO 5 – DADOS ULS (ÁREA DE ESTUDO 2): REDUÇÃO DO GRAU DE<br>FRAGMENTAÇÃO DO CONJUNTO DE ÁRVORES (RNA) POR<br>AGREGAÇÃO 3D ..... | 123 |
| GRÁFICO 6 – DADOS ULS (ÁREA DE ESTUDO 2): AUMENTO DO GRAU DE<br>DISPERSÃO DO CONJUNTO DE ÁRVORES (ADA) POR<br>AGREGAÇÃO 3D .....    | 124 |

## LISTA DE QUADROS

|                                                                                                                                  |    |
|----------------------------------------------------------------------------------------------------------------------------------|----|
| QUADRO 1 – RESUMO DOS LOD (CLASSE <i>VEGETATION</i> ) ESPECIFICADOS NO<br>PADRÃO <i>CITYGML 3.0</i> .....                        | 26 |
| QUADRO 2 – INFORMATIVO DA AQUISIÇÃO LIDAR RIEGL VQ480-II .....                                                                   | 60 |
| QUADRO 3 – INFORMATIVO DA AQUISIÇÃO LIDAR DJI ZENMUSE L1 .....                                                                   | 63 |
| QUADRO 4 – VALORES DOS PARÂMETROS PARA A FILTRAGEM SOR.....                                                                      | 66 |
| QUADRO 5 – VALORES ADOTADOS PARA OS PARÂMETROS DA FILTRAGEM<br>CSF .....                                                         | 68 |
| QUADRO 6 – PARÂMETROS DEFINIDOS PARA A ROTINA <i>LASCLASSIFY</i> .....                                                           | 73 |
| QUADRO 7 – CRITÉRIO RADIOMÉTRICO-ESPECTRAL PARA ANÁLISE DE UM<br>PONTO $X_i$ ROTULADO .....                                      | 76 |
| QUADRO 8 – RESUMO DAS CONDIÇÕES ESTABELECIDAS PARA O<br>REFINAMENTO DA CLASSIFICAÇÃO DE UM PONTO $X_i$ (DOIS<br>CRITÉRIOS) ..... | 78 |
| QUADRO 9 – RESUMO DOS LIMIARES ESTABELECIDOS PARA A AGREGAÇÃO<br>3D .....                                                        | 89 |

## LISTA DE TABELAS

|                                                                                                                                                                |     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| TABELA 1 – REDUÇÃO DA QUANTIDADE DE PONTOS: NUVEM ALS ORIGINAL X NUVEM ALS FILTRADA (SOR + CSF) .....                                                          | 98  |
| TABELA 2 – QUANTIDADES DE PONTOS ROTULADOS APÓS A CLASSIFICAÇÃO INICIAL (DADOS ALS) .....                                                                      | 99  |
| TABELA 3 – MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO DA NUVEM DE PONTOS ALS .....                                                                                    | 100 |
| TABELA 4 – MÉTRICAS DA PAISAGEM CALCULADAS ANTES DA GENERALIZAÇÃO 3D PARA OS DADOS ALS.....                                                                    | 103 |
| TABELA 5 – RESUMO QUANTITATIVO DA AGREGAÇÃO DAS 851 ÁRVORES DELIMITADAS NOS DADOS ALS (POR CONJUNTO DE LIMIARES) .....                                         | 104 |
| TABELA 6 – RESUMO DAS MÉTRICAS DE PAISAGEM CALCULADAS DEPOIS DA AGREGAÇÃO 3D (DADOS ALS).....                                                                  | 106 |
| TABELA 7 – COMPARATIVO DE REDUÇÃO DO ESPAÇO DE ARMAZENAMENTO E DA QUANTIDADE DE PONTOS PELA COMPRESSÃO DOS DADOS ALS POR <i>OCTREE</i> .....                   | 108 |
| TABELA 8 – COMPARATIVO DE REDUÇÃO DE ESPAÇO DE ARMAZENAMENTO E QUANTIDADE DE UNIDADES ELEMENTARES PARA A COMPRESSÃO DOS DADOS ALS POR <i>AUTOENCODER</i> ..... | 110 |
| TABELA 9 – CORRESPONDÊNCIA DAS ÁRVORES GENERALIZADAS COM A CENA 3D ORIGINAL (DADOS ALS).....                                                                   | 112 |
| TABELA 10 – REDUÇÃO DA QUANTIDADE DE PONTOS: NUVEM ULS ORIGINAL X NUVEM ULS FILTRADA (SOR + CSF) .....                                                         | 114 |
| TABELA 11 – QUANTIDADES DE PONTOS ROTULADOS APÓS A CLASSIFICAÇÃO INICIAL (DADOS ULS) .....                                                                     | 116 |
| TABELA 12 – MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO DA NUVEM DE PONTOS ULS .....                                                                                   | 117 |
| TABELA 13 – MÉTRICAS DE PAISAGEM CALCULADAS ANTES DA GENERALIZAÇÃO 3D PARA OS DADOS ULS.....                                                                   | 120 |
| TABELA 14 – RESUMO QUANTITATIVO DA AGREGAÇÃO DAS 518 ÁRVORES NOS DADOS ULS (POR CONJUNTO DE LIMIARES) .....                                                    | 121 |

|                                                                                                                                                                 |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| TABELA 15 – RESUMO DAS MÉTRICAS DE PAISAGEM CALCULADAS DEPOIS DA AGREGAÇÃO 3D (DADOS ULS) .....                                                                 | 123 |
| TABELA 16 – COMPARATIVO DE REDUÇÃO DO ESPAÇO DE ARMAZENAMENTO E DA QUANTIDADE DE PONTOS PELA COMPRESSÃO DOS DADOS ULS POR <i>OCTREE</i> .....                   | 125 |
| TABELA 17 – COMPARATIVO DE REDUÇÃO DE ESPAÇO DE ARMAZENAMENTO E QUANTIDADE DE UNIDADES ELEMENTARES PARA A COMPRESSÃO DOS DADOS ULS POR <i>AUTOENCODER</i> ..... | 126 |
| TABELA 18 – CORRESPONDÊNCIA DAS ÁRVORES GENERALIZADAS COM A CENA 3D ORIGINAL (DADOS ULS) .....                                                                  | 128 |
| TABELA 19 – COMPARATIVO ENTRE OS EXPERIMENTOS REALIZADOS (DADOS ALS X DADOS ULS) .....                                                                          | 130 |

## LISTA DE ABREVIATURAS OU SIGLAS

|         |                                                                  |
|---------|------------------------------------------------------------------|
| 3D      | - Tridimensional                                                 |
| AA      | - Árvores agregadas                                              |
| AD      | - Árvores delimitadas                                            |
| ADA     | - Aumento da dispersão das árvores                               |
| AE      | - Árvores eliminadas                                             |
| ALS     | - <i>Airborne LaserScanning</i>                                  |
| AM      | - Árvores mescladas                                              |
| ANA     | - Árvores não-agregadas                                          |
| AR      | - Árvores resultantes                                            |
| ASPRS   | - <i>American Society for Photogrammetry and Remote Sensing</i>  |
| CHM     | - <i>Canopy height model</i>                                     |
| CNN     | - <i>Convolutional Neural Network</i>                            |
| CSF     | - <i>Cloth Simulation Filter</i>                                 |
| CITYGML | - <i>City Geography Markup Language Standard</i>                 |
| DA      | - Densidade de árvores                                           |
| DEPOCO  | - <i>Deep Point Map Compression</i>                              |
| EAG     | - Espaço de armazenamento após a generalização                   |
| EO      | - Espaço de armazenamento original                               |
| GD      | - Grau de dispersão                                              |
| GF      | - Grau de fragmentação                                           |
| GNSS    | - <i>Global Navigation Satellite System</i>                      |
| GPS     | - <i>Global Positioning System</i>                               |
| IBGE    | - Instituto Brasileiro de Geografia e Estatística                |
| INS     | - <i>Inertial Navigation System</i>                              |
| ITD     | - <i>Individual Tree Detection</i>                               |
| KPCONV  | - <i>Kernel Points Convolutional</i>                             |
| LAS     | - <i>LIDAR Data Exchange Format</i>                              |
| LASER   | - <i>Light Amplification by Stimulated Emission of Radiation</i> |
| LiDAR   | - <i>Light Detection and Ranging</i>                             |
| LMF     | - <i>Local Maximum Filter</i>                                    |
| LoD     | - <i>Level of Detail</i>                                         |
| MLP     | - <i>Multilayer Perceptron</i>                                   |

|         |                                                                        |
|---------|------------------------------------------------------------------------|
| NBR     | - Norma Brasileira                                                     |
| NPG     | - Número de pontos após a generalização                                |
| NPO     | - Número de pontos original                                            |
| OGC     | - <i>Open Geospatial Consortium</i>                                    |
| PA      | - Perda de árvores                                                     |
| PAP     | - Pares de árvores próximas                                            |
| PAPH    | - Pares de árvores próximas similares por altura                       |
| PAPHS   | - Pares de árvores próximas similares por altura e por área de copa    |
| PC      | - <i>Plant Cover</i>                                                   |
| PEC-PCD | - Padrão de Exatidão Cartográfica para Produtos Cartográficos Digitais |
| REA     | - Redução do espaço de armazenamento                                   |
| RF      | - Redução de fragmentação                                              |
| RGB     | - <i>Red, Green, Blue</i>                                              |
| RNA     | - Redução do número de árvores                                         |
| RNP     | - Redução do número de pontos                                          |
| RV      | - Redução de áreas verdes                                              |
| SIRGAS  | - Sistema de Referência Geocêntrico para as Américas                   |
| SOR     | - <i>Statistical Outlier Removal</i>                                   |
| SVO     | - <i>Solitary Vegetation Object</i>                                    |
| ToF     | - <i>Time-of-Flight</i>                                                |
| UAV     | - <i>Unmanned Aerial Vehicle</i>                                       |
| ULS     | - <i>UAV LaserScanning</i>                                             |
| UML     | - <i>Unified Modeling Language</i>                                     |
| UTM     | - Universal Transversa de Mercator                                     |
| WS      | - window size                                                          |

## SUMÁRIO

|                                                                                         |           |
|-----------------------------------------------------------------------------------------|-----------|
| <b>1 INTRODUÇÃO .....</b>                                                               | <b>21</b> |
| 1.1 CONSIDERAÇÕES INICIAIS .....                                                        | 21        |
| 1.2 CONTEXTUALIZAÇÃO DO PROBLEMA.....                                                   | 24        |
| 1.3 HIPÓTESE CENTRAL .....                                                              | 27        |
| 1.4 OBJETIVOS .....                                                                     | 27        |
| 1.4.1 Objetivo geral .....                                                              | 27        |
| 1.4.2 Objetivos específicos.....                                                        | 27        |
| 1.5 JUSTIFICATIVA E CONTRIBUIÇÃO DA PESQUISA .....                                      | 28        |
| 1.6 ORGANIZAÇÃO DA TESE.....                                                            | 30        |
| <b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>                                                     | <b>31</b> |
| 2.1 AQUISIÇÃO DE DADOS LIDAR .....                                                      | 31        |
| 2.2 TÉCNICAS DE PROCESSAMENTO DE NUVENS DE PONTOS.....                                  | 35        |
| 2.2.1 Filtragem .....                                                                   | 35        |
| 2.2.2 Classificação (segmentação semântica) .....                                       | 37        |
| 2.2.3 Segmentação por instância (delimitação de árvores).....                           | 42        |
| 2.3 GENERALIZAÇÃO 3D .....                                                              | 46        |
| 2.3.1 Aspectos gerais .....                                                             | 46        |
| 2.3.2 Operadores de generalização .....                                                 | 48        |
| 2.3.2.1 Agregação .....                                                                 | 48        |
| 2.3.2.2 Simplificação .....                                                             | 51        |
| 2.3.3 Critérios de avaliação .....                                                      | 53        |
| 2.4 PADRÃO <i>CITYGML 3.0</i> (MÓDULO <i>POINTCLOUD</i> ) .....                         | 57        |
| <b>3 DESENVOLVIMENTO METODOLÓGICO.....</b>                                              | <b>59</b> |
| 3.1 VISÃO GERAL .....                                                                   | 59        |
| 3.2 DADOS UTILIZADOS E ÁREAS DE ESTUDO .....                                            | 60        |
| 3.2.1 Dados ALS e ortoimagem RGB (área de estudo 1: bairro da Pituba, Salvador-BA)..... | 60        |
| 3.2.2 Dados ULS (área de estudo 2: Campus Centro Politécnico da UFPR, Curitiba-PR)..... | 62        |
| 3.3 SOFTWARES UTILIZADOS.....                                                           | 64        |
| 3.4 DESCRIÇÃO DAS ETAPAS METODOLÓGICAS .....                                            | 65        |
| 3.4.1 Filtragem .....                                                                   | 65        |

|                                                                                 |            |
|---------------------------------------------------------------------------------|------------|
| 3.4.1.1 Remoção de pontos espúrios (1ª filtragem).....                          | 65         |
| 3.4.1.2 Eliminação dos pontos de terreno (2ª filtragem) .....                   | 66         |
| 3.4.2 Delimitação das árvores .....                                             | 69         |
| 3.4.2.1 Classificação dos pontos não-terreno.....                               | 70         |
| 3.4.2.2 Refinamento da classificação .....                                      | 73         |
| 3.4.2.3 Segmentação das copas .....                                             | 78         |
| 3.4.3 Generalização 3D.....                                                     | 81         |
| 3.4.3.1 Agregação 3D.....                                                       | 82         |
| 3.4.3.2 Simplificação 3D.....                                                   | 90         |
| <b>4 RESULTADOS E DISCUSSÕES.....</b>                                           | <b>97</b>  |
| 4.1 EXPERIMENTOS COM DADOS ALS (ÁREA DE ESTUDO 1) .....                         | 97         |
| 4.1.1 Filtragem .....                                                           | 97         |
| 4.1.2 Delimitação das árvores .....                                             | 98         |
| 4.1.2.1 Classificação e refinamento dos pontos não-terreno.....                 | 98         |
| 4.1.2.2 Segmentação das copas e extração dos atributos métricos das árvores ... | 101        |
| 4.1.3 Generalização 3D.....                                                     | 103        |
| 4.1.3.1 Agregação 3D.....                                                       | 103        |
| 4.1.3.2 Simplificação 3D.....                                                   | 108        |
| 4.1.4 Avaliação final dos resultados .....                                      | 111        |
| 4.2 EXPERIMENTOS COM DADOS ULS (ÁREA DE ESTUDO 2) .....                         | 114        |
| 4.2.1 Filtragem .....                                                           | 114        |
| 4.2.2 Delimitação das árvores .....                                             | 115        |
| 4.2.2.1 Classificação e refinamento dos pontos não-terreno.....                 | 115        |
| 4.2.2.2 Segmentação das copas e extração dos atributos métricos das árvores ... | 118        |
| 4.2.3 Generalização 3D.....                                                     | 120        |
| 4.2.3.1 Agregação 3D.....                                                       | 120        |
| 4.2.3.2 Simplificação 3D.....                                                   | 124        |
| 4.2.4 Avaliação final dos resultados .....                                      | 127        |
| 4.3 COMPARATIVO ENTRE OS DOIS EXPERIMENTOS REALIZADOS .....                     | 130        |
| <b>5 CONCLUSÕES E RECOMENDAÇÕES .....</b>                                       | <b>133</b> |
| <b>REFERÊNCIAS.....</b>                                                         | <b>137</b> |

## 1 INTRODUÇÃO

### 1.1 CONSIDERAÇÕES INICIAIS

A vegetação urbana, definida por Biondi (2015) como a parte vegetal (natural, plantada ou espontânea) presente nas paisagens urbanas (FIGURA 1) em diferentes formas de vida (árvores, arbustos, trepadeiras, herbáceas, plantas de forração, plantas aquáticas e outras), é essencial para a qualidade de vida da população (FAO, 2011) em virtude de benefícios como: - contribuir para o conforto visual e ambiental; - amenizar as condições climáticas por meio da diminuição das amplitudes térmicas, reduzindo o efeito de ilhas de calor nos centros urbanos e aumentando a umidade atmosférica que refresca o ar das cidades; - melhorar o ar a ser respirado; - proteger o solo contra erosão; - proteger das forças dos ventos; - diminuir a poluição sonora; - absorver a poluição da atmosfera; - contribuir para o refúgio e alimento da fauna.

FIGURA 1 – EXEMPLO DE VEGETAÇÃO URBANA



FONTE: O autor (2022)

Devido à sua relevância social, econômica e ambiental para o desenvolvimento sustentável das cidades e municípios, é indispensável uma gestão adequada e efetiva para esse componente biótico. Nesse sentido, são estabelecidos os planos municipais de arborização urbana, que têm a finalidade de legitimar e descrever ações referentes à implantação, ao plantio (silvicultura), à manutenção e ao monitoramento das árvores (COMITÊ, 2018), sendo estas definidas pela Norma Brasileira NBR 16246-1:20131 (ASSOCIAÇÃO BRASILEIRA DE NORMAS

TÉCNICAS, 2013) como um tipo de vegetal lenhoso, com tronco e copa bem definidos, que atinge no mínimo 5 m de altura e 5 cm de diâmetro à altura do peito (1,30 m do solo).

Para a execução dos planos de arborização urbana, é imprescindível ter um correto mapeamento das árvores (FIGURA 2) que possibilite a confecção de inventários onde são preenchidas informações sobre a localização, a espécie e as características dendrológicas (diâmetro e altura do tronco, diâmetro da copa, ramificação lateral, etc) de cada árvore identificada, além das condições físicas locais e do espaço disponível para plantio de novas mudas.

FIGURA 2 - MAPA ILUSTRATIVO DE IDENTIFICAÇÃO DE ÁRVORES URBANAS INVENTARIADAS



FONTE: Comitê (2018)


Diante dessa demanda, busca-se soluções de geoinformação que sejam eficazes para esse propósito, considerando a dificuldade de acesso a algumas áreas verdes existentes e também a necessidade de se ter a maior cobertura territorial de mapeamento possível. Hirye et al. (2017) e Li et al. (2019) analisaram a eficácia de dados de sensoriamento remoto para o mapeamento de árvores urbanas, tendo destacado o emprego da tecnologia LiDAR (*Light Detection and Ranging*) desde o final da década de 1990 principalmente para a discriminação de coberturas vegetais e para a estimativa de parâmetros biofísicos das árvores (áreas das copas, altura total, índice de área foliar, densidade de área foliar e biomassa).

O emprego da tecnologia LiDAR para essa finalidade é viabilizado por suas seguintes vantagens: - aquisição direta de dados 3D sem o emprego dos tradicionais métodos fotogramétricos, gerando “réplicas digitais 3D” representadas por nuvens de

pontos; - penetrabilidade dos pulsos LASER (*Light Amplification by Stimulated Emission of Radiation*) nos alvos vegetais (ALONZO, 2015; RAMDANI, 2013; RUTZINGER, 2008).

A FIGURA 3 mostra a cobertura vegetal alta de uma paisagem urbana sendo discriminada em uma nuvem de pontos LiDAR.

FIGURA 3 – DISCRIMINAÇÃO DE VEGETAÇÃO ALTA EM NUVEM DE PONTOS LIDAR



FONTE: O autor (2022)

Com o avanço das tecnologias geoespaciais, as aquisições LiDAR têm se tornado mais ágeis e flexíveis, impactando o volume (massividade referente à quantidade numerosa de pontos) e o valor (em termos de informações acionáveis) dos dados obtidos. Consequentemente, é exigido um maior esforço computacional (FERLIN e REZENDE, 2019) para o armazenamento, o gerenciamento, o acesso, a manipulação, o processamento e a visualização (LI et al, 2015; ROBINSON et al., 2017) do ativo de realidade digital gerado (POUX, 2019). Exemplo disso é o uso de sensores laser embarcados em veículos aéreos não-tripulados (*unmanned aerial vehicle* – UAV), que permite o aumento da densidade dos pontos registrados em relação à aquisição por sensores laser aerotransportados, possibilitando um mapeamento de arborização urbana mais acurado mas implicando um maior custo computacional (OHORI et al., 2015).

A fim de mitigar esse problema, deve-se reduzir o volume operacional dos dados utilizados sem causar perda de eficácia, o que pode ser conseguido por um processo de generalização 3D, apontado por Poux (2019) como um meio de gerar modelos de representação espacial compactos com reduzidos níveis de detalhamento

(*level of details* – LoD) a partir de nuvens de pontos, sendo exigidos menores requisitos computacionais, principalmente de armazenamento, visualização e análise dos dados (KADA, 2006). Tem-se assim a generalização 3D como uma opção de eficiência no mapeamento de arborização urbana utilizando a tecnologia LiDAR, sendo essencial definir um LoD adequado às análises espaciais requeridas.

Diante disso, a presente pesquisa é motivada pela busca de uma solução de generalização que permita obter informações sobre a localização, o porte e a distribuição espacial de árvores urbanas a partir de dados LiDAR adquiridos em plataformas aéreas.

Nas seções seguintes deste capítulo são apresentados o problema e a hipótese centrais da pesquisa, além dos objetivos (geral e específicos) a serem atingidos, da contribuição do estudo científico realizado e da organização do conteúdo da tese.

## 1.2 CONTEXTUALIZAÇÃO DO PROBLEMA

A temática da generalização 3D vem sendo estudada nas últimas duas décadas como uma adaptação teórica e metodológica da generalização de mapas (MACKANESS et al., 2011), pois são indefinidos requisitos, critérios e regras específicas para objetos 3D (SESTER, 2020). Devido à sua inerente subjetividade, diversas estratégias podem ser adotadas a fim de atender propósitos de uso definidos (BILJECKI, 2017).

Embora vários métodos de generalização 3D já tenham sido implementados, principalmente em pesquisas acadêmicas voltadas para modelagens de cidades (SESTER, 2020), a abordagem dessa temática envolvendo vegetação urbana é recente e pouco abrangente, ainda limitada a apoiar análises espaciais de outros elementos urbanos, carecendo da realização de estudos que contemplem aplicações específicas para essa classe.

Destaca-se o trabalho de Ortega-Cordova (2018), que avaliou conjuntos de LoD de objetos de vegetação especificados em diferentes modelos 3D de cidades e constatou haver imprecisões e pouca consistência nas especificações existentes, que se mostram relativamente genéricas e flexíveis, podendo ser adaptadas e complementadas de acordo com a aplicação desejada.

Sem relacionar algoritmos específicos de generalização, Ortega-Cordova (2018) indica o uso de geometria implícita como uma maneira de reduzir custos computacionais em modelagens 3D de vegetação. Segundo tal autor, o uso de modelos de geometria implícita, tal como o *City Geography Markup Language Standard (CityGML)* do *Open Geospatial Consortium (OGC)*, é amigável à automação e econômico no armazenamento porque a representação dos objetos é feita somente por conjuntos de coordenadas que definem suas localizações, independentemente de sua dimensionalidade, que no caso das árvores urbanas pode ser: 0D para referências pontuais de localização (centroides); 1D para fileiras de árvores; 2D para projeções de copas; 2.5D para alturas extrudidas e 3D original.

Adotado como o padrão internacional para representar e armazenar informações geográficas 3D de objetos urbanos do mundo real, o *CityGML* já se encontra em sua terceira versão, lançada em 2021, denominada *CityGML 3.0* (KUTZNER; CHATURVEDI; KOLBE, 2020), na qual foi adicionado o módulo *PointCloud*, que possibilita usar nuvens de pontos 3D para representar objetos por meio de geometria *multipoint*.

Dessa forma, a modelagem de árvores urbanas a partir de dados LiDAR no padrão *CityGML 3.0* pode atender tanto às especificações do módulo *PointCloud* como do pré-existente módulo *Vegetation*, que é dividido em duas classes: *solitary vegetation object* (SVO), usada para modelar vegetação autônoma/solitária, tal como árvores de ruas; *plant cover* (PC), para modelar cobertura vegetal composta por conjuntos de elementos similares, tais como fragmentos florestais e vegetação herbácea.

A representação de elemento SVO pode ocorrer tanto por geometria explícita como implícita, sendo relacionados atributos como altura relativa total, diâmetro do tronco, diâmetro da copa, classe e espécie. Para um elemento PC, a representação ainda é somente por geometria *multisolid*, *multisurface* e *solid*, sendo bastante usado o atributo altura média para um caso de representação generalizada.

No QUADRO 1, são resumidas as descrições dos quatro LoD hierárquicos (GRANSHAW, 2016) especificados para as classes SVO e PC no *CityGML 3.0*, sendo organizados do mais simplificado (menor nível de detalhes) ao mais detalhado (maior nível de detalhes), sem apresentar relações de agregação ou generalização entre si, visando atender diferentes escalas e requisitos de uso (OGC, 2022).

QUADRO 1 - RESUMO DOS LOD (CLASSE *VEGETATION*) ESPECIFICADOS NO PADRÃO *CITYGML 3.0*

| Nível de detalhes (LoD) | Extensão geográfica                        | Especificações geométricas                                                              |                                | Nível de acurácia |
|-------------------------|--------------------------------------------|-----------------------------------------------------------------------------------------|--------------------------------|-------------------|
|                         |                                            | SVO                                                                                     | PC                             |                   |
| LoD 0                   | Paisagem regional                          | Sem especificações.                                                                     | Sem especificações.            | Mais baixo        |
| LoD 1                   | Cidade ou Município                        | Sem especificações.                                                                     | Cobertura maior que 50m x 50m. | Baixo             |
| LoD 2                   | Bairro/distrito de uma cidade ou município | - Altura mínima de 6 metros (geometria implícita);<br>- Sem especificações horizontais. | Cobertura maior que 5m x 5m.   | Médio             |
| LoD 3                   | Projeto arquitetônico                      | - Altura mínima de 2 metros (geometria implícita);<br>- Sem especificações horizontais. | Menor que o LoD 2.             | Alto              |

FONTE: ORTEGA-CORDOVA (2018)

Observa-se que a especificidade geométrica e a extensão geográfica do LoD 2 para as duas classes são compatíveis com o propósito de uso de generalização 3D definido nesta pesquisa, sendo este, portanto, o nível de detalhe desejado para a solução de generalização a ser encontrada.

Indo ao encontro da abordagem conceitual feita por McMaster e Shea (1992) no tocante à generalização de mapas, onde são discutidos fatores relacionados às questões “por que generalizar?”, “quando generalizar?” e “como generalizar?”, a presente pesquisa tem como problema central a seguinte questão: “como generalizar árvores urbanas discriminadas em nuvens de pontos LiDAR mantendo representatividade espacial compatível com especificações dos módulos *Vegetation* (LoD 2 nas classes SVO e PC) e *PointCloud* do padrão *CityGML 3.0*?”

Para responder a essa pergunta, é adotada como estratégia uma combinação de dois operadores de generalização de mapas adaptados para o domínio 3D, no caso agregação e simplificação (ROBINSON; SALE; MORRISON, 1978), visando reduzir o número de árvores pela formação de unidades visuais por agrupamentos perceptivos que mantenham as características estruturais e o relacionamento espacial originais (KIM; LI, 2019) e compactar a representação das árvores resultantes por meio da diminuição da densidade de pontos da nuvem. Podem assim ser obtidas árvores não-agregadas e simplificadas (compatíveis com objetos da classe SVO) e árvores agregadas simplificadas (compatíveis com objetos da classe PC) representadas em geometria *multipoint* (*PointCloud*).

### 1.3 HIPÓTESE CENTRAL

A definição da estratégia de generalização 3D adotada parte da hipótese central de que o estabelecimento de condições para a agregação de árvores, explorando relações espaciais associadas aos princípios-Gestalt (ARNHEIM, 2011) da proximidade e semelhança (medidas-Gestalt), juntamente com a aplicação de técnicas de compressão da densidade de nuvens de pontos geram um modelo espacial 3D compacto *multipoint* mantendo a coerência espacial de árvores urbanas.

### 1.4 OBJETIVOS

#### 1.4.1 Objetivo geral

A presente pesquisa tem como objetivo geral desenvolver um método para mapear árvores urbanas com base em nuvem de pontos LiDAR aplicando os operadores de generalização (agregação e simplificação) adaptados para o domínio 3D.

#### 1.4.2 Objetivos específicos

Como objetivos específicos, tem-se:


- a) Empregar técnicas de processamento de nuvens de pontos para delimitar automaticamente as árvores de interesse;
- b) Definir condições para agregação das árvores delimitadas, explorando medidas-Gestalt quantificadas com base na localização e nos atributos estruturais (altura, comprimento e área das copas) extraídos;
- c) Analisar o resultado da agregação das árvores a partir de métricas da paisagem calculadas, considerando-se diferentes limiares estabelecidos para as medidas-Gestalt;
- d) Empregar e comparar quantitativamente duas diferentes técnicas de compressão de nuvem de pontos para simplificação 3D das árvores, com base na redução do número de pontos e do armazenamento computacional;
- e) Avaliar a correspondência das árvores generalizadas resultantes em relação à cena 3D original;

f) Analisar a influência da densidade de pontos dos dados LiDAR utilizados e das paisagens urbanas na modelagem realizada.

### 1.5 JUSTIFICATIVA E CONTRIBUIÇÃO DA PESQUISA

Dada a incipiência e pouca abrangência da abordagem teórica e metodológica da generalização 3D para aplicações que envolvem vegetação urbana, a presente pesquisa possui caráter inovador, abordando diferentes questões pertinentes ao seu escopo, resumido na FIGURA 4.

FIGURA 4 – RESUMO DO ESCOPO DA PESQUISA



FONTE: O autor (2022)

Norteados pela construção de modelos 3D compactos de árvores urbanas a partir de dados LiDAR adquiridos em plataformas aéreas, para fins de confecção de inventários que compõem os planos municipais de arborização urbana, o desenvolvimento desta pesquisa segue como padrão de modelagem o *CityGML 3.0*, no qual foi adicionado recentemente o módulo *PointCloud*, sendo utilizada para as árvores generalizadas obtidas a representação geométrica original por nuvens de pontos, sem a necessidade de transformá-las para geometrias sólidas explícitas. Isso complementa o trabalho de Ortega-Cordova (2018) no tocante à utilização de

geometria implícita pra representar objetos da classe PC oriundos de generalização, a qual não foi abordada no referido trabalho.

Ao contemplar os operadores agregação e simplificação de maneira adaptada para o domínio 3D, a presente pesquisa permite a reconceptualização de fundamentos de generalização aplicados para o mapeamento tradicional, complementando algumas abordagens existentes de generalização 3D no contexto de modelagens urbanas, em que se considera como solução alternativa em muitos casos, operadores 2D combinados com a extrusão (HERRERO et al., 2018).

Como contribuições metodológicas associadas à generalização 3D, tem-se as discussões acerca do estabelecimento de condições que exploram a quantificação de medidas-Gestalt extraídas das árvores de interesse a fim de agregá-las e também da utilização de uma adaptação (para o caso de aquisição LiDAR aérea) do algoritmo de aprendizado profundo não-supervisionado proposto por Wiesmann et al. (2021) visando a compressão das nuvens de pontos, em comparação à técnica da partição por *octree*.

A utilização do aprendizado profundo não-supervisionado para a simplificação das árvores resultantes da agregação encontra justificativa em Sester (2020), que menciona o uso de algoritmos *deep learning* como um avanço importante na temática de generalização cartográfica, sendo requeridas estratégias adequadas para a aprendizagem.

Outra potencial contribuição desta pesquisa é a solução mostrada para a tarefa de delimitação automática de árvores urbanas em dados LiDAR, que se mostra desafiadora em face da natureza espacial complexa da vegetação e da heterogeneidade das paisagens urbanas. Considerando a acurácia dos atributos estruturais das árvores um fator relevante para o sucesso da estratégia de generalização adotada, conforme salientado por Feng et al. (2019), técnicas de processamento são empregadas de maneira sequencial, por meio de algoritmos implementados em softwares específicos para nuvens de pontos, a fim de delimitar as árvores de interesse.

A definição dos valores usados para os parâmetros explorados pelos algoritmos busca ser adequada às características das duas áreas de estudo e à densidade de pontos dos dados utilizados. Vale destacar a utilização de informações espectrais (RGB) disponíveis correspondentes aos dados LiDAR, a fim de aumentar a acurácia dos resultados obtidos, já que os algoritmos empregados para essa tarefa

consideram originalmente somente aspectos geométricos (XU e STILLA, 2021). Dessa maneira, o método apresentado para a delimitação das árvores se baseia na extração de atributos geométricos e espectrais, tendo conformidade com a ideia principal do trabalho de Weinmann et al. 2017, que desenvolveram um fluxo de processamento para detectar e segmentar árvores individuais em nuvens de pontos 3D densas de áreas urbanas adquiridas por sistemas de mapeamento móvel. Entretanto, diferentemente do referido trabalho, o método desenvolvido nesta pesquisa não utiliza transformação de nuvens de pontos em dados bidimensionais.

Como os dados utilizados nos experimentos foram adquiridos em diferentes plataformas aéreas e são referentes a dois cenários urbanos distintos (Salvador-BA e Curitiba-PR), pode-se estabelecer um comparativo entre os resultados obtidos, a fim de analisar a influência da caracterização estrutural das duas áreas de estudo e também da amostragem dos dados (densidade de pontos) ao longo de todo o processo de modelagem realizado.

## 1.6 ORGANIZAÇÃO DA TESE

A presente tese está organizada em seis seções.

No Capítulo 2 (Fundamentação Teórica) é apresentado um referencial teórico acerca dos assuntos tratados: - aquisição e processamento de dados LiDAR (filtragem, classificação e segmentação); - generalização 3D (fundamentos, operadores e critérios de avaliação).

No Capítulo 3 (Abordagem Metodológica) são descritos os dados LiDAR utilizados, caracterizadas as duas áreas de estudo e detalhadas todas as etapas metodológicas desenvolvidas, com auxílio de esquemas explicativos.

No Capítulo 4 (Resultados e Discussões) são apresentados, analisados e discutidos os resultados obtidos com os experimentos realizados.

No Capítulo 5 são feitas as considerações finais, onde são apresentadas as conclusões e algumas sugestões e recomendações para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo é dividido em três partes. Na primeira, é explicado o mecanismo de aquisição LiDAR, com destaque para o georreferenciamento direto e a interação laser-vegetação; na segunda, são explicadas as técnicas de processamento de nuvens de pontos empregadas nesta pesquisa (filtragem, classificação e segmentação), sendo utilizados termos próprios de Visão e Aprendizado Computacional; na terceira, são abordados os fundamentos que serviram de base teórica para o desenvolvimento do método de generalização 3D apresentado.

### 2.1 AQUISIÇÃO DE DADOS LIDAR

A tecnologia LiDAR é caracterizada por um tipo de imageamento ativo tridimensional (3D) cujo funcionamento ocorre pela integração de um sistema de varredura óptico-mecânico (FIGURA 5), que emite pulsos laser na faixa espectral do infravermelho próximo (comprimento de onda aproximadamente entre 780 e 1250 nm) em direção aos alvos e capta automaticamente grandes quantidades de dados (ecos ou sinais de retorno) em curto intervalo de tempo, com um mecanismo de georreferenciamento direto constituído por um sistema de navegação inercial (*inertial navigation system* – INS) e um de posicionamento por satélite (*global navigation satellite system* – GNSS).

FIGURA 5 - SISTEMA ÓPTICO-MECÂNICO DE VARREDURA LASER



FONTE: O autor (2022)

Descrito por Wehr e Lohr (1999), Shan e Toth (2009), o sistema de varredura laser possui como componentes principais um gerador de pulsos, um conjunto óptico

de emissão e recepção, um detector de sinais com medidor de tempo e uma unidade de controle e armazenamento. Após a geração de um pulso laser, o conjunto óptico de lentes e espelhos orienta o pulso emitindo-o em direção à superfície física. Ao atingi-la, o pulso interage com o objeto perfilado e retorna ao sensor. O sinal de retorno (eco) passa novamente por um conjunto óptico sendo direcionado à parte eletrônica de recepção do sensor que transforma, por meio de um conversor, o sinal analógico recebido em digital. Por fim, o sinal digital da radiação refletida passa por um controlador de ruído que verifica se o sinal recebido é compatível com o sinal emitido.


Para cada eco recebido, é medido o *range* (alcance)  $\rho$ , que é a distância entre a unidade laser e um ponto terrestre imageado, calculada pelo método ToF (*Time-of-Flight*) representado na equação (1):

$$\rho = \frac{c\tau}{2} \quad (1)$$

onde:  $c$  é a velocidade da luz no ar ( $c = 3 \times 10^8$  m/s) e  $\tau$  é o tempo de transmissão e recepção do pulso laser.

A partir dos valores de  $\rho$  medidos são obtidas, pelo mecanismo de georreferenciamento direto ilustrado na FIGURA 6, as coordenadas planialtimétricas ( $X, Y, Z$ ) de cada ponto LiDAR ( $P_{oi}$ ).

FIGURA 6 - MECANISMO DE GEORREFERENCIAMENTO DIRETO PARA DADOS LIDAR



FONTE: O autor (2022)

Conforme observado, o georreferenciamento direto em relação a um determinado referencial terrestre é obtido por uma soma vetorial de três parcelas em que devem ser aplicadas rotações necessárias ( $R_I, R_b, R_v$ ) para compatibilização dos sistemas de varredura e o inercial. A equação (2), adaptada de Shan e Toth (2009), mostra o cálculo das coordenadas terrestres ( $X, Y, Z$ ) para cada ponto ( $P_{O_i}$ ).

$$\vec{P}_O(t) = \vec{P}_I(t) + R_I(t)\vec{L} + R_I(t)R_bR_v(t)\vec{D}(t) \quad (2)$$

onde:

$\vec{P}_O(t)$  é o vetor resultante ( $X_O, Y_O, Z_O$ ) do georreferenciamento direto para um ponto LiDAR no referencial terrestre;

$\vec{P}_I(t)$  é o vetor-posição da origem do sistema inercial ( $X_I, Y_I, Z_I$ ) no referencial terrestre;

$R_I(t)$  é matriz de rotação que relaciona o sistema inercial ( $X_I, Y_I, Z_I$ ) ao sistema de coordenadas terrestres, obtida pelo produto matricial  $R_\omega R_\varphi R_\kappa$ , que representa rotações em torno dos eixos X, Y e Z, respectivamente;

$\vec{L}$  é o deslocamento linear ( $\Delta X, \Delta Y, \Delta Z$ ) entre a origem do sistema inercial ( $X_I, Y_I, Z_I$ ) e a origem do sistema de coordenadas do dispositivo de varredura laser ( $X_L, Y_L, Z_L$ ), denominado de *lever-arm offset*;

$R_b$  é a matriz que representa o desalinhamento angular entre o sistema inercial e o sistema de coordenadas do dispositivo de varredura laser, chamado de *bore-sight*, e representado pelos ângulos ( $\Delta\omega, \Delta\varphi, \Delta\kappa$ );

$R_v(t)$  é a matriz de rotação que aplica os ângulos (azimute  $\alpha$  e elevação  $\theta$ ) do espelho oscilante na medida de distância do dispositivo de varredura, sendo obtida pelo produto matricial  $R_\alpha R_\theta$ ;

$\vec{D}(t)$  é distância entre o alvo e a origem do dispositivo de varredura, representada pelo

vetor-coluna  $\begin{bmatrix} 0 \\ 0 \\ -\rho \end{bmatrix}$ .


Ressalta-se que dos elementos relacionados no georreferenciamento direto, somente os parâmetros de montagem (*bore-sight* e *lever-arm*) não são variáveis em função do tempo  $t$ , sendo mensurados na calibração do sistema.

Além do georreferenciamento direto 3D, outra vantagem da tecnologia LiDAR para estudos de vegetação é a penetrabilidade dos pulsos laser em alvos vegetais

devida ao fato destes não possuírem superfície contínuas como telhados e arruamentos, o que pode auxiliar a tarefa de discriminação de vegetação urbana em relação a outros elementos.

Essa propriedade favorece a ocorrência de múltiplas reflexões provocadas pelos diferentes componentes vegetais de profundidades variáveis (ramos, galhos, e folhagens), sendo medidos mais de um eco (sinal de retorno) para um mesmo alvo (D'OLIVEIRA et al., 2014). O primeiro é correspondente à cobertura e os pulsos seguintes correspondentes aos elementos sub-copa, conforme mostra a FIGURA 7.

FIGURA 7 - PENETRABILIDADE DE PULSOS LASER NA VEGETAÇÃO



FONTE: O autor (2022)

Segundo Renslow (2012), a penetrabilidade dos pulsos laser emitidos por sistema LiDAR aéreos possibilita a reconstrução tridimensional de estruturas vegetais, cujas alturas podem ser estimadas pela separação do primeiro e último ecos.

Como resultado de uma varredura laser, é gerada uma representação espacial 3D irregular, cuja densidade de pontos é função da frequência de perfilamento, da altura e da velocidade de aquisição, da largura e da sobreposição de faixas imageadas. A densidade de nuvens de pontos LiDAR geradas em plataformas aerotransportadas geralmente varia entre 0,4 e 30 pontos por  $m^2$ , enquanto as aquisições LiDAR UAV podem atingir 100-1000 pontos por  $m^2$  (D'OLIVEIRA et al., 2020).

Os dados obtidos em uma aquisição LiDAR podem ser exportados em diferentes formatos, sendo o .LAS (*LIDAR Data Exchange Format*) o mais usual,

segundo convenção internacional da ASPRS (*American Society for Photogrammetry and Remote Sensing*). Esse formato consiste em um tipo de arquivo binário e público para armazenamento e troca de informações entre usuários de dados 3D, existindo cinco versões (ASPRS, 2021): LAS 1.0, LAS 1.1, LAS 1.2, LAS 1.3, LAS 1.4. Embora haja diferenças entre essas versões no tocante à capacidade, forma e tipo de armazenamento, um arquivo .LAS contém basicamente para cada ponto registrado na varredura laser, além das coordenadas planialtimétricas referenciadas a um datum: a intensidade e o número de ecos; o valor do ângulo de incidência; o tempo GPS; os valores RGB (quando houver câmera óptica na aquisição).

A intensidade dos sinais de retorno é, segundo Kashani et al. (2015), influenciada diretamente pelos seguintes fatores: característica dos alvos imageados; geometria de aquisição; efeitos atmosféricos; parâmetros do sistema de varredura laser. Para trabalhos que usam a informação da intensidade dos ecos, tais autores recomendam uma calibração radiométrica preliminar. No caso desta pesquisa, como não se dispôs de informações necessárias a essa tarefa, a intensidade dos ecos não foi considerada nos experimentos realizados, nem as informações do tempo GPS e dos ângulos de incidência.

## 2.2 TÉCNICAS DE PROCESSAMENTO DE NUVENS DE PONTOS

Apesar de suas vantagens, os dados LiDAR apresentam algumas limitações operacionais devidas à existência de ruídos inerentes ao processo de aquisição e de descontinuidades geométricas devidas às oclusões e à ausência de conectividade entre os pontos registrados, que dificulta a sua interpretação pela ausência de aspectos topológicos e semânticos (DÖLLNER, 2020).


Devido a essas limitações, o mapeamento de arborização urbana a partir de nuvens de pontos LiDAR requer um prévio processamento de dados visando sua semantização e posterior segmentação, sendo empregadas técnicas como filtragem, classificação (segmentação semântica) e segmentação por instância.

### 2.2.1 Filtragem

Haja vista a ocorrência de alguns erros na aquisição LiDAR devidos a fatores intrínsecos (inerentes ao próprio sistema laser) e extrínsecos (presença de obstáculos

e multicaminhamento de sinais), é comum a presença de pontos espúrios (*outliers*) que causam ruídos nas nuvens de pontos geradas (CARRILHO; GALO, 2017). A FIGURA 8 exemplifica pontos espúrios identificados em uma nuvem de pontos que representa uma copa de árvore.

FIGURA 8 - PONTOS ESPÚRIOS IDENTIFICADOS EM UMA NUVEM DE PONTOS



FONTE: O autor (2022)


Esses pontos discrepantes são esparsos e podem ser erroneamente estimados nas etapas de processamento. Por essa razão, a remoção desse tipo de ruído é essencial no fluxo de processamento.

Existem na literatura várias abordagens para remoção dos pontos espúrios, algumas pressupondo modelos matemáticos paramétricos e outras baseadas em algoritmos não-paramétricos. Carrilho, Galo e dos Santos (2018) fazem uma revisão acerca dessas abordagens, ressaltando as limitações existentes.

Nesta pesquisa, optou-se pelo filtro denominado *Statistical Outlier Removal* (SOR), que analisa estatisticamente o comportamento de pontos numa determinada vizinhança (RUSU e COUSINS, 2011). A descrição do referido algoritmo está no capítulo 3 desta tese (ver seção 3.4.1.1).

Uma tarefa comum em processamento de nuvens de pontos quando se deseja extrair informações de feições urbanas é a eliminação dos pontos de terreno, a fim de reduzir significativamente o volume e o tempo de processamento e também evitar erros na delimitação dos objetos de interesse. Na FIGURA 9 é mostrado o resultado da eliminação de pontos de terreno em uma nuvem de pontos LiDAR.

FIGURA 9 - ELIMINAÇÃO DE PONTOS DE TERRENO: (A) NUVEM DE PONTOS LIDAR ORIGINAL; (B) PONTOS DE TERRENO ELIMINADOS; (C) NUVEM DE PONTOS LIDAR FILTRADA SEM PONTOS DE TERRENO



FONTE: O autor (2022)


Para a eliminação dos pontos de terreno nesta pesquisa, 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 (ZHANG et al., 2016). A descrição do referido algoritmo está no capítulo 3 desta tese (ver seção 3.4.1.2).

### 2.2.2 Classificação (segmentação semântica)

A técnica de classificação de uma nuvem de pontos 3D objetiva associar um rótulo semântico específico para cada um de seus pontos, sendo uma tarefa essencial para a sua semantização, que é considerada sinônimo do termo segmentação semântica (XIE et al., 2020), amplamente empregado na Visão Computacional e significa a partição da nuvem em estruturas com conteúdo semântico relevante para uma determinada finalidade (PEDRINI e SCHARTZ, 2008), facilitando a extração das informações desejadas.

Na FIGURA 10, é mostrado um exemplo de semantização de nuvem de pontos em que se destaca a existência de três classes (vegetação, terreno e edificação).

FIGURA 10 - SEMANTIZAÇÃO DE NUVEM DE PONTOS



FONTE: O autor (2022)

A automatização da classificação de nuvens de pontos ocorre com base no reconhecimento de padrões extraídos dos dados utilizados, de maneira supervisionada, onde amostras externas previamente rotuladas são usadas como padrão de referência, ou de maneira não-supervisionada, em que os algoritmos procuram padrões internos repetidos nos dados segundo algum critério definido, sem amostras de referência.


Os padrões extraídos são representados por vetores de atributos ou características contendo descritores locais que quantificam relações contextuais geométricas ou estatísticas de cada ponto com os seus vizinhos, tais como entropia intrínseca, anisotropia, planaridade, linearidade, curvatura e esfericidade. Esses descritores são estimados com base nos autovalores  $(\lambda_1, \lambda_2, \lambda_3)$  das matrizes de covariância 3D obtidas nas vizinhanças locais dos pontos (PAULY et al., 2003; WEST et al., 2004; WEINMANN et al., 2013). A necessidade do cômputo das vizinhanças locais dos pontos para a estimação desses atributos descritores se deve à falta de conectividade original entre os pontos (WEINMANN et al., 2015).

Matematicamente, a classificação de uma nuvem de pontos 3D pode ser tratada como uma função  $(L_k)_i = f(A_i(X_i))$ , onde  $X = \{X_1, X_2, X_3, \dots, X_i\}$  é a nuvem de pontos 3D contendo  $i$  elementos,  $f$  é o algoritmo utilizado,  $(L_k)_i$  é um rótulo de classe

$L_k$  para um ponto  $i$  e  $A_i(X_i)$  é o vetor de  $n$ -atributos ou características  $A_i = (a_{1_i}, a_{2_i}, \dots, a_{n_i})$  de um ponto  $i$ .

Nesta pesquisa, o software utilizado para a classificação realizada considerou somente duas classes de rotulação  $L_k$  (edificações e vegetação) para os pontos não-terreno, tendo sido estimados os vetores de atributos ou características  $A_i = (a_{1_i}, a_{2_i})$  com base nos descritores planaridade ( $a_1$ ) e espalhamento volumétrico ( $a_2$ ), conforme mostra a FIGURA 11.

FIGURA 11 - FUNÇÃO DE CLASSIFICAÇÃO REALIZADA NA PESQUISA



FONTE: O autor (2022)

Descritos em Weinmann et al. (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 identificação 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 identificação de copas de árvores.

A estimação dos atributos  $a_1$  e  $a_2$  para cada um dos pontos  $X_i$  segue as equações (3) e (4):

$$a_1 = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (3)$$


$$a_2 = \frac{\lambda_3}{\lambda_1} \quad (4)$$

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

Os procedimentos para as classificações realizadas na pesquisa são detalhados no capítulo 3 desta tese (ver seção 3.4.2.1).

Devido à possibilidade de existência de erros significativos na rotulação dos pontos, Kada e Kuramin (2021) alertam para a necessidade de refinar os resultados obtidos em classificações de nuvens de pontos LiDAR, podendo ser feito manualmente, de maneira semiautomática ou pelo uso de algoritmos de aprendizado de máquina supervisionados. Na FIGURA 12 são exemplificados, com base em uma comparação visual entre o resultado de uma classificação de nuvem de pontos genérica e sua correspondente imagem óptica, quatro falsos positivos para pontos rotulados como vegetação.

FIGURA 12 - IDENTIFICAÇÃO DE FALSOS POSITIVOS PARA VEGETAÇÃO CLASSIFICADA



FONTE: O autor (2022)

O refinamento das classificações realizadas na presente pesquisa bem como a avaliação da acurácia dos resultados obtidos são detalhados nos capítulos 3 (ver seção 3.4.2.2) e 4 desta tese. Ressalta-se que para a avaliação das classificações foram geradas matrizes de erro ou confusão que quantificam a relação entre os pontos rotulados e uma determinada referência utilizada (FIGURA 13).

FIGURA 13 - MATRIZ DE CONFUSÃO (RESULTADO X REFERÊNCIA)

|               |                      | Referência               |                          |
|---------------|----------------------|--------------------------|--------------------------|
|               |                      | <u>Vegetação</u>         | <u>Não-Vegetação</u>     |
| Classificação | <u>Vegetação</u>     | Verdadeiro Positivo (VP) | Falso Positivo (FP)      |
|               | <u>Não-Vegetação</u> | Falso Negativo (FN)      | Verdadeiro Negativo (VN) |

FONTE: O autor (2022)

Com base nas matrizes de confusão geradas, foram calculadas a exatidão ou acurácia global (taxa de acerto), os erros de inclusão e omissão, e as exatidões do produtor e do usuário. Fundamentada no trabalho de Silva (2009), a descrição dessas medidas está a seguir:

- taxa de acerto (exatidão global): razão entre os pontos rotulados corretamente (vegetação e não-vegetação) e o número total de pontos rotulados, equivale ao percentual do total de acertos em relação ao total de pontos rotulados, representada pela divisão da soma dos elementos da diagonal principal pela soma de todos os elementos da matriz de confusão, conforme a equação (5).

$$\text{Taxa de acerto} = \frac{VP+VN}{VP+VN+FN+FP} \quad (5)$$

- exatidão do usuário: razão entre os achados positivos rotulados corretamente (verdadeiros positivos de vegetação) e o total de achados positivos (quantidade de pontos rotulados como vegetação), conforme a equação (6).

$$\text{Exatidão do usuário} = \frac{VP}{VP+FP} \quad (6)$$

- exatidão do produtor: razão entre os achados positivos rotulados corretamente (verdadeiros positivos) e o total de pontos verdadeiramente de vegetação (verdadeiros positivos e falsos negativos), conforme a equação (7).

$$\text{Exatidão do produtor} = \frac{VP}{VP+FN} \quad (7)$$

- erro de inclusão ou comissão: razão entre os pontos rotulados erroneamente (falsos positivos) e o número total de pontos rotulados em determinada classe (verdadeiros e falsos positivos), conforme a equação (8).

$$\text{Erro de inclusão: } \frac{FP}{VP+FP} \quad (8)$$

- erro de omissão: razão entre os pontos que deixaram de ser rotulados (falsos negativos) e o número total de pontos existentes em determinada classe (verdadeiros positivos e falsos negativos), conforme a equação (9).


$$\text{Erro de omissão: } \frac{FN}{VP+FN} \quad (9)$$

### 2.2.3 Segmentação por instância (delimitação de árvores)

Após a semantização de uma nuvem de pontos, pode-se, por meio de uma segmentação precisa de árvores individuais, construir um banco de dados contendo para cada árvore detectada e delimitada atributos como posição, altura, diâmetro de copa, volume e biomassa. Esses atributos são obtidos diretamente a partir dos conjuntos de pontos contidos em cada árvore segmentada, considerando a geometria *multipoint*.

A cada árvore delimitada é associado também um ID (identificador) que auxilia a criação do banco de dados. Na FIGURA 14, árvores segmentadas são visualizadas em diferentes cores de acordo com seus ID's.

FIGURA 14 - ÁRVORES SEGMENTADAS (VARIAÇÃO DE CORES DE ACORDO COM OS ID'S)



FONTE: Roussel et al. (2020)

A detecção individual de uma árvore (*individual tree detection* - ITD) é o processo de determinar sua localização espacial e sua altura, enquanto sua delimitação permite o delineamento de suas características dendrológicas. Tem-se assim a detecção dos topos das árvores como a etapa mais importante na tarefa de segmentação, pois afeta significativamente as medidas resultantes.

Segundo Xiao et al. (2019), são encontrados na literatura diferentes métodos implementados para a detecção e segmentação de árvores individuais em dados LiDAR adquiridos por plataformas aéreas, sendo adotados critérios baseados em limiares de altura, e também em relações de vizinhança entre os pontos definidos em uma janela de busca.

No caso da detecção de árvores individuais, é expressivo o uso de filtros de máximos locais para localização dos topos de objetos vegetais (pontos de maior altura) principalmente em povoamentos florestais (POPESCU, 2002; POPESCU e WYNNE, 2004; SILVA et al., 2013; MLENEK, 2020), podendo ser aplicados diretamente em nuvens de pontos LiDAR ou em modelos de dossel digital (CHM – *canopy height model*), que são imagens raster interpoladas a partir de nuvens de pontos e que representam o topo da copa da vegetação.

O número de árvores detectadas por essa filtragem é correlacionado ao tamanho de janela de vizinhança, que pode ser fixo (maior automatização) ou variável em função da altura das árvores, possuindo formato circular ou quadrado. Tamanhos menores de janela detectam maiores quantidades de árvores de menor porte e mais próximas entre si, enquanto janelas de maiores tamanhos detectam árvores de maior porte e mais espaçadas entre si. Porém, janelas grandes podem omitir árvores

menores que estejam envolvidas por árvores mais altas, que têm copas comparativamente maiores.


Devido à dificuldade de determinar o tamanho da janela mais adequado para filtragem de máximos locais em cenários heterogêneos (POPESCU e WYNNE, 2004; CHEN et al., 2006), onde existem árvores de estruturas complexas e de tamanhos variáveis, e dada a vantagem de aplicar algoritmos de segmentação diretamente em nuvens de pontos LiDAR, evitando erros de interpolação na geração dos CHM que poderiam diminuir a confiabilidade das segmentações de árvores e das medidas obtidas (GUO et al., 2010), foi empregada nesta pesquisa uma adaptação (para o caso urbano) do método proposto por Li et al. (2012).

Tal método detecta e segmenta árvores diretamente em nuvens de pontos, empregando o crescimento de regiões a partir de pontos de máximos globais identificados (pontos-semente), com base em regras de espaçamento horizontal (distâncias projetadas no solo) entre os ápices e entre as bases esperadas das árvores, sendo estabelecidos limites mínimos e máximos de distância para o agrupamento dos pontos.

Encontrando o ponto de maior altura da nuvem em questão ( $U$ ), que é o primeiro máximo global identificado ( $m_1$ ), o algoritmo segmenta a árvore mais alta correspondente ( $U_1$ ) contendo somente os pontos cujos espaçamentos ( $E$ ) estejam dentro de um limite previamente definido ( $dt$ ). A árvore mais alta segmentada é então separada do restante da nuvem de pontos, sendo obtida a primeira nuvem resultante  $L_1$ , equivalente à diferença ( $U - U_1$ ), que contém todos os pontos de  $U$  que foram excluídos de  $U_1$  por possuírem espaçamento maior que o limite definido.

O processo de busca do ponto mais alto de  $L_1$  ( $m_2$ ) reinicia (SANTOS, 2018), sendo este considerado o topo da segunda árvore mais alta ( $U_2$ ), e assim sucessivamente. Dessa maneira, as árvores são segmentadas individualmente e sequencialmente, do ponto mais alto ao ponto mais baixo da nuvem e também do centro para as bordas, conforme mostra a FIGURA 15.

FIGURA 15 - VISÃO GERAL DA SEGMENTAÇÃO DE ÁRVORES PELO ALGORITMO DE LI ET AL. (2012)



FONTE: O autor (2022)

As iterações  $i$  são finalizadas quando toda a nuvem de pontos  $U$  estiver segmentada, ou seja, todos os pontos forem associados às suas árvores correspondentes e a nuvem resultante  $L_i$  estiver vazia, conforme as equações (10) e (11) respectivamente:

$$U = \{U_1, U_2, U_3, \dots, U_i\} \quad (10)$$

$$L_i = \emptyset \quad (11)$$

onde o conjunto  $\{U_1, U_2, U_3, \dots, U_i\}$  representa as nuvens de pontos correspondentes a cada uma das  $i$ -árvores segmentadas.

Assim como ocorre na detecção individual, os resultados obtidos na segmentação pelo algoritmo de Li et al. (2012) são sensíveis à escolha dos limiares de espaçamento. Valores fixos mais altos podem resultar em subsegmentações, enquanto limites menores propiciam segmentações excessivas. Isso pode ser reduzido por limites adaptativos, assumindo que árvores mais altas têm diâmetros de copa maiores (POPESCU e WYNNE, 2004; CHEN et al., 2006) e portanto, exigem maior espaçamento para individualização de seu nível superior.

Devido a essas incertezas, os algoritmos não são adequados para todos os contextos, devendo ser adaptados para o cenário estudado. Os limites de espaçamento a serem definidos devem considerar valores de raio das copas das

árvores, materializando regiões nas quais pontos satisfazem condições estabelecidas ao longo do processo de segmentação. Em regiões onde árvores são esparsas, como ocorre em muitas paisagens urbanas, pode-se definir limites maiores para isolar árvores.

A descrição da segmentação realizada na presente pesquisa está no capítulo 3 (ver seção 3.4.2.3) desta tese.

## 2.3 GENERALIZAÇÃO 3D


Nesta seção são abordados os fundamentos de generalização 3D que serviram de base teórica para o desenvolvimento do método apresentado na presente pesquisa.

### 2.3.1 Aspectos gerais

Enquanto no domínio de mapeamento tradicional os métodos de generalização visam ajustar ou adaptar a representação de feições selecionadas de um produto cartográfico em função da mudança de escala, dos requisitos da comunicação cartográfica, do usuário e dos objetivos deste produto (ROBINSON et al., 1995; SLOCUM et al., 2009; KRAAK; ORMELING, 2010), no caso tridimensional os métodos empregados objetivam reduzir, por meio de transformações espaciais e de atributos (MCMASTER; SHEA, 1992) chamadas de operadores de generalização, os LoD geométrico e semântico dos objetos representados preservando a coerência espacial original (SCHMIDT, 2012) e garantindo suficiente realismo funcional (OVIEDO, 2014).

A FIGURA 16 mostra um modelo 3D compacto, onde os objetos urbanos representados possuem níveis de detalhes que garantem um realismo suficiente para a obtenção das informações de interesse.

FIGURA 16 - MODELO DE REPRESENTAÇÃO 3D COMPACTO



FONTE: ORTEGA-CORDOVA (2018)

Embora a redução dos LoD cause a diminuição do volume operacional dos dados utilizados, as análises espaciais requeridas podem se tornar limitadas para uma determinada finalidade. Segundo Biljecki (2017), objetos em LoD maiores permitem análises mais confiáveis, uma vez que apresentam maior aderência de extensão espacial à realidade representada e consequentemente maior riqueza de informações.


Percebe-se assim uma interdependência entre os LoD dos objetos e os requisitos/escalas de uso do modelo 3D gerado. Contudo, Biljecki (2017) ressalta que a quantificação de um LoD é subjetiva, ao contrário de outras noções elementares como escala cartográfica e resolução espacial.

Além do propósito de uso (BILJECKI, 2017), os critérios para a redução do LoD de um objeto devem levar em consideração também a sua natureza espacial, pois há variação de padrão geométrico e de relacionamentos expostos entre diferentes classes de objetos (LEE et al., 2017; SESTER et al., 2018).

Entende-se assim a generalização 3D como um processo subjetivo de derivação de dados em que, mediante o estabelecimento de condições de realização, diferentes abstrações da realidade (ROBINSON et al., 1995) e suas respectivas representações podem ser feitas a partir de um mesmo conjunto de dados, tal como ocorre na generalização de mapas.

A FIGURA 17 ilustra, para o caso de uma nuvem de pontos  $A$ , a subjetividade da generalização 3D, a partir da qual podem ser derivadas  $k$  nuvens de pontos ( $A_k$ ), cada uma representada em um nível de detalhamento (LoD- $k$ ) correspondente ao grau de generalização atingido (GLANDER; DÖLLNER, 2008).

FIGURA 17 – GENERALIZAÇÃO 3D COMO UM PROCESSO SUBJETIVO DE DERIVAÇÃO DE DADOS



FONTE: O autor (2022)

Em face dessa subjetividade, e devido à evolução das tecnologias geoespaciais, não há consenso sobre operadores e algoritmos adequados, requisitos a serem atendidos e LoD a serem atingidos para todos os casos (SESTER et al. 2018). Segundo Mackaness et al. (2011), a maioria das pesquisas sobre a temática de generalização assume que o processo pode ser dividido em uma série de operadores, que juntos devem manter similaridades espaciais e estatísticas entre o conjunto original de dados e o generalizado.


A seguir, são explicadas as transformações espaciais associadas aos dois operadores de generalização empregados nesta pesquisa.

### 2.3.2 Operadores de generalização

#### 2.3.2.1 Agregação

Robinson, Sale, Morrison (1978) e McMaster e Shea (1992) definem a agregação como uma operação cartográfica que emprega uma transformação espacial na qual objetos de mesma entidade de classe são agregados gerando um novo objeto mesclado ou fusionado (*merge*), composto pelos objetos originais, mas geometricamente mais simples. Sua aplicação permite minimizar a distribuição representativa dos objetos mas mantendo suas estruturas espaciais originais, como mostra a FIGURA 18.


FIGURA 18 – OPERAÇÃO DE AGREGAÇÃO



FONTE: O autor (2022)

A aplicação desse operador adaptado ao domínio 3D nesta pesquisa objetiva agrupar indivíduos de árvores (objetos do tipo SVO) para formar conjuntos representados por entidades únicas (objetos tipo PC), como visualizado na FIGURA 19.

FIGURA 19 - AGREGAÇÃO DE DUAS ÁRVORES INDIVIDUAIS (A, B)



FONTE: O autor (2022)

Pela operação de agregação, as duas árvores A e B são fusionadas para compor a árvore AB, cujas dimensões são dadas em função das dimensões das árvores A e B, mediante algumas regras definidas. Percebe-se assim um tipo de “reclassificação” das árvores originais como árvore mesclada.

Para a agregação, podem ser estabelecidas condições com base em leis gestaltianas ou princípios-Gestalt (ARNHEIM, 2011) da proximidade e semelhança para formar os agrupamentos perceptivos, e dessa maneira diminuir a densidade espacial de objetos, de uma maneira adaptada do trabalho de Wang et al. (2015), que generalizou edifícios pela técnica do corte em grafos (*graphcut*), explorando a conexão entre objetos adjacentes que fossem similares em tamanho e em regularidade, a fim de gerar objetos resultantes mesclados.

Dent et al. (2009) analisaram os princípios-Gestalt associados ao agrupamento perceptivo, ressaltando que a simples proximidade (FIGURA 20a) não é suficiente para explicar o agrupamento de elementos, sendo necessário também empregar o agrupamento por semelhança em forma e tamanho (FIGURA 20b).

FIGURA 20 - PRINCÍPIOS GESTALT: (A) PROXIMIDADE; (B) SEMELHANÇA




FONTE: Adaptada de DENT (2009)

Pelo princípio da semelhança, objetos no campo visual que possuem formas e tamanhos semelhantes são combinados em um sub-grupo que parece ser distinto do restante dos objetos. No caso do tamanho dos objetos, a dimensão percebida é influenciada pelos elementos vizinhos. Sendo assim, a dimensão é um atributo geométrico que auxilia no processo de discriminação dos objetos.

Já pelo princípio da proximidade, elementos no campo visual que estão mais próximos entre si, tendem a ser vistos como uma unidade que se destaca do restante. Nesse sentido, quanto menor a distância entre os objetos, maior a tendência de unicidade.

Na método de generalização 3D desenvolvido na presente pesquisa, explora-se a conexão entre as árvores adjacentes e similares, a fim de gerar árvores mescladas que sejam próximas-similares. Na FIGURA 21, as árvores A e B são próximas-similares, enquanto C e D são próximas sem similaridade.

FIGURA 21 - EXEMPLOS DE ÁRVORES PRÓXIMAS E PRÓXIMAS-SIMILARES



FONTE: O autor (2022)


### 2.3.2.2 Simplificação

Segundo Regnauld e McMaster (2007), a simplificação é o operador de generalização de mapas mais comumente usado. Seu objetivo é eliminar detalhes de uma feição mas mantendo o máximo possível de sua forma, reduzindo assim a sua complexidade (ROBINSON; SALE; MORRISON, 1978; McMASTER, SHEA (1992).

Originalmente projetado para feições lineares (FIGURA 22), o operador simplificação elimina o número máximo de coordenadas consideradas descartáveis para um determinado propósito.

FIGURA 22 - OPERADOR SIMPLIFICAÇÃO

(A, B, C, D, E, F, G, H, I, J, K, L)  $\Rightarrow$  (A, F, I, L)



FONTE: O autor (2022)

A maioria das rotinas de simplificação utiliza critérios geométricos (distância e medidas angulares) na seleção de pontos significativos ou críticos, considerando para a linha a ser simplificada: as posições absolutas de cada um dos pontos (independente da vizinhança), as vizinhanças locais restritas e irrestritas, ou todos os pontos de maneira global (holística).

Nesta pesquisa, a simplificação 3D empregada visa a eliminação de pontos na nuvem para diminuir o custo de armazenamento dos dados. Objetiva-se a redução do número de coordenadas armazenadas computacionalmente para as árvores mas preservando a sua geometria, como se observa na FIGURA 23.

FIGURA 23 – SIMPLIFICAÇÃO 3D DE ÁRVORE INDIVIDUAL: (A) REPRESENTAÇÃO ORIGINAL; (B) REPRESENTAÇÃO SIMPLIFICADA.



FONTE: O autor (2022)

Para tal, são empregados dois tipos de compressão de nuvens de pontos: partição espacial por *octree* e aprendizado profundo não-supervisionado (*autoencoder*). A *octree* é uma árvore computacional hierárquica que permite a estruturação de nuvens de pontos 3D para operações de particionamento espacial de dados (PCL, 2021), podendo armazenar coordenadas espaciais tridimensionais de forma eficiente (HORNUNG et al. 2013). A compressão por aprendizado computacional não-supervisionado realizada nesta pesquisa é baseada no trabalho de Wiesmann et al. (2021), onde é empregada uma rede neural convolucional (*convolutional neural network* – CNN) do tipo *autoencoder* visando obter, a partir da análise de similaridades locais dos pontos de uma nuvem 3D uma derivação simplificada preservando suas características geométricas.

Ambas as técnicas empregadas são apresentadas no capítulo 3 desta tese (ver seção 3.4.3.2).

### 2.3.3 Critérios de avaliação

Mackaness e Ruas (2007) discutem a natureza das avaliações de soluções automatizadas para generalização de mapas, destacando desafios para a definição de critérios e metodologias de avaliação, que objetivam examinar a conformidade da solução cartográfica encontrada em relação às necessidades do usuário/propósito de uso, considerando diversos aspectos tais como cartometria, design, robustez do algoritmo, reprodutibilidade, etc.

Adaptando essa importante questão para o caso da presente pesquisa, a avaliação do método de generalização 3D desenvolvido leva em consideração aspectos computacionais, variação de métricas da paisagem calculadas para as árvores generalizadas e a correspondência delas com a cena 3D original.

Os aspectos computacionais analisados são associados ao espaço de armazenamento, para o qual é esperada uma diminuição após a generalização 3D, devida à redução do volume dos dados. Tal diminuição é calculada por meio de percentuais de redução do número de pontos (RNP) e do espaço de armazenamento computacional (REA), como mostram as equações (12) e (13):

$$RNP = 100x \left( 1 - \frac{NPG}{NPO} \right) \% \quad (12)$$

$$REA = 100x \left( 1 - \frac{EAG}{EAO} \right) \% \quad (13)$$

onde:

*NPG* é o número de pontos da nuvem contendo as árvores generalizadas;

*NPO* é o número de pontos da nuvem contendo as árvores antes da generalização 3D;

*EAG* é o espaço de armazenamento computacional da nuvem contendo as árvores generalizadas;

*EAO* é o espaço de armazenamento computacional da nuvem contendo as árvores antes da generalização 3D.

As métricas da paisagem podem ser usadas para quantificar a estrutura das áreas urbanas (LIU; YANG, 2015), em termos de localização, distribuição, tamanho, forma e arranjo, permitindo assim fazer inferências acerca de mudanças ocorridas em épocas distintas para um mesmo cenário. No caso da presente pesquisa, tais métricas são usadas para avaliar o resultado obtido pela operação de agregação 3D, comparando-se a fragmentação e a dispersão dos conjuntos de árvores resultantes da agregação em relação às árvores delimitadas originais.

Definidas em Ponte et al. (2017), as métricas de fragmentação e de dispersão representam respectivamente o grau de segmentação do conjunto de árvores existentes (considerando a quantidade de árvores na área estudada e a área total da superfície de suas copas) e o grau de afastamento interno médio entre elas, sendo formuladas de acordo com as equações (14) e (15):

$$GF = \frac{AD}{\sum Sapr_i} \quad (14)$$

$$GD = \frac{\sum d_{V_i, V_j}}{\sum (V_i, V_j)} \quad (15)$$

onde:

$GF$  é o grau de fragmentação do conjunto de árvores, medido em árvores/metro quadrado de área verde;

$GD$  é o grau de dispersão das árvores, medido em metros;

$AD$  é o número de árvores delimitadas na área de estudo;

$\sum Sapr_i$  é a área total de superfície aproximada das copas das árvores existentes (ver seção 3.4.3.1.1);

$\sum d_{V_i, V_j}$  é a somatória de todas as distâncias horizontais entre árvores  $(V_i, V_j)$  adjacentes (ver seção 3.4.3.1.1);

$\sum (V_i, V_j)$  é o número total de pares de árvores adjacentes existentes.

A partir das métricas  $GF$  e  $GD$  calculadas antes e depois da agregação 3D, pode-se analisar a variação desses índices com base em percentuais dados pelas equações (16) e (17), sendo esperados uma redução de fragmentação (RF) devida à formação de agrupamentos de árvores e também um aumento da dispersão das

árvores (ADA), pois os menores afastamentos internos são suprimidos na operação de agregação:

$$RF = 100x \left( 1 - \frac{GF_g}{GF_o} \right) \% \quad (16)$$

$$ADA = 100x \left( \frac{GD_g}{GD_o} - 1 \right) \% \quad (17)$$

onde:

$GF_g$  é o grau de fragmentação do conjunto de árvores resultantes da agregação 3D;

$GF_o$  é o grau de fragmentação do conjunto de árvores antes da agregação 3D;

$GD_g$  é o grau de dispersão do conjunto de árvores resultantes da agregação 3D;

$GD_o$  é o grau de dispersão do conjunto de árvores antes da agregação 3D;

$RF$  é o percentual de redução do grau de fragmentação obtido após a agregação 3D;

$ADA$  é o percentual de aumento do grau de dispersão obtido após a agregação 3D.

No tocante à correspondência com a cena 3D original, pode ser calculado para cada árvore generalizada ( $V_{ig}$ ) as seguintes medidas em relação à árvore original ( $V_{io}$ ): deslocamento horizontal do centroide ( $\Delta P_{ci}$ ), variação de altura relativa ( $\Delta h_{Vi}$ ) e variação de área aproximada da superfície de copa ( $\Delta S_{aprox_i}$ ), dadas pelas equações (18) a (22).

$$\Delta P_{ci} = \sqrt{(\Delta X_{ci})^2 + (\Delta Y_{ci})^2} \quad (18)$$

$$\Delta X_{ci} = X_{cio} - X_{cig} \quad (19)$$

$$\Delta Y_{ci} = Y_{cio} - Y_{cig} \quad (20)$$

$$\Delta h_{Vi} = h_{Vio} - h_{Vig} \quad (21)$$

$$\Delta S_{aprox_i} = S_{aproxio} - S_{aproxig} \quad (22)$$

onde os termos com índice “o” representam os atributos estruturais calculados antes da generalização, enquanto os termos com índice “g” se referem aos atributos calculados depois da generalização.

Além das medidas de variação individuais, pode ser estimada também a perda de área total de superfície aproximada das copas (perda de área verde total), seja pelo número de árvores não-agregadas que possam ser eliminadas (AE) ao final da simplificação 3D, ou pela soma das reduções das áreas de cada árvore, de acordo com a equação (23):

$$RV = 100 \left( 1 - \frac{S_{total_o} - S_{total_g}}{S_{total_o}} \right) \% \quad (23)$$

onde:

$RV$  é o percentual de redução da área verde estimado;

$S_{total_o}$  é a área total de superfície aproximada das copas das árvores antes da generalização, correspondente à soma das áreas aproximadas das copas de todas as árvores delimitadas originalmente ( $\sum S_{apr_{io}}$ );

$S_{total_g}$  é a área total de superfície aproximada das copas das árvores depois da generalização, correspondente à soma das áreas aproximadas das copas de todas as árvores resultantes da generalização 3D ( $\sum S_{apr_{ig}}$ ).

No caso da eliminação de árvores ao final da simplificação 3D, é calculado o índice PA (perda de árvores), de acordo com a equação (24):

$$PA = 100 \left( 1 - \frac{AE}{AR} \right) \% \quad (24)$$

onde:

PA é o percentual de perda de árvores;

AE é o número de árvores eliminadas;


AR é o número de árvores resultantes da agregação 3D.

A explicação e a formulação de todas as variáveis que quantificam os atributos estruturais extraídos das árvores está na seção 3.4.2.3, enquanto a explicação do índice quantitativo AR está na seção 4.1.3.1

## 2.4 PADRÃO *CITYGML 3.0* (MÓDULO *POINTCLOUD*)


Lançado em setembro de 2021, o padrão internacional de modelagem urbana *CityGML 3.0* é composto, além de um módulo central (*Core*), por módulos temáticos e conceituais (aplicados a todos os temas), como mostrado na FIGURA 24.

FIGURA 24 - VISÃO GERAL DO *CITYGML 3.0*



FONTE: Adaptada de KUTZNER et al. (2020)

No caso desta pesquisa, utilizou-se para a representação das árvores resultantes da generalização 3D o módulo *PointCloud*, cujo diagrama UML (*Unified Modeling Language*) é mostrado na FIGURA 25.

FIGURA 25 – DIAGRAMA UML DO MÓDULO *POINTCLOUD* DO *CITYGML 3.0*

FONTE: OGC (2022)

Esse módulo especifica como codificar a representação de espaços físicos e de superfícies por meio de nuvens de pontos 3D, que podem ser acessadas diretamente dentro de um arquivo *CityGML* ou de maneira externa, referenciada por arquivos de outra extensão mais comum, como o *.LAS/.LAZ*.

A geometria definida para a representação de um objeto em *PointCloud* é do tipo *MultiPoint*, o que impôs que cada árvore resultante da generalização 3D realizada nesta pesquisa fosse representada por um conjunto de múltiplos pontos com coordenadas espaciais XYZ, no caso coordenadas UTM (N, E) e a altura relativa ( $h_r$ ) de todos os seus pontos. Como as especificações para o módulo *PointCloud* ainda são limitadas, estabeleceu-se nesta pesquisa a inserção do atributo ID aos arquivos *.LAS* referentes às nuvens de pontos contendo as árvores resultantes da generalização 3D, complementando o conteúdo informativo original dos arquivos, citado na seção 2.1.

### 3 DESENVOLVIMENTO METODOLÓGICO

#### 3.1 VISÃO GERAL

Esquematizado na FIGURA 26, o desenvolvimento metodológico desta pesquisa foi dividido em quatro etapas: filtragem dos dados utilizados; delimitação automática das árvores; generalização 3D; modelagem das árvores generalizadas no padrão *CityGML 3.0*.

FIGURA 26 - ESQUEMATIZAÇÃO GERAL DA METODOLOGIA EMPREGADA



FONTE: O autor (2022)

Inicialmente, as nuvens de pontos LiDAR foram filtradas com o intuito de remover os pontos espúrios e eliminar também os pontos de solo (*ground points*), já

que a classe de interesse é a arborização urbana. Na sequência, a tarefa de delimitação automática das árvores urbanas exigiu a realização das técnicas de classificação e segmentação.

Delimitadas as árvores e extraídos seus atributos estruturais, o processo de generalização 3D foi dividido em duas etapas: agregação, com base em regras que exploraram medidas espaciais associadas aos princípios-Gestalt (medidas-Gestalt) da proximidade e semelhança; e simplificação, a partir da compressão das nuvens de pontos por meio de um aprendizado profundo não-supervisionado (*autoencoder*) e de uma partição espacial por *octree*. Por fim, as árvores generalizadas foram armazenadas num banco de dados seguindo o padrão de representação *CityGML 3.0* (geometria *multipoint*).

Todo o desenvolvimento metodológico desta pesquisa está detalhado nas seções seguintes deste capítulo, que descrevem os dados utilizados, as duas áreas de estudo correspondentes e as etapas realizadas.

## 3.2 DADOS UTILIZADOS E ÁREAS DE ESTUDO

### 3.2.1 Dados ALS e ortoimagem RGB (área de estudo 1: bairro da Pituba, Salvador-BA)

Os dados ALS foram adquiridos pelo sensor laser RIEGL VQ480-II e disponibilizados no site de Cartografia da Prefeitura Municipal de Salvador (PMS, 2021) no formato *.LAS* versão 1.2. O QUADRO 2 contém um informativo acerca da aquisição dos dados ALS utilizados.

QUADRO 2 - INFORMATIVO DA AQUISIÇÃO LIDAR RIEGL VQ480-II


| Mês/Ano de aquisição           | Altura de voo (m) | Densidade média da nuvem de pontos (pontos/m <sup>2</sup> ) | Acurácia em range (cm) | Sistema geodésico de referência | Sistema de coordenadas | Câmera RGB |
|--------------------------------|-------------------|-------------------------------------------------------------|------------------------|---------------------------------|------------------------|------------|
| Agosto/2016-<br>Fevereiro/2017 | 450               | 8                                                           | 2                      | SIRGAS 2000                     | UTM Fuso 24            | Não        |

FONTE: RIEGL (2019) e PMS (2021)

Como não se dispôs de câmera de mapeamento RGB na aquisição ALS, a colorização RGB dos dados (ver seção 3.4.2.2) foi feita com auxílio de uma ortoimagem adquirida em um 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 ALS e a ortoimagem RGB foram adquiridos com diferença temporal de 3 dias (PMS, 2021) e são referentes a uma área cuja extensão aproximada é 0,297 km<sup>2</sup> (502,64 m x 592,48 m), localizada entre as longitudes 38° 27' 13,26" W - 38° 27' 29,91" W e latitudes 12° 59' 34,76" S - 12° 59' 54,08" S, no bairro da Pituba, município de Salvador-BA (FIGURA 27).

FIGURA 27 - LOCALIZAÇÃO DA ÁREA DE ESTUDO 1 (DADOS ALS)




FONTE: O autor (2022)

O terreno da área de estudo 1 apresenta altitude média inferior a 12 metros (PMS, 2021), não sendo observados significativos declives. Sua paisagem é heterogênea, composta por elementos de vegetação, arruamentos (ruas e avenidas de grande circulação), terrenos pavimentados e diferentes tipos de construções e edificações, englobando um complexo militar pertencente ao Exército Brasileiro (Escola de Formação Complementar do Exército/EsFCEEx e Colégio Militar de Salvador/CMS) e suas vizinhanças norte e leste.

A FIGURA 28 mostra em três modos distintos a heterogeneidade característica da área de estudo em questão.

FIGURA 28 - ÁREA DE ESTUDO 1 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: O autor (2022)

A flora existente nessa área é diversificada (Roque et al., 2020), contendo espécies arbóreas, arbustivas e sub-arbustivas de diferentes estruturas vegetais, encontradas individual ou coletivamente em praças e jardins públicos, propriedades particulares e de acesso restrito, e também plantadas em calçadas (arborização de ruas). Vegetação rasteira (gramínea) também é encontrada na região, principalmente em canteiros de ruas e avenidas e em alguns terrenos baixos sem pavimentação.

### 3.2.2 Dados ULS (área de estudo 2: Campus Centro Politécnico da UFPR, Curitiba-PR)

Os dados ULS foram adquiridos pelo sensor laser DJI Zenmuse L1 e disponibilizados pelo Centro de Pesquisas Aplicadas em Geoinformação (CEPAG) da Universidade Federal do Paraná no formato *.LAS* versão 1.2. Diferentemente dos dados ALS utilizados, os dados ULS foram adquiridos simultaneamente com uma

câmera de mapeamento RGB, não sendo necessária uma nova colorização. O QUADRO 3 contém um informativo acerca da aquisição dos dados ULS utilizados.


QUADRO 3 - INFORMATIVO DA AQUISIÇÃO LIDAR DJI ZENMUSE L1

| Mês/Ano de aquisição | Altura de voo (m) | Densidade média da nuvem de pontos (pontos/m <sup>2</sup> ) | Acurácia em range (cm)          | Sistema geodésico de referência | Sistema de coordenadas | Câmera RGB |
|----------------------|-------------------|-------------------------------------------------------------|---------------------------------|---------------------------------|------------------------|------------|
| Outubro/2021         | 60                | 280                                                         | 10 (horizontal)<br>5 (vertical) | SIRGAS 2000                     | UTM Fuso 22            | Sim        |

FONTE: DJI (2021) e Delazari e Ercolin Filho (2021)

Os dados ULS são referentes a uma área de extensão aproximadamente 0,26 km<sup>2</sup> (650 m x 400 m), localizada entre as longitudes 49° 13' 46.80" W - 49° 14' 15.41" W e latitudes 25° 26' 58.24" S – 25° 27' 14.41" S, na região do Campus Centro Politécnico da Universidade Federal do Paraná em Curitiba-PR (FIGURA 29).


FIGURA 29 - LOCALIZAÇÃO DA ÁREA DE ESTUDO 2 (DADOS ULS)



FONTE: O autor (2022)

Essa área abrange a parte centro-sul do Campus Politécnico e sua vizinhança leste (parte do bairro residencial Jardim das Américas), sendo nela encontrados elementos de vegetação, arruamentos (vias internas e ruas externas ao Campus), e diferentes tipos de construções e edificações, conforme se observa na FIGURA 30.

FIGURA 30 - ÁREA DE ESTUDO 2 VISUALIZADA EM TRÊS MODOS DISTINTOS: (A) NUVEM DE PONTOS LIDAR (RGB); (B) NUVEM DE PONTOS LIDAR (INTENSIDADE); (C) NUVEM DE PONTOS LIDAR (VARIAÇÃO DE ALTIMETRIA).



FONTE: O autor (2022)

A área de estudo 2 contém poucos declives, sendo sua altitude média de 932 metros (IPPUC, 2021). A flora existente na região apresenta tipos diversificados de estruturas arbóreas, tendo destaque os ipês e as araucárias (dominantes no bioma em que está inserida a capital paranaense). Vegetação rasteira (campos e gramíneas) existente em terrenos descampados sem pavimentação também é comum de ser encontrada.

### 3.3 SOFTWARES UTILIZADOS

Foram utilizados nesta pesquisa os seguintes programas e plataformas computacionais:

- *CloudCompare 2.10*: software livre que permitiu a visualização, manipulação e pré-processamento (filtragens) das nuvens de pontos LiDAR;

- *lastools* (ISENBURG, 2011): conjunto de rotinas usadas para visualizar, manipular e processar dados LIDAR em formato .LAS;
- *RStudio*: ambiente de desenvolvimento da linguagem *R*;
- linguagem *Python 3* (com o ambiente de desenvolvimento integrado *Jupyter Notebook*): para adaptação e treinamento da rede neural profunda *DePoCo*;

### 3.4 DESCRIÇÃO DAS ETAPAS METODOLÓGICAS


#### 3.4.1 Filtragem

Nesta seção são descritos os dois algoritmos empregados para as filtrações realizadas (remoção de pontos espúrios e eliminação de pontos-terreno).

##### 3.4.1.1 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 31), 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 31 - DISTÂNCIAS DE UM PONTO  $N_i$  EM SUA  $K$ -VIZINHANÇA (ALGORITMO SOR)



FONTE: O autor (2022)

Conforme a equação (25), 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 fator escalar  $\alpha$  multiplicado pelo desvio-padrão amostral das distâncias ( $s$ ).

$$d_{N_i} > \bar{d} + \alpha.s, \text{ sendo: } \bar{d} = \frac{\sum d_i}{k}; s = \sqrt{\frac{\sum (d_i - \bar{d})^2}{k-1}} \quad (25)$$

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, o *CloudCompare 2.10* exigiu a definição de valores para os parâmetros  $k$  e  $\alpha$ , conforme o QUADRO 4.

QUADRO 4 - VALORES DOS PARÂMETROS PARA A FILTRAGEM SOR

| Dados utilizados | Número de pontos vizinhos (k) | Fator multiplicativo ( $\alpha$ ) |
|------------------|-------------------------------|-----------------------------------|
| ALS              | 6                             | 1                                 |
| ULS              | 15                            | 1                                 |

FONTE: O autor (2022)


A escolha dos valores adotados para esses parâmetros foi feita com base no trabalho de Rusu et al. (2008). No caso do fator multiplicativo  $\alpha$ , foi definido tanto para os dados ALS como para os dados ULS o valor  $\alpha = 1$ , enquanto no caso do número de pontos vizinhos  $k$  foi adotado um valor maior ( $k = 15$ ) para os dados ULS do que para os dados ALS ( $k = 6$ ), devido à maior densidade de pontos.

#### 3.4.1.2 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). 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 32.

FIGURA 32 – SIMULAÇÃO DE TECIDO (ALGORITMO CSF)



FONTE: O autor (2022)

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 equação (26).

$$m_c \frac{\partial^2 P_c(t)}{\partial t^2} = F_{ext}(P_c(t), t) + F_{int}(P_c(t), t) \quad (26)$$

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*  $\delta$  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  $\delta$  são classificados como pontos de terreno  $T_i$  e os demais como pontos não-terreno  $X_i$ .

Dada uma nuvem de pontos  $N = \{N_1, N_2, N_3, \dots, N_n\}$  e o tecido simulado de  $C = \{m_1, m_2, \dots, m_c\}$ , o resultado da filtragem CSF atende, para cada um dos  $n$  pontos, às condições estabelecidas nas equação (27) e (28):

$$\text{se } Z_n - Z_c \leq \delta, \text{ então } N_n \in T \quad (27)$$

$$\text{se } Z_n - Z_c > \delta, \text{ então } N_n \in X \quad (28)$$

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

A filtragem CSF também foi realizada no software *CloudCompare 2.10*, sendo definidos os parâmetros informados no QUADRO 5, além de ter sido selecionada a opção “*Slope processing*” a fim de computar variações altimétricas locais que pudessem ser identificadas pelo algoritmo.

QUADRO 5 - VALORES ADOTADOS PARA OS PARÂMETROS DA FILTRAGEM CSF

| Dado | Tipo de terreno | Resolução da grade (m) | Número máximo de iterações | Limiar para classificação (m) |
|------|-----------------|------------------------|----------------------------|-------------------------------|
| ALS  | Plano           | 1,0                    | 500                        | 0,1                           |
| ULS  | Saliente        | 1,0                    | 500                        | 0,1                           |

FONTE: O autor (2022)

Considerando as características de relevo das duas áreas de estudo, o tipo de terreno foi definido como plano (“*flat*”) para a área 1, enquanto para a área 2 foi definido o tipo saliente (“*relief*”).

A resolução da grade equivale ao espaçamento entre os nós do tecido simulado, e foi definida como 1,0 metro para as duas áreas de estudo, considerando

ser este um valor intermediário (valor padrão do software é de 2,0 metros) que permitisse evitar superamostragem ou subamostragem.


O número máximo de iterações para o ajuste da simulação do tecido foi definido como o padrão do software, no caso, igual a 500.

Para o limiar de classificação (tolerância para a distância final calculada entre os nós do tecido simulado e os pontos da nuvem invertida) foi definido para as duas áreas de estudo o valor de 0,1 metro, visando maior precisão.

### 3.4.2 Delimitação das árvores

Buscando delimitar de maneira individual as árvores de interesse nas nuvens de pontos, foi realizada a sequência de procedimentos mostrados na FIGURA 33.

FIGURA 33 - SEQUÊNCIA DE PROCEDIMENTOS PARA A DELIMITAÇÃO DAS ÁRVORES



FONTE: O autor (2022)

Após as duas filtragens (SOR + CSF), foi realizada uma classificação preliminar dos pontos não-terreno visando auxiliar a identificação dos pontos de vegetação. Posteriormente, foi feita uma análise que apontasse os erros de omissão


e de inclusão e permitisse refinar o resultado da classificação com o intuito de descartar os falsos positivos e aproveitar os falsos negativos de vegetação.

Selecionados então todos os pontos de vegetação (verdadeiros positivos e falsos negativos), estes foram usados para a segmentação e a delimitação das árvores de interesse para a generalização 3D. Nessa tarefa, buscou-se delimitar todas as estruturas vegetais arbóreas existentes nas duas áreas de estudo, considerando seus principais elementos (copa e sub-copa).

#### 3.4.2.1 Classificação dos pontos não-terreno

O procedimento foi realizado de maneira sequencial com auxílio de três rotinas de processamento implementadas no software *lastools* (ISENBURG, 2011): *lasground*, *lasheight* e *lasclassify* (FIGURA 34).

FIGURA 34 - ROTINAS LASTOOLS UTILIZADAS PARA CLASSIFICAÇÃO DOS PONTOS NÃO-TERRENO



FONTE: O autor (2022)

A rotina *lasground* foi utilizada com o intuito de validar o resultado da filtragem CSF e criar um atributo de classificação inicial para todos os pontos não-terreno filtrados, sendo atribuído o valor “1” para os pontos confirmados como não-terreno e o valor “2” para pontos erroneamente filtrados como não-terreno, seguindo a codificação estabelecida pela ASPRS, que foi descrita no trabalho de Ferreira (2014). Por essa codificação, pontos sem classificação recebem o valor “1”, pontos de terreno recebem o valor “2”, pontos de vegetação recebem o valor “5” e pontos de edificações recebem o valor “6”.

Segundo o arquivo *.readme* da rotina *lasground*, a filtragem se baseia na análise da variação de desníveis altimétricos (*steps*) em pequenas áreas, sendo o valor de 25 metros tratado como o padrão do algoritmo (opção “*city*”). Outros valores de *steps* podem ser definidos de acordo com a região analisada: 10 metros (opção “*town*”), para terrenos com poucos edifícios; ou 50 metros (opção “*metropolis*”), para regiões urbanas complexas com muitos edifícios.

Considerando a caracterização estrutural das duas áreas de estudo, definiu-se o tipo “*metropolis*” para a nuvem ALS e o tipo “*city*” para a nuvem ULS. Para os outros parâmetros empregados selecionou-se a opção “*default*”.

A rotina *lasheight* calculou, com base numa triangulação irregular (TIN – *triangular irregular net*) a altura (valor de altimetria acima do terreno) para todos os pontos validados como não-terreno (atributo de classificação “1”), a fim de auxiliar a tarefa de classificação. Visando reduzir a quantidade de pontos usados na classificação, optou-se por remover (opção “*drop points*”) aqueles que tivessem valores de altura inferiores a 5 metros (“*below 5*”) e superiores a 30 metros (“*above 30*”), considerando haver nas áreas estudadas árvores com estes limites de altura. Visando simplificar cálculos seguintes, selecionou-se a opção de substituir as coordenadas Z originais dos pontos da nuvem pelos valores calculados das alturas (opção *replace Z*).

A rotina *lasclassify* rotulou os pontos remanescentes (altura entre 5 e 30 metros) em edificações ou vegetação, com base na busca de pontos vizinhos que formam, por crescimento de regiões, superfícies planares. Os pontos cuja planaridade estimada ( $a_1$ ) foi suficiente para o pertencimento a um determinado plano local ajustado foram rotulados como edificações; caso contrário foram rotulados como

vegetação (não-planares e volumetricamente espalhados), por apresentarem valores mais significativos para o atributo  $a_2$  estimado.

Para a rotulação, foram consideradas tolerâncias medidas em desvio-padrão: 0,1m para a planaridade (opção “*building planarity*”), que é o valor estabelecido como padrão pelo *lastools*, para evitar falsos negativos de vegetação, já que maiores valores poderiam aumentar a quantidade de pontos rotulados como edificações; 0,3m para o espalhamento volumétrico (opção “*forest ruggedness*”), visando aumentar a tolerância para a rotulação de pontos de vegetação.

A rotina *lasclassify* exigiu também a definição de outros parâmetros:

- tamanho da janela de vizinhança (opção “*search area size*”): como padrão da rotina, é adotado o valor de 2 metros, podendo ser definido um tamanho máximo de 4 metros para nuvens de pontos esparsas. Por isso, adotou-se o valor padrão para os dados ULS enquanto para os dados ALS foi adotado o valor de 4 metros, já que estes têm menor densidade de pontos;

- valor mínimo de altura considerada para a classificação (opção “*ground offset*”): foi definido para as duas nuvens de pontos o valor de 5 metros, concordante com a altura mínima previamente considerada na rotina *lasheight*;

- simulação ou não da projeção de bordas de edificações (opção “*wide gutters*”): visando corrigir o problema da borda em edificações devido à ausência parcial de pontos vizinhos para a estimação da planaridade, a simulação das bordas por projeção foi considerada para as duas nuvens de pontos;

- existência ou não de pequenos edifícios (opção “*small buildings*”): devido aos diferentes tipos de construções existentes nas duas áreas de estudo, considerou-se também a existência de pequenos edifícios, não só os de grandes dimensões horizontais e verticais;

- existência ou não de vegetação sobreposta a edificações (opção “*tree overhang*”): a fim de identificar o máximo de pontos de vegetação possível, considerou-se também a existência de vegetação sobreposta às edificações nas duas áreas de estudo.

O QUADRO 6 resume, para os dados ALS e ULS utilizados, todos os parâmetros definidos para a classificação.

QUADRO 6 - PARÂMETROS DEFINIDOS PARA A ROTINA *LASCLASSIFY*

| Dados | Tamanho de janela de vizinhança (m) | Limiar planar (m) | Limiar não-planar (m) | Off-set (m) | Pequenos edifícios | Vegetação sobreposta a edificações | Projeção de bordas |
|-------|-------------------------------------|-------------------|-----------------------|-------------|--------------------|------------------------------------|--------------------|
| ALS   | 4                                   | 0,1               | 0,3                   | 5           | Sim                | Sim                                | Sim                |
| ULS   | 2                                   | 0,1               | 0,3                   | 5           | Sim                | Sim                                | Sim                |

FONTE: O autor (2022)

Ressalta-se que devido à limitação do referido software no tocante à quantidade de pontos processados, foi necessário dividir a nuvem de pontos ULS em nuvens menores, de modo que cada parte contivesse o máximo de 1,5 milhão de pontos, conforme sugerido nos arquivos “*readme*” correspondentes às rotinas utilizadas. Obteve-se assim 23 nuvens ULS menores, que ao final de todo o processamento realizado, foram concatenadas (*merge*) numa única nuvem ULS classificada resultante.


#### 3.4.2.2 Refinamento da classificação

Como o algoritmo implementado na rotina *lasclassify* empregou somente atributos geométricos associados à dimensionalidade (planar ou volumétrica) dos objetos, o refinamento da classificação foi feito considerando simultaneamente outros dois aspectos: radiométrico-espectral (RGB) e máximo local.

A escolha do critério radiométrico-espectral se deu em virtude da disponibilidade de informações RGB correspondentes às aquisições LiDAR, informações estas consideradas úteis ao processo de delimitação das árvores, haja vista o destacado comportamento espectral da vegetação na faixa eletromagnética do visível (bandas espectrais azul/verde/vermelho). Por sua vez, a escolha do critério máximo local se justifica pela sua aplicabilidade em tarefas de detecção de árvores individuais, conforme explicado no capítulo anterior.

A FIGURA 35 mostra resumidamente os dois critérios empregados para a análise e o refinamento semi-automático da classificação realizada.

FIGURA 35 - CRITÉRIOS PARA A ANÁLISE E O REFINAMENTO DA CLASSIFICAÇÃO




FONTE: O autor (2022)

Segundo Magalhães e Xavier (2018) e Jensen (2011), devido à presença de clorofila a vegetação apresenta alta reflectância entre 0,5 e 0,6  $\mu\text{m}$  de comprimento de onda (verde) e forte absorção entre as faixas de 0,4 a 0,5  $\mu\text{m}$  (azul) e de 0,63 a 0,7  $\mu\text{m}$  (vermelho). Magalhães e Xavier (2018) destacaram ainda a alta reflectância de alvos urbanos como telhados, concretos, calçadas e ruas sem pavimentação na faixa do vermelho.

Dessa maneira, presume-se que aos pontos de vegetação podem ser associados maiores valores de reflectância na componente G (*green*), sendo estes maiores que os valores para as componentes R (*red*) e B (*blue*), todos quantificados no intervalo  $[0; 2^b - 1]$ , onde  $b$  é a resolução radiométrica (número de bits) considerada. Pelo mesmo entendimento, maiores valores de reflectância em R podem ser associados aos pontos de edificações, sendo estes maiores que os valores em G e B.

Frisa-se que a resolução radiométrica considerada nesta pesquisa é a do mapeamento óptico (RGB) correspondente aos dados LiDAR adquiridos. Para os dados ULS, a câmera óptica auxiliar possibilitou uma aquisição em 16 bits (padrão .LAS), sendo os valores das coordenadas RGB pertencentes ao intervalo  $[0, 65.535]$ , equivalente a  $2^{16}$  níveis de cinza. Já para o caso dos dados ALS, como a aquisição não dispôs de uma câmera de mapeamento RGB, a colorização ocorreu com auxílio de outra rotina *lastools: lascolor* (FIGURA 36).

FIGURA 36 - ROTINA LASCOLOR PARA COLORIZAÇÃO DA NUVEM DE PONTOS ALS



FONTE: O autor (2022)

Observa-se a necessidade da prévia transformação radiométrica da correspondente ortoimagem RGB, de 8 para 16 bits, usando o *QGIS 3.16*. Consequentemente, o intervalo de valores para as coordenadas RGB foi ampliado de [0, 255] para [0, 65.535].

Como resultado da colorização, a rotina atribuiu a cada um dos pontos da nuvem ALS (coordenadas N, E, h) as coordenadas RGB dos pixels correspondentes (mesmas coordenadas N, E) na ortoimagem, adicionando assim três atributos à nuvem de pontos, de maneira que cada ponto possui coordenadas (R, G, B) além das coordenadas originais (N, E, h).

Sendo  $X_{iR}$ ,  $X_{iG}$  e  $X_{iB}$  respectivamente os valores de reflectância das componentes R, G e B quantificados para um ponto  $X_i$ , e  $2^{b-1}$  a metade do intervalo de valores correspondentes à resolução radiométrica  $b$ , definem-se as seguintes condições para análise e validação de um ponto  $X_i$  rotulado, conforme o QUADRO 7:

QUADRO 7 - CRITÉRIO RADIOMÉTRICO-ESPECTRAL PARA ANÁLISE DE UM PONTO  $X_i$  ROTULADO


| Rótulo inicial   | Condições para $X_{iG}$ , $X_{iR}$ e $X_{iB}$                       | Resultado da validação                         |
|------------------|---------------------------------------------------------------------|------------------------------------------------|
| Vegetação        | $X_{iG} \geq 2^{b-1}$ ; $X_{iG} > X_{iR}$ ; $X_{iG} > X_{iB}$       | Verdadeiro positivo                            |
|                  | $X_{iG} \geq 2^{b-1}$ ; $X_{iG} < X_{iR}$ ou $X_{iG} < X_{iB}$      | Falso positivo (falso negativo de edificações) |
|                  | $X_{iG} < 2^{b-1}$ ; $X_{iG} > X_{iR}$ ; $X_{iG} > X_{iB}$          | Verdadeiro positivo                            |
|                  | $X_{iG} < 2^{b-1}$ ; $X_{iG} < X_{iR}$ ou $X_{iG} < X_{iB}$         | Falso positivo (falso negativo de edificações) |
| Edificações      | $X_{iR} \geq 2^{b-1}$ ; $X_{iR} > X_{iG}$ ; $X_{iR} > X_{iB}$       | Verdadeiro positivo                            |
|                  | $X_{iR} \geq 2^{b-1}$ ; $X_{iR} < X_{iG}$ ; $X_{iR} \approx X_{iB}$ | Falso positivo (falso negativo de vegetação)   |
|                  | $X_{iR} < 2^{b-1}$ ; $X_{iR} > X_{iG}$ ; $X_{iR} > X_{iB}$          | Verdadeiro positivo                            |
|                  | $X_{iR} < 2^{b-1}$ ; $X_{iR} < X_{iG}$ ; $X_{iR} \approx X_{iB}$    | Falso positivo (falso negativo de vegetação)   |
| Não classificado | $X_{iG} \geq 2^{b-1}$ ; $X_{iG} > X_{iR}$ ; $X_{iG} > X_{iB}$       | Falso negativo de vegetação                    |
|                  | $X_{iG} \geq 2^{b-1}$ ; $X_{iG} < X_{iR}$ ou $X_{iG} < X_{iB}$      | Falso negativo de edificações                  |
|                  | $X_{iG} < 2^{b-1}$ ; $X_{iG} > X_{iR}$ ; $X_{iG} > X_{iB}$          | Falso negativo de vegetação                    |
|                  | $X_{iG} < 2^{b-1}$ ; $X_{iG} < X_{iR}$ ou $X_{iG} < X_{iB}$         | Falso negativo de edificações                  |
|                  | $X_{iR} \geq 2^{b-1}$ ; $X_{iR} > X_{iG}$ ; $X_{iR} > X_{iB}$       | Falso negativo de edificações                  |
|                  | $X_{iR} \geq 2^{b-1}$ ; $X_{iR} < X_{iG}$ ; $X_{iR} \approx X_{iB}$ | Falso negativo de vegetação                    |
|                  | $X_{iR} < 2^{b-1}$ ; $X_{iR} > X_{iG}$ ; $X_{iR} > X_{iB}$          | Falso negativo de edificações                  |
|                  | $X_{iR} < 2^{b-1}$ ; $X_{iR} < X_{iG}$ ; $X_{iR} \approx X_{iB}$    | Falso negativo de vegetação                    |

FONTE: O autor (2022)

A análise e o remanejamento dos pontos falsos positivos e falsos negativos identificados para as suas classes corretas foram feitas com auxílio da rotina *las2las*, que permite salvar novos arquivos com a extensão .LAS a partir de algum critério previamente aplicado a um arquivo .LAS original. Foi considerado para o parâmetro  $2^{b-1}$  o valor de 32.767, uma vez que a resolução radiométrica considerada foi de 16 bits. Finalizou-se assim o refinamento pelo critério radiométrico-espectral.

Pelo critério do máximo local, pontos que não apresentam significativas variações altimétricas em relação aos seus vizinhos podem pertencer a regiões planares horizontais (telhados e coberturas), sendo então descartados como pontos de vegetação. A FIGURA 37 mostra os pontos A, B, C e D validados como vegetação pois apresentam variações de altura em suas respectivas vizinhanças ( $d_A$ ,  $d_B$ ,  $d_C$ ,  $d_D$ ), ao passo que E e F não apresentam variação altimétrica em relação aos seus vizinhos ( $d_E$ ,  $d_F$ ) sendo então considerados pontos não-vegetação (edificações).

FIGURA 37 - CRITÉRIO DO MÁXIMO LOCAL



FONTE: O autor (2022)

O refinamento por esse critério ocorreu da seguinte maneira: aplicou-se nas nuvens de pontos ALS e ULS classificadas uma adaptação do filtro de máximos locais (*local maximum filter* – *lmf*) implementado na função *find-trees* da biblioteca *lidR* (Roussel et al., 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 de edificações.

Estabelecidos os dois critérios para o refinamento da classificação, as condições a serem atendidas simultaneamente por um ponto  $X_i$  classificado estão resumidas no QUADRO 8:

QUADRO 8 – RESUMO DAS CONDIÇÕES ESTABELECIDAS PARA O REFINAMENTO DA CLASSIFICAÇÃO DE UM PONTO  $X_i$  (DOIS CRITÉRIOS)

| Classe      | CrITÉrio RGB                                                            | CrITÉrio do máximo local |
|-------------|-------------------------------------------------------------------------|--------------------------|
| Vegetação   | $X_{iG} \geq 2^{b-1}; X_{iG} > X_{iR} \geq X_{iB}$                      | $X_i$ é máximo local     |
|             | $X_{iG} < 2^{b-1}; X_{iG} > X_{iR}; X_{iG} > X_{iB}$                    |                          |
|             | $X_{iR} \geq 2^{b-1}; X_{iR} < X_{iG}; X_{iR} \approx X_{iB}$           |                          |
|             | $X_{iR} < 2^{b-1}; X_{iR} < X_{iG}; X_{iR} \approx X_{iB}$              |                          |
| Edificações | $X_{iR} \geq 2^{b-1}; X_{iB} \geq 2^{b-1}; X_{iR} \geq X_{iB} > X_{iG}$ | $X_i$ não é máximo local |
|             | $X_{iR} < 2^{b-1}; X_{iR} > X_{iG}; X_{iR} > X_{iB}$                    |                          |
|             | $X_{iG} \geq 2^{b-1}; X_{iG} < X_{iR}$ ou $X_{iG} < X_{iB}$             |                          |
|             | $X_{iG} < 2^{b-1}; X_{iG} < X_{iR}$ ou $X_{iG} < X_{iB}$                |                          |

FONTE: O autor (2022)


Após o refinamento simultâneo pelos dois critérios, foi então obtida uma nuvem de pontos resultante  $U = \{u_1, u_2, \dots, u_n\}$  contendo somente os verdadeiros positivos e os falsos negativos de vegetação.

#### 3.4.2.3 Segmentação das copas

Para a delimitação das árvores, foi realizada a segmentação da nuvem  $U$  com auxílio da função *segment\_trees* implementada no *lidR*, tendo sido adotada uma adaptação do algoritmo desenvolvido por Li et al. (2012), que exigiu a definição dos seguintes parâmetros: limites inferior (*dt1*) e superior (*dt2*) que correspondem aos espaçamentos horizontais teóricos admissíveis dos ápices das copas e das prováveis bases; raio de busca para máximos locais (*R*); valor condicionante de altura (*Zu*) que define os limites adaptativos para os espaçamentos, ou seja, para pontos de  $U$  cuja altura seja maior que *Zu* adota-se *dt2* e para pontos  $u$  cuja altura seja menor ou igual a *Zu* adota-se *dt1*; altura mínima admissível para uma árvore detectada (*hmin*); valor máximo do raio da copa de uma árvore (*speed\_up*).

Para facilitar o entendimento do método de segmentação utilizado, os parâmetros citados estão identificados na FIGURA 38.

FIGURA 38 – VISÃO GERAL DO MÉTODO DE SEGMENTAÇÃO ADOTADO



FONTE: O autor (2022)

O algoritmo segmenta as árvores a partir de máximos globais identificados (pontos-semente), analisando os outros  $u$  pontos da nuvem  $U$  de acordo com as seguintes regras:

1. Sendo  $u$  um máximo local dentro de um raio de busca  $R$ , este pode ser o topo de um galho pertencente à árvore-alvo da segmentação na iteração  $i$  ou pertencer ao topo de outra árvore. O algoritmo analisa o espaçamento admissível entre os ápices e também espaçamentos mínimos, dados por distâncias  $d_{min_1}$  e  $d_{min_2}$ , que correspondem respectivamente a valores para os quais  $u$  pertença à árvore-alvo  $U_i$  ou à árvore resultante  $N_i$ .

Sendo assim, tem-se as condições dadas pelas equações (29), (30) e (31):

$$\text{se } d_{min_1} > d_t, u \in N_i; \quad (29)$$

$$\text{se } d_{min_1} \leq d_t \text{ e } d_{min_1} \leq d_{min_2}, u \in U_i; \quad (30)$$

$$\text{se } d_{min_1} \leq d_t \text{ e } d_{min_1} > d_{min_2}, u \in N_i. \quad (31)$$

onde  $d_t$  é um limite adaptativo, usado nesta pesquisa de acordo com as condições dadas pelas equações (32) e (33) :

$$d_t = 7 \text{ m, se } Z_u > 15 \text{ m}; \quad (32)$$

$$d_t = 5 \text{ m, se } Zu \leq 15 \text{ m.} \quad (33)$$

2. Sendo  $u$  um ponto não máximo local, ele é analisado somente com base na regra de espaçamento mínimo, de acordo com as equações (34) e (35):

$$\text{se } d_{min_1} \leq d_{min_2}, u \in U_i; \quad (34)$$

$$\text{se } d_{min_1} > d_{min_2}, u \in N_i. \quad (35)$$

No caso ilustrado na FIGURA 38, o ponto A é atribuído à árvore  $U_1$  porque a distância horizontal  $d_{m_1,A}$  entre  $m_1$  e A é menor que o limite de espaçamento  $d_{t_2}$ . O ponto B é o próximo ponto testado, cuja distância  $d_{m_1,B}$  é maior que o limite  $d_{t_2}$ , sendo então atribuído à árvore  $U_2$ .

Para a realização da segmentação, foram definidos os seguintes valores dos parâmetros exigidos pelo algoritmo:  $dt1$  (limite adaptativo inferior) = 5 metros;  $dt2$  (limite adaptativo superior) = 7 metros;  $R$  = 5 metros;  $Zu$  = 15 metros (*default* utilizado);  $hmin$  = 5 metros, já que todo o procedimento de classificação realizado considerou este como o valor mínimo de altura das árvores;  $speed\_up$  = 10 metros (*default* utilizado).

Os valores de 5 metros e 7 metros adotados para os limites adaptativos inferior ( $dt1$ ) e superior ( $dt2$ ), bem como o valor de 5 metros para o raio de busca  $R$  se justificam por serem considerados razoáveis para os cenários urbanos estudados.

Foi então usado o seguinte comando para executar a função de segmentação:

*las <- segment\_trees (las, li2012 (dt1=5, dt2=7, R=5, Zu=15, hmin = 5, speed\_up = 10), attribute = "IDli")*, sendo *li2012* o algoritmo utilizado e *las* o arquivo contendo a nuvem de pontos  $U$  a ser segmentada (obtida após o refinamento da classificação).

Como resultado da segmentação, foi criado para cada ponto das nuvens ALS e ULS um novo atributo (identificador  $IDtree = IDli$ ) que identifica a árvore a qual pertence, de maneira específica. Pôde-se assim extrair as seguintes métricas de cada uma das árvores delimitadas, com o emprego da função *tree\_metrics*:

$X_{min}$  – coordenada E de menor valor;

$X_{mean}$  – coordenada E do ponto centroide;  
 $X_{max}$  – coordenada E de maior valor;  
 $Y_{min}$  – coordenada N de menor valor;  
 $Y_{mean}$  – coordenada N do ponto centroide;  
 $Y_{max}$  – coordenada N de maior valor;  
 $Z_{min}$  – coordenada Z de menor valor;  
 $Z_{mean}$  – coordenada Z do ponto centroide;  
 $Z_{max}$  – coordenada Z de maior valor;  
 $h_r$  – altura relativa (diferença entre  $Z_{max}$  e  $Z_{min}$ ;  $h_r = Z_{max} - Z_{min}$ );  
 $C_x$  – comprimento aproximado da copa no sentido E (diferença entre  $E_{max}$  e  $E_{min}$ ;  $C_x = E_{max} - E_{min}$ );  
 $C_y$  – comprimento aproximado da copa no sentido N (diferença entre  $N_{max}$  e  $N_{min}$ ;  $C_y = N_{max} - N_{min}$ );  
 $S_{apr}$  – área aproximada da copa (produto entre  $C_x$  e  $C_y$ ;  $S_{apr} = C_x \times C_y$ ).

Para tal, foi usado o seguinte comando: `tree_metrics (las, ~list (x_max = max(X), y_max = max(Y), z_max = max(Z), x_min = min(X), y_min = min(Y), z_min = min(Z), x_mean = mean(X), y_mean = mean(Y), z_mean = mean(Z), Cx = max(X) - min(X), Cy = max(Y) - min(Y), hr = max(Z) - min(Z), Sapr = (max(X) - min(X)) * (max(Y) - min(Y))), attribute="IDli")`, sendo a variável *las* correspondente aos arquivos .LAS que contêm as árvores previamente segmentadas.


Como resultado dessa função, obtém-se uma estrutura de arquivo tratada na linguagem *R* como um *SpatialPointsDataFrame*, uma espécie de tabela onde cada linha se refere a uma árvore segmentada e as colunas a cada um dos atributos estruturais extraídos.

Além da extração dos atributos estruturais de cada árvore, a delimitação das árvores permitiu também o cálculo das métricas de paisagens (fragmentação e dispersão), sendo previamente conhecida a extensão das duas áreas de estudo.

### 3.4.3 Generalização 3D

Delimitadas as árvores de interesse e extraídos seus atributos estruturais, procedeu-se à generalização 3D pela aplicação sequencial dos operadores agregação e simplificação adaptados para o domínio 3D, conforme mostra a FIGURA 39.

FIGURA 39 - OPERADORES APLICADOS NA GENERALIZAÇÃO 3D



FONTE: O autor (2022)

A agregação 3D explorou relações espaciais de proximidade e semelhança quantificadas entre as árvores a fim de gerar agrupamentos perceptivos e consequentemente reduzir o número de elementos arbóreos. A simplificação 3D ocorreu com base na compressão da densidade de pontos das nuvens resultantes do processo de agregação 3D.

Empregou-se assim uma abordagem mista, tratando-se objetos na agregação 3D e pontos na simplificação 3D, sendo considerada a geometria *multipoint* em ambas as operações.


Nos itens a seguir, são detalhadas as duas operações realizadas.

#### 3.4.3.1 Agregação 3D

Para realizar essa operação, foi necessário definir condições que exploraram relações espaciais de proximidade e semelhança (tamanho relativo) entre pares de árvores adjacentes ( $V_i$  e  $V_j$ ). Essas relações foram quantificadas por meio das seguintes medidas-Gestalt relacionadas na FIGURA 40: distância horizontal entre os centroides ( $d(V_i, V_j)$ ); razão das alturas relativas ( $R_h$ ); razão dos comprimentos das

copas em duas dimensões ( $R_{Cx}$  e  $R_{Cy}$ ); razão das áreas superficiais aproximadas das copas ( $R_{Sapr}$ ).

FIGURA 40 - VISÃO GERAL DA AGREGAÇÃO 3D



FONTE: O autor (2022)

Nas subseções seguintes são formuladas as medidas-Gestalt exploradas bem como seus limiares estabelecidos para a agregação das árvores.

#### 3.4.3.1.1 Formulação das medidas-Gestalt e condições geométricas

A distância horizontal ( $d(V_i, V_j)$ ) representa a projeção da distância euclidiana entre os centroides das árvores  $V_i$  e  $V_j$  num plano horizontal e quantifica a proximidade entre elas, sendo definida pela equação (36).

$$d(V_i, V_j) = \sqrt{(X_{ci} - X_{cj})^2 + (Y_{ci} - Y_{cj})^2} \quad (36)$$

onde:

- $X_{ci}$  e  $X_{cj}$  são as coordenadas E dos centroides ( $X_{mean}$ ) das árvores  $V_i$  e  $V_j$  respectivamente;
- $Y_{ci}$  e  $Y_{cj}$  são as coordenadas N dos centroides ( $Y_{mean}$ ) das árvores  $V_i$  e  $V_j$  respectivamente.

A razão das alturas relativas ( $R_h$ ), a razão dos comprimentos das copas ( $R_c$ ) em X e Y, e a razão das áreas superficiais aproximadas das copas ( $R_{Sapr}$ ) são medidas que quantificam a similaridade de tamanho (porte) entre duas árvores  $V_i$  e  $V_j$ , sendo definidas pelas equações (37), (38), (39), (40).

$$Rh(i, j) = \frac{hr_i}{hr_j} \quad (37)$$

$$R_{cx}(i, j) = \frac{Cx_i}{Cx_j} \quad (38)$$

$$R_{cy}(i, j) = \frac{Cy_i}{Cy_j} \quad (39)$$

$$RSapr(i, j) = \frac{Sapri}{Sapri} \quad (40)$$

onde:

-  $hr_i$  e  $hr_j$  são as alturas relativas das árvores  $V_i$  e  $V_j$ , dadas pelas equações (41) e (42) respectivamente;

$$hr_i = Z_{(\max)_i} - Z_{(\min)_i} \quad (41)$$

$$hr_j = Z_{(\max)_j} - Z_{(\min)_j} \quad (42)$$

-  $C_{xi}$  e  $C_{xj}$  são os comprimentos (em sentido X) das copas das árvores  $V_i$  e  $V_j$ , dados pelas equações (43) e (44) respectivamente;

$$C_{xi} = (X_{(\max)} - X_{(\min)})_i \quad (43)$$

$$C_{xj} = (X_{(\max)} - X_{(\min)})_j \quad (44)$$

-  $C_{yi}$  e  $C_{yj}$  são os comprimentos (em sentido Y) das copas das árvores  $V_i$  e  $V_j$ , dados pelas equações (45) e (46) respectivamente;

$$C_{yi} = (Y_{(\max)} - Y_{(\min)})_i \quad (45)$$

$$C_{yj} = (Y_{(\max)} - Y_{(\min)})_j \quad (46)$$

-  $S_{apri}$  e  $S_{apri}$  são as áreas superficiais aproximadas das copas das árvores  $V_i$  e  $V_j$ , dadas pelas equações (47) e (48) respectivamente.

$$S_{apri} = (C_{xi})x(C_{yi}) \quad (47)$$

$$S_{apri} = (C_{xj})x(C_{yj}) \quad (48)$$

Formuladas as medidas-Gestalt, foram definidas as condições espaciais a serem atendidas na agregação, que considera simultaneamente a proximidade e a semelhança. Para a agregação por proximidade, tem-se a condição definida pela equação (49):

$$\text{Se } d_{V_i, V_j} \leq t_d, \{V_i, V_j\} \in G_p \quad (49)$$

onde:  $t_d$  é um limiar preestabelecido para o valor de distância entre as árvores  $V_i$  e  $V_j$ ;  $G_p$  é um agrupamento formado por árvores que atendem ao critério da proximidade estabelecido, equivalente a um par de árvores consideradas próximas.

Obtidos os grupos compostos por árvores próximas, verifica-se as relações de tamanho relativo para cada par, visando a agregação por semelhança. Para tal, são estabelecidas as condições definidas pelas equações (50), (51), (52) e (53):

$$\text{Se: } t_{h_{\min}} < \frac{h_{ri}}{h_{rj}} \leq t_{h_{\max}} \quad (50)$$

$$t_{C_{x\min}} < \frac{C_{x_i}}{C_{x_j}} \leq t_{C_{x\max}} \quad (51)$$

$$t_{C_{y\min}} < \frac{C_{y_i}}{C_{y_j}} \leq t_{C_{y\max}} \quad (52)$$

$$t_{S_{apr\min}} < \frac{S_{apr_i}}{S_{apr_j}} \leq t_{S_{apr\max}} \quad (53)$$

$$\{V_i, V_j\} \in G_S$$

Onde: -  $t_{hr_{\min}}$  e  $t_{hr_{\max}}$  são valores limiares mínimo e máximo para a razão entre as alturas relativas das árvores  $V_i$  e  $V_j$ ;

-  $t_{C_{x\min}}$  e  $t_{C_{x\max}}$  são valores limiares mínimo e máximo para a razão entre os comprimentos (em X) das copas das árvores  $V_i$  e  $V_j$ ;


-  $t_{C_{y\min}}$  e  $t_{C_{y\max}}$  são valores limiares mínimo e máximo para a razão entre os comprimentos (em Y) das copas das árvores  $V_i$  e  $V_j$ ;

-  $t_{S_{apr\min}}$  e  $t_{S_{apr\max}}$  são valores limiares mínimo e máximo para a razão entre as áreas aproximadas das árvores  $V_i$  e  $V_j$ ;

-  $G_S$  é um agrupamento formado por árvores próximas pertencentes a  $G_p$  que também atendem aos critérios de agregação por semelhança.  $G_S$  é então composto por pares de árvores próximas e similares por altura e área de superfície aproximada, tal que  $G_S \subset G_p$ , e num caso particular onde todas as árvores próximas são similares tem-se  $G_S \subseteq G_p$ .

Exemplificando as condições espaciais para operação de agregação 3D, a FIGURA 41 ilustra um cenário hipotético de quatro árvores (A, B, C, D), com seus respectivos atributos estruturais extraídos.

FIGURA 41 - CONDIÇÕES ESPACIAIS PARA A AGREGAÇÃO 3D



FONTE: O autor (2022)

No caso, os pares de árvores (A, B) e (B, C) são considerados próximos pois  $d_{A,B}$  e  $d_{B,C}$  são inferiores a um determinado limite  $t_d$  considerado. O par (C, D) não é considerado próximo pois  $d_{C,D}$  é maior que  $t_d$ . No tocante à similaridade, o par (B, C) não apresenta a mesma altura  $Hr$ , enquanto o par (A, B) apresenta similaridade de altura ( $Hr_A \approx Hr_B$ ) e também de comprimento ( $Cx_A \approx Cx_B$ ). Como resultado, somente as árvores A e B seriam agregadas nessa situação, gerando um objeto mesclado AB cujas dimensões resultantes são dadas em função dos atributos estruturais previamente extraídos de A e B, conforme as equações (54), (55), (56) e (57).

$$Hr_{(AB)} = \frac{Hr_A + Hr_B}{2} \quad (54)$$

$$Cx_{(AB)} = Cx_A + Cx_B \quad (55)$$

$$Cy_{(AB)} = Cy_A + Cy_B \quad (56)$$

$$Sapr_{(AB)} = Sapr_A + Sapr_B \quad (57)$$


#### 3.4.3.1.2 Conjuntos de limiares estabelecidos

Com base nas especificações do LoD 2 da classe PC, que prevêem limites de área de cobertura vegetal ( $Scv$ ) no intervalo de valores entre 5 metros x 5 metros (limite superior para o LoD 3) e 50 metros x 50 metros (limite inferior para o LoD 1),

no caso  $(5 \times 5) \text{ m}^2 < S_{cv} \leq (50 \times 50) \text{ m}^2$ , e a fim de evitar agregações errôneas causadas pela supressão preliminar das edificações existentes, estabeleceu-se seis diferentes valores para o limiar  $t_d$  (em metros): 35; 30; 25; 20; 15.

A escolha dos dois valores extremos (35 metros e 15 metros) se dá pelo limite de 7 metros como o valor máximo de espaçamento horizontal adotado no algoritmo de segmentação, conforme ilustra a FIGURA 42.

FIGURA 42 – DEFINIÇÃO DO LIMAR DE DISTÂNCIA ENTRE AS ÁRVORES (MÁXIMO E MÍNIMO)



FONTE: O autor (2022)

Como não são especificadas dimensões altimétricas do LoD 2 para objetos do tipo PC, e buscando compatibilizar a altura mínima especificada para a classe SVO (6 metros) com a mínima altura obtida nas etapas metodológicas anteriores, adotou-se como limites para a razão  $Rh(i, j)$  os valores de 0,83 e 1,2, respectivamente iguais a  $\left(\frac{5}{6}\right)$  e  $\left(\frac{6}{5}\right)$ .

Para a definição dos limiares de  $C_x$ ,  $C_y$  e  $S_{apr}$ , são considerados dois casos: a similaridade entre os dois limites de espaçamento horizontal adotados para a prévia segmentação, no caso 5 e 7 metros; abordagem feita em Wang et al. (2015), que considerou como limite superior para a razão de áreas de pegadas de prédios a serem agregados o valor de 1,5.

Tem-se então, para o primeiro caso, os seguintes valores mínimos e máximos estabelecidos:  $\left(\frac{5}{7}\right)$  para  $t_{C_{x_{\min}}}$  e para  $t_{C_{y_{\min}}}$ ;  $\left(\frac{7}{5}\right)$  para  $t_{C_{x_{\max}}}$  e para  $t_{C_{y_{\max}}}$ ;  $\left(\frac{25}{49}\right)$

para  $t_{Sapr_{\min}}$  e  $\left(\frac{49}{25}\right)$  para  $t_{Sapr_{\max}}$ . Para o segundo caso, estabelece-se (mínimo e máximo):  $\left(\frac{1}{\sqrt{1,5}}\right)$  para  $t_{C_{x_{\min}}}$  e para  $t_{C_{y_{\min}}}$ ;  $\sqrt{1,5}$  para  $t_{C_{x_{\max}}}$  e para  $t_{C_{y_{\max}}}$ ;  $\left(\frac{1}{1,5}\right)$  para  $t_{Sapr_{\min}}$  e 1,5 para  $t_{Sapr_{\max}}$ . Os valores mínimos e máximos estabelecidos para todos os limiares de razão mantêm relação inversa devido à comutatividade entre os pares de árvores, no caso:  $(V_i, V_j) = (V_j, V_i)$ .

Definidas as condições geométricas de proximidade e semelhança para a agregação, o QUADRO 9 resume todos os limiares estabelecidos, agrupados em dez conjuntos (A, B, C, D, E, F, G, H, I, J).

QUADRO 9 - RESUMO DOS LIMIARES ESTABELECIDOS PARA A AGREGAÇÃO 3D

|                       |   | Proximidade                     | Semelhança       |                |                            |                    |                            |                    |                            |                      |
|-----------------------|---|---------------------------------|------------------|----------------|----------------------------|--------------------|----------------------------|--------------------|----------------------------|----------------------|
|                       |   | Distância horizontal euclidiana | Razão de alturas |                | Razão de comprimentos em X |                    | Razão de comprimentos em Y |                    | Razão de áreas aproximadas |                      |
|                       |   |                                 |                  |                |                            |                    |                            |                    |                            |                      |
|                       |   | $t_d$ (metros)                  | $t_{h_{\min}}$   | $t_{h_{\max}}$ | $t_{C_{x_{\min}}}$         | $t_{C_{x_{\max}}}$ | $t_{C_{y_{\min}}}$         | $t_{C_{y_{\max}}}$ | $t_{S_{apr_{\min}}}$       | $t_{S_{apr_{\max}}}$ |
| Conjuntos de limiares | A | 35                              | $\frac{5}{6}$    | $\frac{6}{5}$  | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{25}{49}$            | $\frac{49}{25}$      |
|                       | B |                                 |                  |                | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{1,5}$            | 1,5                  |
|                       | C | 30                              |                  |                | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{25}{49}$            | $\frac{49}{25}$      |
|                       | D |                                 |                  |                | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{1,5}$            | 1,5                  |
|                       | E | 25                              |                  |                | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{25}{49}$            | $\frac{49}{25}$      |
|                       | F |                                 |                  |                | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{1,5}$            | 1,5                  |
|                       | G | 20                              |                  |                | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{25}{49}$            | $\frac{49}{25}$      |
|                       | H |                                 |                  |                | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{1,5}$            | 1,5                  |
|                       | I | 15                              |                  |                | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{5}{7}$              | $\frac{7}{5}$      | $\frac{25}{49}$            | $\frac{49}{25}$      |
|                       | J |                                 |                  |                | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{\sqrt{1,5}}$     | $\sqrt{1,5}$       | $\frac{1}{1,5}$            | 1,5                  |

FONTE: O autor (2022)

A operação de agregação 3D foi realizada a partir do *SpatialPointsDataFrame* contendo os atributos estruturais extraídos para cada  $n$ -árvore delimitada na segmentação, tratado como uma matriz de  $n$ -linhas por 14 colunas. Com auxílio de comandos na linguagem *R*, primeiramente foram calculadas as distâncias para todos os  $\frac{n!}{2!(n-2)!}$  pares de árvores e, na sequência, a análise dos limiares de altura, comprimento e área aproximada para aqueles pares que atendem às condições de proximidade.

Para cada um dos conjuntos de limiares estabelecidos foi gerado um novo *SpatialPointsDataFrame*, em que as linhas correspondem às árvores resultantes da agregação 3D, compostas por árvores mescladas e por árvores não-agregadas (que não atenderam aos critérios estabelecidos de agregação) e as colunas são os atributos recalculados de acordo com as equações (54), (55), (56) e (57) mostradas.


Ao término da operação de agregação 3D, obtém-se novos ID's para as árvores mescladas, mantendo-se os mesmos ID's para as árvores não-agregadas. A nuvem *R* segmentada, a partir da qual foram extraídos os atributos das árvores, é atualizada da seguinte forma: os pontos das árvores não-agregadas têm mantidos seus ID's, ao passo que os pontos das árvores mescladas têm seus ID's substituídos pelos pares ordenados referentes aos ID's das árvores originais componentes da mescla.

Como resultado final, são então obtidos dez novos arquivos *.LAS* contendo diferentes atualizações (por ID) da nuvem *R*, sendo mantida sua quantidade de pontos.

#### 3.4.3.2 Simplificação 3D

Para esta operação, são aplicadas em cada uma das nuvens de pontos resultantes da agregação 3D duas técnicas de compressão de nuvens de pontos: partição espacial por *octree* e aprendizado profundo não-supervisionado (FIGURA 43).

FIGURA 43 – VISÃO GERAL DA SIMPLIFICAÇÃO 3D




FONTE: O autor (2022)

Nas subseções a seguir são detalhados os dois tipos de compressão empregados para a simplificação 3D das árvores delimitadas (mescladas e não-agregadas) em cada uma das nuvens resultantes da agregação 3D.

#### 3.4.3.2.1 Partição espacial por *octree*

Para a compressão por *octree* das nuvens de pontos, foi utilizada a função *Subsample* do software *CloudCompare*, que permite extrair subconjuntos da nuvem original. O funcionamento dessa compressão ocorreu conforme mostrado na FIGURA 44.

FIGURA 44 – PARTIÇÃO ESPACIAL POR OCTREE



FONTE: ANDRADE E SILVA; SANTOS (2022)

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 gerado um tamanho mínimo de célula ( $E_R$ ) desejado. Quanto maior o nível de decomposição ( $Q$ ), menores são as células resultantes, e, conseqüentemente, mais pontos serão armazenados. Estabelece-se assim uma proporcionalidade inversa entre  $Q$  e  $E_R$ , e direta entre  $Q$  e a quantidade de pontos armazenados.

Ao longo do particionamento recursivo, todas as subdivisões têm um mesmo volume em cada nível  $Q$  de profundidade, de modo que todos os nós “pais” são divididos em oito nós “filhos” idênticos. Células vazias (sem pontos em seu interior) não devem ser subdivididas.

Ao final da partição, somente o ponto mais próximo do centro de cada célula ( $x_m, y_m, z_m$ ) é armazenado, sendo mantido o seu vetor de atributos, diferentemente do que ocorreria com a função *Resample* do mesmo software, onde haveria o cômputo de novas coordenadas ( $x_E, y_E, z_E$ ) e, conseqüentemente, a alteração dos vetores de atributos.

Foram definidos para a partição por *octree* empregada nesta pesquisa dois diferentes níveis de profundidade ( $Q$ ) compatíveis com os valores de dimensões


mínimas de voxels (0,5 m e 1 m) mostrados no trabalho de Andrade e Silva; Santos (2022): 9 e 10. Tais tamanhos são adequados à densidade de pontos apresentada pelos dados LiDAR utilizados.

#### 3.4.3.2.2 Aprendizado profundo não-supervisionado (*autoencoder*)

Desenvolvida por Wiesmann et al. (2021), a arquitetura profunda DePoCo (*Deep Point Map Compression*) foi escolhida devido à sua eficiência para gerar representações compactas de dados LiDAR de ambientes externos sem que haja significativa perda de informação. O aprendizado de representação ocorreu de maneira “ponta a ponta”, diretamente nas nuvens de pontos de entrada  $U = \{u_1, u_2, \dots, u_n\}$  que contêm as árvores resultantes da agregação 3D, usando um bloco profundo de camadas convolucionais (*encoder*) chamadas por Thomas et al. (2019) de KPConvs (*Kernel Points Convolutional*).

A ideia geral foi aprender pequenos conjuntos de descritores geométricos locais  $F = \{f_1, f_2, \dots, f_d\}$  para cada um dos pontos, explorando estruturas recorrentes na nuvem. Aprendidos esses descritores, que são representações reduzidas (menor dimensionalidade) dos atributos extraídos dos pontos, pôde-se reconstruir as nuvens de pontos por deconvolução (*decoder*), descomprimindo-as por meio de *multilayer perceptrons* (MLP) para duas diferentes densidades ( $\mu$ ) compatíveis com valores de  $Q$  definidos na partição espacial por *octree* (conforme seção 3.4.3.2.1), objetivando um mínimo possível de perda de informação, como mostra a FIGURA 45.


FIGURA 45 – VISÃO GERAL DA ARQUITETURA AUTOENCODER (DEPOCO)



FONTE: O autor (2022)

Em cada camada do bloco *encoder*, a redução da densidade da nuvem de pontos é feita por uma subamostragem baseada em voxels, sendo mantido o ponto mais próximo do seu centro. Tal estratégia também emprega uma *octree* e fornece uma distribuição homogênea de pontos, sem perder informação em áreas mais esparsas. Tem-se assim um tipo de regularização que permite a aplicação dos *Kernel* convolucionais 3D (FIGURA 46).

FIGURA 46 - *KERNEL* CONVOLUCIONAL 3D APLICADO



FONTE: O autor (2022)

A convolução de  $F$  para um ponto  $u$  com um *kernel* (núcleo) convolucional  $g$  é definida como uma soma ponderada de suas características vizinhas e é expressada matematicamente pela equação (58).

$$(F * g)(u) = \sum_{(u_i, f_i) \in N} g(u_i - u) f_i \quad (58)$$

onde  $N$  é o conjunto dos  $i$ -vizinhos considerados de  $u$ .

Cada *KPConv* tem 27 ( $3 \times 3$ ) pontos *Kernel* cujos pesos sinápticos  $W_i$  foram definidos a partir da interpolação de pontos da nuvem  $U$  usando *splines* de primeira ordem, para definir uma aproximação inicial do comportamento da distribuição dos pontos pertencentes ao conjunto de dados.

A última camada do bloco *encoder* é composta por um MLP que compacta os descritores para uma dimensão desejada.

Na deconvolução, os atributos foram integrados e propagados por quatro camadas MLP, de modo que para cada ponto foram encontrados  $K$  novos pontos que

compuseram sua vizinhança. Matematicamente, a deconvolução é uma função  $\phi_k$  que objetiva o aumento de densidade de pontos para um valor  $\mu$  desejado, segundo as equações (59) e (60).

$$u_i^k = u_i + r \cdot \Delta_k(f_i) \quad (59)$$

$$f_i^k = \phi_k(f_i) \quad (60)$$

onde:

$\Delta_k$  indica um bloco de multicamadas ocultas de ativação;

$r$  é o raio da nova vizinhança responsáveis por definir filtros de aprendizado de um conjunto de pontos.

Ao comparar a reconstrução com a nuvem de pontos original, a rede aprende parâmetros de maneira auto-supervisionada, por retropropagação (*backpropagation*), sendo calculada uma função de erro (L) com base em uma medida de similaridade: a distância quadrada média ( $\bar{D}$ ) de cada ponto e seus vizinhos mais próximos (DOVRAT et al., 2019), estimada segundo as equações (61) e (62).

$$\bar{D}(U, U_{out}) = \frac{d^2(U, U_{out})}{2} + \frac{d^2(U_{out}, U)}{2} \quad (61)$$

$$d^2(U, U_{out}) = \frac{1}{|U|} \sum_{u_i \in U_{out}} \min_{u_j \in U_{out}} \|u_i - u_j\|_2^2 \quad (62)$$

onde:

$U$  é a nuvem de pontos de entrada;

$U_{out}$  é a nuvem de pontos de saída simplificada (resultante do *decoder*).

Essa formulação permite que a rede analise as distâncias entre os vizinhos e possibilite encontrar uma solução otimizada, minimizando a função L expressada na equação (63).

$$L = \bar{D}(U, U_{out}) + \beta \sum_j \bar{D}(U, U_{out}) \quad (63)$$

Em que  $\beta$  é uma constante estimada para regularização da simplificação, sendo recomendado por Wiesmann et al. (2021) o valor de 0,2.

A realização dessa etapa foi feita seguindo as explicações e recomendações contidas em: <https://github.com/PRBonn/deep-point-map-compression>, tendo sido alterados os parâmetros de acordo com esta pesquisa. Uma vez que a arquitetura *DePoCo* também emprega uma *octree*, pode-se avaliar a influência da convolução nos resultados obtidos para a compressão.

## 4 RESULTADOS E DISCUSSÕES


Neste capítulo são apresentados, analisados e discutidos os resultados obtidos com os experimentos realizados na pesquisa, que foram organizados por área de estudo/tipo de dados LiDAR. Na parte final do capítulo é estabelecido um comparativo a fim de se avaliar a influência da área de estudo e da amostragem da varredura laser na construção dos modelos 3D generalizados.

### 4.1 EXPERIMENTOS COM DADOS ALS (ÁREA DE ESTUDO 1)

#### 4.1.1 Filtragem

Os resultados obtidos nas duas filtrações realizadas (SOR e CSF) para os dados ALS são mostrados na FIGURA 47.

FIGURA 47 - RESULTADO DAS FILTRAGENS PARA OS DADOS ALS: (A) SOR; (B) CSF



FONTE: O autor (2022)

Conforme se observa na TABELA 1, ao término das duas filtrações (SOR + CSF) houve uma redução total de 48,51% (1.241.452 pontos) em relação à nuvem ALS original, sendo obtida uma nuvem filtrada com remanescentes 1.317.397 pontos não-terreno.

TABELA 1 - REDUÇÃO DA QUANTIDADE DE PONTOS: NUVEM ALS ORIGINAL X NUVEM ALS FILTRADA (SOR + CSF)

| Nuvem de pontos      | Quantidade de pontos | Porcentagem em relação aos dados originais |
|----------------------|----------------------|--------------------------------------------|
| Original             | 2.558.849            | 100%                                       |
| Pontos espúrios      | 226.794              | 8,86%                                      |
| Pontos de terreno    | 1.014.658            | 39,65%                                     |
| Filtrada (SOR + CSF) | 1.317.397            | 51,49%                                     |

FONTE: O autor (2022)

A significativa redução da quantidade de pontos pela filtragem CSF realizada (aproximadamente 40%) é satisfatória para o cenário urbano estudado, pois está em conformidade com a existência de feições sem dimensões verticais tais como arruamentos, terrenos com solo exposto, campos gramados, etc.

#### 4.1.2 Delimitação das árvores

São apresentados nesta seção os resultados obtidos com a sequência de procedimentos realizados para a delimitação automáticas das árvores de interesse nos dados ALS.


##### 4.1.2.1 Classificação e refinamento dos pontos não-terreno

Após a realização das duas filtragens (SOR e CSF) e antes do procedimento de classificação dos pontos não-terreno, também foram eliminados, com auxílio da rotina *lasheight*, 296.325 pontos de altura inferior a 5 metros e superior a 30 metros (11,58% da nuvem de pontos ALS original), restando 1.021.072 pontos (correspondente a 77,51% da nuvem filtrada SOR + CSF e a 39,90% da nuvem original).

Os pontos eliminados pela rotina *lasheight* são provavelmente associados a feições naturais e construídas que apresentam pequenas dimensões verticais (jardins, canteiros, calçadas, muros, portões e pequenos arbustos que não seriam rotulados como vegetação média e alta), e também a edifícios altos, já que se considerou haver na paisagem urbana estudada árvores somente com este limite de altura, segundo a descrição da flora da região feita por Roque et al. (2020).

A nuvem de pontos de altimetria relativa entre 5 e 30 metros e o resultado visual de sua classificação inicial são mostrados na FIGURA 48, enquanto a TABELA 2 informa as quantidades de pontos rotulados em cada uma das classes.

FIGURA 48 - (A) NUVEM DE PONTOS ALS COM ALTIMETRIA ENTRE 5 E 30 M; (B) RESULTADO VISUAL DE SUA CLASSIFICAÇÃO INICIAL.



FONTE: O autor (2022)

TABELA 2 - QUANTIDADES DE PONTOS ROTULADOS APÓS A CLASSIFICAÇÃO INICIAL (DADOS ALS)

| Nuvem de pontos                   | Quantidade de pontos | Porcentagem em relação à nuvem classificada |
|-----------------------------------|----------------------|---------------------------------------------|
| Pontos com altura entre 5 e 30 m  | 1.021.072            | 100%                                        |
| Pontos rotulados como Vegetação   | 594.389              | 58,21%                                      |
| Pontos rotulados como Edificações | 415.372              | 40,67%                                      |
| Pontos sem rótulo                 | 11.311               | 1,12%                                       |

FONTE: O autor (2022)

A quantidade maior de pontos inicialmente rotulados como vegetação pode ser justificada por dois fatores: - existência de áreas de vegetação mais densa no complexo militar localizado na região; - o fato do algoritmo de classificação considerar como vegetação quaisquer pontos cujas planaridades não sejam suficientes para serem rotulados como edificações, desde que o espalhamento volumétrico estimado esteja dentro de um limite aceitável para vegetação.

Já a pequena quantidade de pontos sem rótulos (cerca de 1%) pode ser justificada pelo fato de que esses pontos não apresentam valores de planaridade e espalhamento volumétrico suficientes para serem rotulados como edificações ou vegetação.

Após a análise e o refinamento da classificação pelos critérios RGB e máximo local, tem-se o resultado final da rotulação dos pontos ALS, que serve como referência para a avaliação da acurácia da classificação inicial realizada pelo *lastools*, com base em sua matriz de confusão correspondente (TABELA 3).

TABELA 3 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO DA NUVEM DE PONTOS ALS

|               |                                                       | Verdade Referência |                                                       | Total            |
|---------------|-------------------------------------------------------|--------------------|-------------------------------------------------------|------------------|
|               |                                                       | Vegetação          | Não-vegetação<br>(Edificações +<br>sem classificação) |                  |
| Classificação | Vegetação                                             | 500.164 pontos     | 94.225 pontos                                         | 594.389 pontos   |
|               | Não-vegetação<br>(Edificações + sem<br>classificação) | 18.569 pontos      | 408.114 pontos                                        | 426.683 pontos   |
|               | Total                                                 | 518.733 pontos     | 502.339 pontos                                        | 1.021.072 pontos |


FONTE: O autor (2022)

Pela matriz de confusão obtida, estima-se que a classificação inicial dos dados ALS teve uma acurácia global de 88,95% (908.278 pontos rotulados corretamente/1.021.072 pontos rotulados).

O refinamento da classificação implicou uma diminuição da diferença entre as quantidades de pontos inicialmente rotulados como vegetação e edificações (de 179.017 para 16.394), devido à correção dos erros de inclusão (15,85%) e de omissão (3,57%) para a classe vegetação, tornando assim o resultado quantitativamente menos desigual entre as duas classes consideradas.

A FIGURA 49 mostra todos os 518.733 pontos de vegetação resultantes do refinamento (500.164 pontos verdadeiros positivos e 18.569 pontos falsos negativos), em comparação visual à classificação inicial.

FIGURA 49 – PONTOS DE VEGETAÇÃO ROTULADOS NOS DADOS ALS: (A) CLASSIFICAÇÃO INICIAL; (B) CLASSIFICAÇÃO REFINADA.



FONTE: O autor (2022)

Como o interesse é na classe de vegetação, os verdadeiros negativos e os falsos positivos não foram considerados para as etapas metodológicas seguintes.

#### 4.1.2.2 Segmentação das copas e extração dos atributos métricos das árvores

Realizada a segmentação das copas nos dados ALS, obteve-se a delimitação das árvores de interesse para as etapas seguintes. Porém, foram observados valores inconsistentes (nulos) de altura relativa, comprimentos e área aproximada de copas de árvores de 4 objetos delimitados, sendo estes, na verdade, pontos que não atenderam aos critérios de espaçamento definidos para o algoritmo de segmentação empregado.

Após a devida remoção desses 4 objetos nulos, resultaram para a área de estudo 1 (extensão total de 0,297 km<sup>2</sup>) 851 árvores delimitadas, sendo obtida uma densidade espacial de 28,65 árvores/hectare. O resultado visual da segmentação obtida é visualizado (em cores por ID de cada árvore) na FIGURA 50, enquanto a FIGURA 51 mostra por meio de uma tabela (*SpatialPointsDataFrame*) gerada no software *R* os treze atributos métricos extraídos das 851 árvores delimitadas, usados para o cálculo das medidas-Gestalt exploradas na agregação 3D.

FIGURA 50 - RESULTADO VISUAL DA SEGMENTAÇÃO DE ÁRVORES NOS DADOS ALS  
(VISUALIZAÇÃO EM CORES POR ID)



FONTE: O autor (2022)

FIGURA 51 - ATRIBUTOS MÉTRICOS EXTRAÍDOS DAS ÁRVORES DELIMITADAS NOS DADOS ALS  
(VISUALIZAÇÃO EM TABELA)

| IDli | x_max    | y_max   | z_max | x_min    | y_min   | z_min | x_mean   | y_mean  | z_mean    | H <sub>z</sub> | Sap <sub>r</sub> | C <sub>x</sub> | C <sub>y</sub> |
|------|----------|---------|-------|----------|---------|-------|----------|---------|-----------|----------------|------------------|----------------|----------------|
| 1    | 559040.9 | 8563367 | 30.00 | 559021.3 | 8563347 | 11.33 | 559031.4 | 8563357 | 26.217056 | 18.67          | 387.1000         | 19.60          | 19.75          |
| 2    | 559070.9 | 8563376 | 30.00 | 559051.1 | 8563356 | 15.38 | 559061.2 | 8563366 | 26.633629 | 14.62          | 393.8184         | 19.77          | 19.92          |
| 3    | 559053.7 | 8563361 | 30.00 | 559034.9 | 8563344 | 15.43 | 559045.7 | 8563352 | 27.284834 | 14.57          | 321.5988         | 18.84          | 17.07          |
| 4    | 559058.2 | 8563353 | 30.00 | 559039.4 | 8563334 | 15.08 | 559049.2 | 8563342 | 26.506397 | 14.92          | 349.4920         | 18.80          | 18.59          |
| 5    | 559026.0 | 8563362 | 29.91 | 559015.6 | 8563343 | 11.20 | 559020.0 | 8563353 | 21.749115 | 18.71          | 206.2221         | 10.41          | 19.81          |
| 6    | 558795.1 | 8563006 | 29.83 | 558779.6 | 8562993 | 13.62 | 558788.3 | 8562999 | 18.562559 | 16.21          | 203.8605         | 15.55          | 13.11          |
| 7    | 559065.5 | 8563091 | 29.28 | 559047.7 | 8563072 | 5.00  | 559055.9 | 8563083 | 15.263295 | 24.28          | 334.4314         | 17.77          | 18.82          |
| 8    | 559036.0 | 8563024 | 28.99 | 559031.6 | 8563020 | 7.97  | 559033.7 | 8563022 | 12.645464 | 21.02          | 16.4866          | 4.42           | 3.73           |
| 9    | 559015.4 | 8563344 | 28.82 | 558995.6 | 8563326 | 9.09  | 559004.3 | 8563335 | 21.712711 | 19.73          | 348.8097         | 19.83          | 17.59          |
| 10   | 559087.5 | 8563354 | 28.75 | 559067.8 | 8563334 | 16.50 | 559077.7 | 8563344 | 25.255774 | 12.25          | 392.4297         | 19.73          | 19.89          |
| 11   | 559012.8 | 8563419 | 28.70 | 558992.9 | 8563400 | 6.53  | 559003.0 | 8563410 | 15.888345 | 22.17          | 394.4160         | 19.80          | 19.92          |
| 12   | 559077.2 | 8563368 | 28.59 | 559057.5 | 8563349 | 16.02 | 559069.3 | 8563357 | 25.640952 | 12.57          | 377.6592         | 19.68          | 19.19          |
| 13   | 559046.8 | 8563371 | 28.47 | 559033.2 | 8563361 | 15.17 | 559040.7 | 8563366 | 24.253271 | 13.30          | 140.3220         | 13.65          | 10.28          |
| 14   | 559023.7 | 8563045 | 28.39 | 559011.9 | 8563026 | 5.73  | 559018.2 | 8563033 | 10.558997 | 22.66          | 218.9902         | 11.78          | 18.59          |
| 15   | 559060.6 | 8563366 | 28.38 | 559044.8 | 8563348 | 16.11 | 559053.3 | 8563358 | 25.531864 | 12.27          | 271.2582         | 15.78          | 17.19          |
| 16   | 559024.7 | 8563355 | 28.34 | 559004.7 | 8563335 | 19.64 | 559013.2 | 8563345 | 24.351403 | 8.70           | 392.2108         | 19.97          | 19.64          |
| 17   | 559032.4 | 8563062 | 28.28 | 559020.7 | 8563053 | 7.38  | 559028.4 | 8563056 | 21.247255 | 20.90          | 96.7284          | 11.64          | 8.31           |
| 18   | 559037.9 | 8563348 | 28.08 | 559022.8 | 8563336 | 12.44 | 559030.2 | 8563342 | 24.947394 | 15.64          | 175.8804         | 15.11          | 11.64          |
| 19   | 559068.4 | 8563348 | 28.07 | 559053.9 | 8563333 | 21.08 | 559061.5 | 8563341 | 24.890930 | 6.99           | 217.3644         | 14.52          | 14.97          |
| 20   | 559016.7 | 8563399 | 27.96 | 559001.2 | 8563385 | 13.45 | 559009.1 | 8563393 | 18.360989 | 14.51          | 208.7440         | 15.52          | 13.45          |
| 21   | 558997.2 | 8563062 | 27.84 | 558978.5 | 8563042 | 5.33  | 558986.6 | 8563053 | 14.352384 | 22.51          | 369.8640         | 18.68          | 19.80          |
| 22   | 559088.2 | 8563340 | 27.81 | 559068.4 | 8563324 | 15.01 | 559078.6 | 8563331 | 24.243263 | 12.80          | 307.9324         | 19.79          | 15.56          |
| 23   | 559000.4 | 8563380 | 27.81 | 558970.5 | 8563360 | 8.34  | 559009.0 | 8563370 | 18.057471 | 10.47          | 205.4123         | 10.88          | 10.80          |

1 to 23 of 851 entries, 14 total columns

FONTE: O autor (2022)

A partir do resultado quantitativo da delimitação das árvores (AD), foi possível calcular, além da densidade espacial de árvores (DA), o grau de fragmentação (GF) e o grau de dispersão (GD) do conjunto de árvores segmentadas, com base na extensão da área verde obtida e na média dos afastamentos entre pares de árvores adjacentes. Tais métricas calculadas são mostradas na TABELA 4.

TABELA 4 - MÉTRICAS DA PAISAGEM CALCULADAS ANTES DA GENERALIZAÇÃO 3D PARA OS DADOS ALS

| AD  | Extensão total da área (hectare) | Extensão da área verde (hectare) | DA (árvores/hectare) | GF (árvores/hectare de área verde) | GD (metros) |
|-----|----------------------------------|----------------------------------|----------------------|------------------------------------|-------------|
| 851 | 29,70                            | 12,64                            | 28,65                | 67,33                              | 9,73        |

FONTE: O autor (2022)

Esses valores são usados para fins de comparação com os resultados obtidos após a agregação 3D das árvores.

#### 4.1.3 Generalização 3D

São apresentados nesta seção os resultados obtidos com a aplicação dos dois operadores de generalização 3D nas árvores de interesse delimitadas nos dados ALS.

##### 4.1.3.1 Agregação 3D

Realizada a operação de agregação 3D para as 851 árvores delimitadas (AD) nos dados ALS, considerando-se os dez conjuntos de limiares estabelecidos no QUADRO 9, foram obtidos os seguintes quantitativos:

- número de pares de árvores próximas (PAP);
- número de pares de árvores próximas similares por altura (PAPH);
- número de pares de árvores próximas similares por altura e por área de copa (PAPHS), e sua porcentagem em relação ao número de pares de árvores próximas;
- número de árvores agregadas (AA), que representa a quantidade de árvores que satisfizeram às condições de agregação;
- número de árvores não-agregadas (ANA), e sua porcentagem em relação ao total de árvores delimitadas;

- número de árvores mescladas (AM), que representa a quantidade de árvores formadas por agregação;
- número de árvores resultantes da agregação (AR), composto pela soma do número de árvores não-agregadas (ANA) e do número de árvores mescladas (AM);
- redução do número de árvores (RNA), correspondente ao percentual representado pela diferença entre a unidade e a razão do número de árvores resultantes da agregação (AR) pelo número de árvores delimitadas (AD).

Tais quantitativos são apresentados, para cada um dos dez conjuntos de limiares estabelecidos, na TABELA 5:

TABELA 5 – RESUMO QUANTITATIVO DA AGREGAÇÃO DAS 851 ÁRVORES DELIMITADAS NOS DADOS ALS (POR CONJUNTO DE LIMIARES)

| Conjunto de limiares | PAP   | PAPH  | PAPHS<br>(% em relação a PAP) | AA<br>(% em relação a AD) | ANA<br>(% em relação a AD) | AM  | AR  | RNA   |
|----------------------|-------|-------|-------------------------------|---------------------------|----------------------------|-----|-----|-------|
| A                    | 7.479 | 1.701 | 649<br>(8,67%)                | 420<br>(49,36%)           | 431<br>(50,64%)            | 382 | 813 | 4,46% |
| B                    | 7.479 | 1.701 | 320<br>(4,27%)                | 297<br>(34,91%)           | 554<br>(65,09%)            | 271 | 825 | 3,05% |
| C                    | 5.666 | 1.307 | 507<br>(8,94%)                | 394<br>(46,30%)           | 457<br>(53,70%)            | 354 | 811 | 4,70% |
| D                    | 5.666 | 1.307 | 249<br>(4,39%)                | 271<br>(31,85%)           | 580<br>(68,15%)            | 249 | 829 | 2,58% |
| E                    | 4.031 | 951   | 354<br>(8,78%)                | 355<br>(41,72%)           | 496<br>(58,28%)            | 284 | 780 | 8,34% |
| F                    | 4.031 | 951   | 175<br>(4,34%)                | 226<br>(26,56%)           | 625<br>(73,44%)            | 175 | 800 | 5,99% |
| G                    | 2.603 | 654   | 240<br>(9,22%)                | 299<br>(35,14%)           | 552<br>(64,86%)            | 240 | 792 | 6,93% |
| H                    | 2.603 | 654   | 128<br>(4,91%)                | 181<br>(21,27%)           | 670<br>(78,73%)            | 118 | 788 | 7,40% |
| I                    | 1.526 | 394   | 142<br>(9,30%)                | 226<br>(26,56%)           | 625<br>(73,44%)            | 142 | 767 | 9,87% |
| J                    | 1.526 | 394   | 69<br>(4,52%)                 | 129<br>(15,16%)           | 722<br>(84,84%)            | 69  | 791 | 7,05% |

FONTE: O autor (2022)


No geral, observa-se que à medida em que diminui o limiar de proximidade (sentido do conjunto A para o J), diminui também o número de pares de árvores consideradas próximas (PAP). Comparando-se os conjuntos que apresentam o mesmo limiar de proximidade (A e B; C e D; E e F; G e H; I e J), o número de pares próximos e similares (PAPHS) também diminui em decorrência de uma diminuição do

limiar superior de tamanho relativo de área aproximada, que foi definido segundo o critério de Wang et al. (2015).

Constata-se assim que a diminuição simultânea dos limiares de proximidade e de tamanho relativo implicou o decréscimo do número de árvores mescladas e consequentemente o aumento do número de árvores não-agregadas, como se pode verificar para o conjunto limitante J, que apresentou o maior número de ANA e o menor de AM dentre todos os dez conjuntos de limiares; fato este que sugere ser o referido conjunto como o de menor tendência à generalização por agregação 3D.

Porém, isso não se confirma, pois a ocorrência do maior número de AR e consequentemente da menor RNA estão associada ao conjunto D, conforme se observa no GRÁFICO 1, que mostra os valores da última coluna da TABELA 5.

GRÁFICO 1 – REDUÇÃO DO NÚMERO DE ÁRVORES POR AGREGAÇÃO 3D (DADOS ALS/ÁREA DE ESTUDO 1)



FONTE: O autor (2022)

O fato do conjunto J não estar associado ao menor percentual de RNA pode ser explicado pelo fato de que mesmo impactando um maior número de árvores não-agregadas, o menor número de árvores mescladas não foi suficiente para garantir um número de árvores resultantes acima da quantidade obtida para o conjunto D, o qual gerou um ANA menor e um AM maior que J.

Pelo GRÁFICO 1, percebe-se que, dentre os dez conjuntos de limiares estabelecidos, o conjunto I foi o que propiciou a maior generalização por agregação

3D, quantificada neste caso por meio do maior valor da RNA, decorrente do menor número de árvores resultantes (mescladas e não-agregadas).

Além da análise da redução do número de árvores, pode-se analisar também como resultado da agregação 3D o impacto da existência de árvores mescladas no grau de fragmentação e de dispersão da área verde total. Na TABELA 6 são mostradas as variações dos graus de fragmentação e de dispersão do conjunto de árvores resultantes calculadas em relação às árvores delimitadas originalmente na nuvem de pontos ALS.

TABELA 6 – RESUMO DAS MÉTRICAS DE PAISAGEM CALCULADAS DEPOIS DA AGREGAÇÃO 3D (DADOS ALS)


| <b>Conjunto de limiares</b> | <b>DA<br/>(árvores/hectare)</b> | <b>GF<br/>(árvores/hectare de área verde)</b> | <b>RF (%)</b> | <b>GD<br/>(metros)</b> | <b>ADA (%)</b> |
|-----------------------------|---------------------------------|-----------------------------------------------|---------------|------------------------|----------------|
| A                           | 27,37                           | 64,31                                         | 4,46          | 12,56                  | 29,09          |
| B                           | 27,77                           | 65,26                                         | 3,05          | 13,37                  | 37,41          |
| C                           | 27,30                           | 64,16                                         | 4,70          | 14,48                  | 48,81          |
| D                           | 27,91                           | 65,58                                         | 2,58          | 13,94                  | 43,26          |
| E                           | 26,26                           | 61,70                                         | 8,34          | 14,17                  | 45,63          |
| F                           | 26,93                           | 63,29                                         | 5,99          | 14,11                  | 45,01          |
| G                           | 26,66                           | 62,65                                         | 6,93          | 14,64                  | 50,46          |
| H                           | 26,53                           | 62,34                                         | 7,40          | 14,12                  | 45,11          |
| I                           | 25,82                           | 60,68                                         | 9,87          | 14,81                  | 52,20          |
| J                           | 26,63                           | 62,57                                         | 7,05          | 14,07                  | 44,60          |

FONTE: O autor (2022)

Conforme o esperado, os valores dos percentuais de redução de fragmentação são significativamente iguais aos valores dos percentuais de redução do número de árvores mostrados anteriormente na TABELA 5, já que ambos os índices são calculados em função do número de árvores resultantes da agregação 3D e do número de árvores delimitadas originalmente, que permanecem inalterados no referido cálculo.


Nos GRÁFICOS 2 e 3 são mostrados os percentuais de redução do grau de fragmentação e do grau de dispersão dos conjuntos de árvores resultantes da agregação 3D.

GRÁFICO 2 - REDUÇÃO DO GRAU DE FRAGMENTAÇÃO DO CONJUNTO DE ÁRVORES POR AGREGAÇÃO 3D (DADOS ALS/ÁREA DE ESTUDO 1)



FONTE: O autor (2022)

GRÁFICO 3 - DADOS ALS (ÁREA DE ESTUDO 1): AUMENTO DO GRAU DE DISPERSÃO DO CONJUNTO DE ÁRVORES (ADA) POR AGREGAÇÃO 3D



FONTE: O autor (2022)

Comparando-se os dois gráficos, nota-se que os maiores valores dos dois índices calculados estão associados ao mesmo conjunto (I), e que, excetuando-se o conjunto B, há uma relação direta entre os valores de RF e de ADA obtidos, ou seja, reduzida a fragmentação do conjunto de árvores, estas ficaram mais dispersas pois aumentou o afastamento próximo médio entre elas.

No caso do conjunto B, a redução de fragmentação obtida foi menor do que para o conjunto A, sendo esperado também um menor valor de redução da dispersão. Porém, foi obtido para B um valor de ADA maior do que para A.

Nota-se também que os menores valores obtidos para RF e ADA não estão associados ao mesmo conjunto, sendo o conjunto D o que gerou a menor RF e o conjunto A o maior ADA.

#### 4.1.3.2 Simplificação 3D

Nesta seção são mostrados os resultados obtidos com as duas técnicas de compressão de nuvens de pontos empregadas para os dados ALS.

##### 4.1.3.2.1 Partição espacial por *octree*

Realizada a compressão por *octree*, obteve-se, para todas as nuvens de pontos resultantes da agregação 3D, a mesma redução da quantidade de pontos, considerando-se um mesmo número de subdivisões *Q*. Quanto ao espaço de armazenamento computacional, sua redução também foi significativamente igual para todas as nuvens, já que estas se diferenciam apenas quanto aos ID's atualizados.


A fim de facilitar a análise dos resultados obtidos pelas partições por *octree*, na TABELA 7 e na FIGURA 52 são comparados quantitativamente e visualmente, para uma das nuvens de pontos resultante da agregação 3D (considerando o conjunto de limiares A), os resultados obtidos após nove e dez subdivisões.

TABELA 7 - COMPARATIVO DE REDUÇÃO DO ESPAÇO DE ARMAZENAMENTO E DA QUANTIDADE DE PONTOS PELA COMPRESSÃO DOS DADOS ALS POR *OCTREE*

| Grandeza                                      | Nuvem resultante da agregação 3D (conjunto A) | Compressão por <i>octree</i> |         |
|-----------------------------------------------|-----------------------------------------------|------------------------------|---------|
|                                               |                                               | Q = 9                        | Q = 10  |
| Unidade elementares (pontos)                  | 518.733                                       | 120.790                      | 312.864 |
| Redução do número de pontos (RNP em %)        | -----                                         | 76,71%                       | 39,68%  |
| Espaço de armazenamento (MB)                  | 19,251                                        | 4,995                        | 12,833  |
| Redução do espaço de armazenamento (REA em %) | -----                                         | 74,07%                       | 33,34%  |

FONTE: O autor (2022)

FIGURA 52 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE PONTOS ALS RESULTANTE DA SEGMENTAÇÃO (A) E O RESULTADO DE SUAS COMPRESSÕES POR *OCTREE* COM 10 (B) E 9 SUBDIVISÕES (C)



FONTE: O autor (2022)

Embora sem uma perceptível relação linear entre as reduções do número de pontos e do espaço de armazenamento computacional obtidas, foi verificada uma proporcionalidade inversa entre os percentuais calculados e o número de subdivisões, sendo os maiores valores (76,71% e 74,07%) associados ao menor valor de  $Q$ , no caso nove subdivisões.

Tal observação vai ao encontro do esperado para uma partição por *octree*, pois uma menor quantidade de subdivisões implicou menor número de pontos resultantes da compressão e consequentemente menor espaço de armazenamento computacional requerido, conforme explicado na seção 3.4.3.2.1.

#### 4.1.3.2.1 Aprendizado profundo não-supervisionado (*autoencoder*)

Assim como ocorreu para a compressão por *octree*, foram obtidas após a compressão por aprendizado não-supervisionado a mesma redução da quantidade de pontos para todas as nuvens de pontos resultantes da agregação 3D, considerando-se uma mesma densidade resultante  $\mu$ . Quanto ao espaço de armazenamento computacional, sua redução também foi significativamente igual para todas as nuvens, já que estas se diferenciam apenas quanto aos ID's atualizados.

A fim de facilitar a análise dos resultados obtidos pelo *autoencoder*, na TABELA 8 e na FIGURA 53 são comparados quantitativamente e visualmente, para uma das nuvens de pontos resultante da agregação 3D (considerando o conjunto de


limiares A), os resultados obtidos considerando-se densidades resultantes ( $\mu$ ) de 1 e 2 pontos/m<sup>2</sup>.

TABELA 8 - COMPARATIVO DE REDUÇÃO DE ESPAÇO DE ARMAZENAMENTO E QUANTIDADE DE UNIDADES ELEMENTARES PARA A COMPRESSÃO DOS DADOS ALS POR *AUTOENCODER*

| Grandeza                               | Nuvem resultante da agregação 3D (conjunto A) | Compressão por <i>autoencoder</i> |               |
|----------------------------------------|-----------------------------------------------|-----------------------------------|---------------|
|                                        |                                               | ( $\mu = 2$ )                     | ( $\mu = 1$ ) |
| Unidade elementares (pontos)           | 518.733                                       | 283.624                           | 141.812       |
| Redução do número de pontos (%)        | -----                                         | 45,32%                            | 72,66%        |
| Espaço de armazenamento (MB)           | 19,251                                        | 10,526                            | 5,264         |
| Redução do espaço de armazenamento (%) | -----                                         | 45,32%                            | 72,65%        |

Fonte: O autor (2022)

FIGURA 53 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE PONTOS ALS RESULTANTE DA SEGMENTAÇÃO (A) E O RESULTADO DE SUAS COMPRESSÕES POR *AUTOENCODER* COM DENSIDADE DE 2 (B) E 1 PONTO/M<sup>2</sup> (C)



FONTE: O autor (2022)

Diferentemente do que foi observado para a partição por *octree*, houve uma relação linear entre as reduções do número de pontos e do espaço de armazenamento computacional obtidas. Foi verificada também uma proporcionalidade inversa entre os percentuais calculados e a densidade de pontos da nuvem simplificada, sendo os maiores valores (72,66% e 72,65%) associados ao menor valor de  $\mu$ , no caso igual a 1.

Tal observação vai ao encontro do esperado para o *autoencoder*, pois uma menor densidade de pontos previamente definida implicou menor número de pontos resultantes da compressão e consequentemente menor espaço de armazenamento computacional requerido, conforme explicado na seção 3.4.3.2.2.

#### 4.1.4 Avaliação final dos resultados

Além da análise da redução do espaço de armazenamento computacional decorrente da diminuição da densidade de pontos pelas duas técnicas de compressão de nuvens de pontos empregadas, e também do comparativo entre as métricas de paisagem (fragmentação e dispersão) calculadas antes e depois da operação de agregação 3D, a avaliação final do desempenho do método desenvolvido para generalizar as árvores delimitadas a partir dos dados ALS pôde ser feita com base na correspondência com a cena 3D original.

Para tal, comparou-se os atributos estruturais das árvores generalizadas (resultantes das operações de agregação e simplificação) com as árvores originais delimitadas, considerando-se os dez conjuntos de limiares. Ressalta-se que para o cálculo de  $\Delta P_{c_i}$ ,  $\Delta h_{V_i}$  e  $\Delta S_{ap}$  mostrados na TABELA 9 foi novamente utilizada a função *tree\_metrics*, sendo utilizadas as nuvens de pontos atualizadas pelos ID resultantes da agregação, que foram salvas em arquivos .LAS, para fins de compatibilidade com o módulo *PointCloud* do padrão *CityGML 3.0*.

TABELA 9 – CORRESPONDÊNCIA DAS ÁRVORES GENERALIZADAS COM A CENA 3D ORIGINAL (DADOS ALS)

| Indicadores avaliados              |        |        | Conjunto de limiares |       |       |       |       |       |       |       |       |       |
|------------------------------------|--------|--------|----------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|                                    |        |        | A                    | B     | C     | D     | E     | F     | G     | H     | I     | J     |
| $\overline{\Delta P_{c_i}}$<br>(m) | Octree | Q = 9  | 0,31                 | 0,32  |       | 0,33  |       |       |       |       | 0,34  |       |
|                                    |        | Q = 10 | 0,14                 | 0,15  |       |       |       |       |       |       |       |       |
|                                    | DePoCo | μ = 1  | 0,37                 | 0,35  | 0,37  | 0,35  | 0,36  | 0,35  | 0,36  | 0,34  |       | 0,32  |
|                                    |        | μ = 2  | 0,19                 | 0,18  | 0,19  | 0,18  | 0,19  | 0,18  | 0,19  | 0,18  |       |       |
| $\overline{\Delta h_{V_i}}$<br>(m) | Octree | Q = 9  | 0,24                 | 0,23  | 0,24  | 0,23  | 0,24  | 0,23  |       |       | 0,22  |       |
|                                    |        | Q = 10 | 0,08                 | 0,07  |       |       |       |       |       |       |       | 0,06  |
|                                    | DePoCo | μ = 1  | 0,59                 |       | 0,62  | 0,59  | 0,61  | 0,58  | 0,59  |       | 0,57  | 0,59  |
|                                    |        | μ = 2  | 0,28                 | 0,25  | 0,28  | 0,25  | 0,27  | 0,24  | 0,25  |       | 0,24  | 0,25  |
| $\overline{\Delta S_{ap}}$<br>(m²) | Octree | Q = 9  | 5,51                 | 6,50  | 5,54  | 6,56  | 5,80  | 6,95  | 6,28  | 7,22  | 6,87  | 7,53  |
|                                    |        | Q = 10 | 1,27                 | 1,48  | 1,29  | 1,52  | 1,33  | 1,58  | 1,46  | 1,61  | 1,68  | 1,79  |
|                                    | DePoCo | μ = 1  | 9,58                 | 10,20 | 10,01 | 10,37 | 10,07 | 10,52 | 10,19 | 10,63 | 10,70 | 10,83 |
|                                    |        | μ = 2  | 3,63                 | 3,71  | 3,63  | 3,76  | 3,78  | 3,92  | 3,90  | 3,99  | 4,15  | 4,08  |
| $S_{total}$<br>(hect)              | Octree | Q = 9  | 11,95                |       |       |       |       |       |       |       |       |       |
|                                    |        | Q = 10 | 12,48                |       |       |       |       |       |       |       |       |       |
|                                    | DePoCo | μ = 1  | 11,71                |       |       |       |       |       |       |       |       |       |
|                                    |        | μ = 2  | 12,29                |       |       |       |       |       |       |       |       |       |
| RV<br>(%)                          | Octree | Q = 9  | 5,45                 |       |       |       |       |       |       |       |       |       |
|                                    |        | Q = 10 | 1,26                 |       |       |       |       |       |       |       |       |       |
|                                    | DePoCo | μ = 1  | 7,35                 |       |       |       |       |       |       |       |       |       |
|                                    |        | μ = 2  | 2,76                 |       |       |       |       |       |       |       |       |       |
| AE                                 | Octree | Q = 9  | 12                   |       |       |       |       |       |       |       |       |       |
|                                    |        | Q = 10 | 4                    |       |       |       |       |       |       |       |       |       |
|                                    | DePoCo | μ = 1  | 30                   |       |       |       |       |       |       |       |       |       |
|                                    |        | μ = 2  | 10                   |       |       |       |       |       |       |       |       |       |
| PA<br>(%)                          | Octree | Q = 9  | 1,48                 | 1,45  | 1,48  | 1,45  | 1,54  | 1,5   | 1,52  | 1,52  | 1,56  | 1,52  |
|                                    |        | Q = 10 | 0,49                 | 0,48  | 0,49  | 0,48  | 0,51  | 0,5   | 0,51  | 0,51  | 0,52  | 0,51  |
|                                    | DePoCo | μ = 1  | 3,69                 | 3,63  | 3,70  | 3,62  | 3,85  | 3,75  | 3,79  | 3,81  | 3,91  | 3,79  |
|                                    |        | μ = 2  | 1,23                 | 1,21  | 1,23  | 1,21  | 1,28  | 1,25  | 1,26  | 1,27  | 1,30  | 1,26  |

FONTE: O autor (2022)

Observa-se para todos os índices calculados que os maiores valores são associados à arquitetura DePoCo, especificamente no caso de  $\mu = 1$ , permitindo constatar que a compressão realizada por aprendizado profundo implicou as maiores variações acerca dos atributos estruturais das árvores bem como o maior número de árvores eliminadas.

Em relação às partições espaciais por *octree*, foram observados maiores valores dos índices calculados para o caso de menor subdivisão ( $Q = 9$ ).

No tocante aos índices RV e AE, todos os conjuntos limiares apresentaram o mesmo valor, já que o diferencial entre as nuvens de pontos resultantes no caso de

uma mesma compressão realizada é apenas em relação aos ID's atualizados pela agregação 3D, sendo mantidas as quantidades de pontos das nuvens.

No caso dos índices  $\Delta P_{ci}$  e  $\Delta h_{Vi}$  todos os valores calculados são inferiores a 1 metro, e os valores de  $\Delta S_{ap}$  são todos inferiores a 50 m<sup>2</sup>. Isso permite atestar que as reduções devidas à generalização 3D não implicaram em suficiente perda de informação que tornasse a representação das árvores resultantes da generalização 3D aplicada aos dados ALS incompatíveis ao LoD 2.

Como resultado final dos experimentos realizados com os dados ALS, foram obtidas dez nuvens de pontos (salvas em arquivos .LAS) contendo as árvores generalizadas, que puderam ser representadas em bancos de dados por geometria *multipoint* e associadas aos seus respectivos ID (*tree\_ID*), como mostra a FIGURA 54 para o caso do conjunto de limiares A.

FIGURA 54 - BANCO DE DADOS PARA ÁRVORES GENERALIZADAS (CONJUNTO A)

|    | treeid<br>integer | numpoints<br>bigint | geom<br>text                                                                                                                                       |
|----|-------------------|---------------------|----------------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | 1                 | 2225                | MULTIPOINT Z (559021.33 8563356.7 19.48,559021.38 8563357.6 16.55,559021.45 8563358.16 4,559021.51 8563358.5 16.24,559021.56 8563359.16 16,55902   |
| 2  | 5                 | 836                 | MULTIPOINT Z (559015.55 8563355.3 22,559015.63 8563355.8 22.33,559015.68 8563355.22 02,559015.71 8563356.4 23,559015.72 8563355.5 22.2,559015.76   |
| 3  | 7                 | 352                 | MULTIPOINT Z (559047.74 8563080.5 15.29,559047.79 8563081.14 69,559048.11 8563082.4 14.59,559048.14 8563081.9 14.85,559048.17 8563081.4 14.89,55   |
| 4  | 8                 | 97                  | MULTIPOINT Z (559031.62 8563021.9 8.13,559031.66 8563022.4 8.12,559031.67 8563023.3 8.12,559031.71 8563022.7 8.14,559031.71 8563022.9 8.13,559031  |
| 5  | 10                | 2475                | MULTIPOINT Z (559067.81 8563343.23 92,559067.84 8563345.9 22.43,559067.85 8563343.6 23.98,559067.86 8563346.25 68,559067.87 8563345.3 22.86,5590   |
| 6  | 11                | 2290                | MULTIPOINT Z (558992.95 8563407.7 18.54,558993.02 8563408.1 18.24,558993.1 8563408.9 20.9,558993.14 8563411.9 17.53,558993.17 8563411.5 17.45,558  |
| 7  | 13                | 590                 | MULTIPOINT Z (559033.19 8563366.8 27.57,559033.69 8563367.27 53,559033.74 8563367.3 26.91,559033.77 8563367.5 26.79,559033.81 8563366.9 27.56,55   |
| 8  | 14                | 289                 | MULTIPOINT Z (559011.87 8563032.9 7.34,559011.88 8563032.2 5.73,559011.9 8563032.5 7.63,559011.93 8563032.7 8.6,559011.95 8563031.8 5.78,559011.96 |
| 9  | 16                | 1568                | MULTIPOINT Z (559004.73 8563344.3 22.36,559004.76 8563344.8 22.75,559004.79 8563343.8 23.56,559004.8 8563345.2 23.12,559004.81 8563345.4 23.75,55  |
| 10 | 17                | 102                 | MULTIPOINT Z (559020.74 8563058.5 19.55,559020.77 8563058.6 19.61,559020.98 8563058.6 19.5,559021.33 8563058.5 19.37,559021.37 8563059.19 4,5590   |
| 11 | 18                | 917                 | MULTIPOINT Z (559022.76 8563338.6 24.1,559022.85 8563338.5 24.16,559022.87 8563338.1 23.65,559023.13 8563338.3 23.67,559023.15 8563338.7 24.17,55  |

FONTE: O autor (2022)


A partir de cada banco de dados criado é possível acessar informações sobre a localização, o porte e a distribuição espacial das árvores urbanas mapeadas, facilitando assim a confecção de inventários que podem ser usados também em outras demandas além da execução de planos municipais de arborização urbana.

## 4.2 EXPERIMENTOS COM DADOS ULS (ÁREA DE ESTUDO 2)

### 4.2.1 Filtragem

Os resultados obtidos nas duas filtragens realizadas (SOR e CSF) para os dados ULS são mostrados na FIGURA 55.

FIGURA 55 - RESULTADO DAS FILTRAGENS PARA OS DADOS ULS: (A) SOR; (B) CSF



FONTE: O autor (2022)

Conforme se observa na TABELA 10, ao término das duas filtragens (SOR + CSF) houve uma redução total de 49,68% (25.742.188 pontos) em relação à nuvem ULS original, sendo obtida uma nuvem filtrada com remanescentes 32.449.630 pontos não-terreno.

TABELA 10 - REDUÇÃO DA QUANTIDADE DE PONTOS: NUVEM ULS ORIGINAL X NUVEM ULS FILTRADA (SOR + CSF)

| Nuvem de pontos      | Quantidade de pontos | Porcentagem em relação aos dados originais |
|----------------------|----------------------|--------------------------------------------|
| Original             | 64.479.165           | 100%                                       |
| Pontos espúrios      | 6.287.347            | 9,75%                                      |
| Pontos de terreno    | 25.742.188           | 39,92%                                     |
| Filtrada (SOR + CSF) | 32.449.630           | 50,32%                                     |

FONTE: O autor (2022)

Assim como foi observado para o experimento realizado com os dados ALS, a significativa redução da quantidade de pontos pela filtragem CSF é satisfatória para a área em questão, considerando sua caracterização estrutural. A existência de feições sem dimensões verticais tais como arruamentos, terrenos com solo exposto, campos gramados e calçadas justifica o percentual de aproximadamente 40% para a eliminação dos pontos de terreno.

#### 4.2.2 Delimitação das árvores

São apresentados nesta seção os resultados obtidos com a sequência de procedimentos realizados para a delimitação automáticas das árvores de interesse nos dados ULS.


##### 4.2.2.1 Classificação e refinamento dos pontos não-terreno

Após a realização das duas filtragens (SOR e CSF) e antes do procedimento de classificação dos pontos não-terreno, também foram eliminados, com auxílio da rotina *lasheight*, 9.790.424 pontos de altura inferior a 5 metros e superior a 30 metros (15,18% da nuvem original), restando 22.659.206 pontos (correspondente a 69,82% da nuvem filtrada SOR + CSF e a 35,14% da nuvem original).

Os pontos eliminados pela rotina *lasheight* são provavelmente associados a feições naturais e construídas que apresentam pequenas dimensões verticais (calçadas, canteiros, calçadas, muros e vegetais de menor porte que não seriam rotulados como vegetação média e alta), e também a alguns edifícios mais altos existentes no campus Politécnico, já que se considerou haver na paisagem urbana em questão apenas árvores (ipês e pinheiros) com este limite de altura.

A nuvem de pontos de altimetria relativa entre 5 e 30 metros e o resultado visual de sua classificação inicial são mostrados na FIGURA 56, enquanto a TABELA 11 informa as quantidades de pontos rotulados em cada uma das classes.

FIGURA 56 - (A) NUVEM DE PONTOS ULS COM ALTURA ENTRE 5 E 30 M; (B) RESULTADO VISUAL DA CLASSIFICAÇÃO.



FONTE: O autor (2022)

TABELA 11 - QUANTIDADES DE PONTOS ROTULADOS APÓS A CLASSIFICAÇÃO INICIAL (DADOS ULS)

| Nuvem de pontos                   | Quantidade de pontos | Porcentagem em relação à nuvem classificada |
|-----------------------------------|----------------------|---------------------------------------------|
| Pontos com altura entre 5 e 30 m  | 22.659.206           | 100%                                        |
| Pontos rotulados como Vegetação   | 7.545.159            | 33,30%                                      |
| Pontos rotulados como Edificações | 14.903.567           | 65,77%                                      |
| Pontos sem rótulo                 | 210.480              | 0,93%                                       |

FONTE: O autor (2022)

A quantidade menor de pontos inicialmente rotulados como vegetação pode ser justificada pela existência apenas de árvores isoladas e/ou pouco concentradas na área de estudo em questão, diferentemente do que ocorre na área de estudo 1. Já a pequena quantidade de pontos sem rótulos (inferior a 1%) pode ser justificada pelo fato de que esses pontos não apresentam valores de planaridade e espalhamento volumétrico suficientes para serem rotulados como edificações ou vegetação.

Após a análise e o refinamento da classificação pelos critérios RGB e máximo local, tem-se o resultado final da rotulação dos pontos ULS, que serve como referência para a avaliação da acurácia da classificação inicial realizada pelo *lastools*, com base em sua matriz de confusão correspondente (TABELA 12).

TABELA 12 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO DA NUVEM DE PONTOS ULS

|               |                                                       | Verdade Referência |                                                       | Total             |
|---------------|-------------------------------------------------------|--------------------|-------------------------------------------------------|-------------------|
|               |                                                       | Vegetação          | Não-vegetação<br>(Edificações +<br>sem classificação) |                   |
| Classificação | Vegetação                                             | 6.455.452 pontos   | 1.089.707 pontos                                      | 7.545.159 pontos  |
|               | Não-vegetação<br>(Edificações + sem<br>classificação) | 169.953 pontos     | 14.944.094 pontos                                     | 15.114.047 pontos |
|               | Total                                                 | 6.625.405 pontos   | 16.083.801 pontos                                     | 22.659.206 pontos |


FONTE: O autor (2022)

Pela matriz de confusão obtida, estima-se que a classificação inicial dos dados ULS teve uma acurácia global de 94,44% (21.399.546 pontos rotulados corretamente/22.659.206 pontos rotulados).

Nota-se que, ao contrário do que foi observado para os dados ALS, o refinamento da classificação implicou um aumento da diferença entre as quantidades de pontos inicialmente rotulados como vegetação e edificações (de 7.568.888 para 9.458.396), apesar da correção dos erros de inclusão (14,44%) e de omissão (2,56%) para a classe vegetação, tornando o resultado quantitativamente ainda mais desigual entre as duas classes consideradas.

A FIGURA 57 mostra todos os 6.625.405 pontos de vegetação resultantes do refinamento (6.455.452 pontos verdadeiros positivos e 169.953 pontos falsos negativos), em comparação visual à classificação inicial.

FIGURA 57 - PONTOS DE VEGETAÇÃO ROTULADOS NOS DADOS ULS: (A) CLASSIFICAÇÃO INICIAL; (B) CLASSIFICAÇÃO REFINADA



FONTE: O autor (2022)

Como o interesse é na classe de vegetação, os verdadeiros negativos e os falsos positivos não foram considerados para as etapas metodológicas seguintes.

#### 4.2.2.2 Segmentação das copas e extração dos atributos métricos das árvores

Realizada a segmentação das copas nos dados ULS, obteve-se a delimitação das árvores de interesse para as etapas seguintes. Contudo, foram observados valores inconsistentes (nulos) de altura relativa, comprimentos e área aproximada de copas de árvores de 2 objetos delimitados, sendo estes, na verdade, pontos que não atenderam aos critérios de espaçamento definidos para o algoritmo de segmentação empregado.

Após a devida remoção desses 2 objetos nulos, resultaram para a área de estudo 2 (extensão total de 0,26 km<sup>2</sup>) 518 árvores delimitadas, sendo obtida uma densidade espacial de 19,9 árvores/hectare. O resultado visual da segmentação obtida é visualizado (em cores por ID de cada árvore) na FIGURA 58 em diferentes cores segundo os ID de cada árvore delimitada, enquanto a FIGURA 59 mostra por meio de uma tabela (*SpatialPointsDataFrame*) gerada no software *R* os treze atributos métricos extraídos das árvores 518 delimitadas, usados para o cálculo das medidas-Gestalt exploradas na agregação 3D.

FIGURA 58 - RESULTADO VISUAL DA SEGMENTAÇÃO DE ÁRVORES NOS DADOS ULS (VISUALIZAÇÃO EM CORES POR ID)



FONTE: O autor (2022)

FIGURA 59 - ATRIBUTOS MÉTRICOS EXTRAÍDOS DAS ÁRVORES DELIMITADAS NOS DADOS ULS (VISUALIZAÇÃO EM TABELA)

|    | IDli | x_max    | y_max   | z_max   | x_min    | y_min   | z_min   | x_mean   | y_mean  | z_mean    | Cx      | Cy      | Hr      | Sapr         |
|----|------|----------|---------|---------|----------|---------|---------|----------|---------|-----------|---------|---------|---------|--------------|
| 1  | 298  | 677730.0 | 7183774 | 10.1716 | 677717.5 | 7183764 | 5.0015  | 677724.7 | 7183771 | 8.746689  | 12.4793 | 9.9049  | 5.1701  | 123.60621858 |
| 2  | 55   | 677703.0 | 7183767 | 17.9414 | 677684.3 | 7183748 | 5.0018  | 677693.0 | 7183755 | 13.728523 | 18.6604 | 18.6771 | 12.9396 | 348.52215684 |
| 3  | 93   | 677713.2 | 7183759 | 15.4069 | 677696.8 | 7183748 | 6.0456  | 677706.3 | 7183752 | 10.080451 | 16.4562 | 10.9649 | 9.3613  | 180.44058738 |
| 4  | 465  | 677694.3 | 7183747 | 6.8738  | 677688.7 | 7183739 | 5.0002  | 677691.8 | 7183743 | 5.778880  | 5.5846  | 7.3779  | 1.8736  | 41.20262034  |
| 5  | 223  | 677726.0 | 7183759 | 11.5894 | 677710.1 | 7183744 | 5.0051  | 677716.9 | 7183749 | 8.425711  | 15.8574 | 14.5863 | 6.5843  | 231.30079361 |
| 6  | 78   | 677682.1 | 7183818 | 16.4372 | 677665.6 | 7183803 | 5.1721  | 677672.8 | 7183809 | 13.942890 | 16.5802 | 14.9033 | 11.2651 | 247.09969467 |
| 7  | 115  | 677670.8 | 7183807 | 14.7432 | 677662.0 | 7183803 | 10.6938 | 677667.2 | 7183804 | 13.490574 | 8.7266  | 3.9557  | 4.0494  | 34.51981163  |
| 8  | 62   | 677674.0 | 7183825 | 17.3145 | 677654.3 | 7183807 | 5.0005  | 677664.6 | 7183815 | 14.468840 | 19.7083 | 18.4845 | 12.3140 | 364.29807135 |
| 9  | 85   | 677709.1 | 7183789 | 16.0163 | 677696.3 | 7183778 | 5.0003  | 677703.5 | 7183784 | 9.757415  | 12.7360 | 10.2474 | 11.0160 | 130.51088641 |
| 10 | 446  | 677697.1 | 7183789 | 7.4188  | 677692.8 | 7183779 | 5.0010  | 677695.8 | 7183784 | 6.221407  | 4.3052  | 9.6482  | 2.4178  | 41.53743064  |
| 11 | 106  | 677696.4 | 7183791 | 14.9008 | 677676.4 | 7183780 | 5.0004  | 677689.8 | 7183786 | 7.405082  | 19.9870 | 11.2171 | 9.9004  | 224.19617770 |
| 12 | 454  | 677611.6 | 7183796 | 7.2185  | 677607.4 | 7183789 | 5.0009  | 677609.9 | 7183793 | 5.822747  | 4.1625  | 7.7038  | 2.2176  | 32.06706750  |
| 13 | 388  | 677608.1 | 7183782 | 8.4926  | 677595.3 | 7183765 | 5.0002  | 677600.6 | 7183775 | 6.511657  | 12.8026 | 17.5928 | 3.4924  | 225.23358128 |
| 14 | 426  | 677612.3 | 7183789 | 7.8021  | 677604.5 | 7183775 | 5.0004  | 677609.0 | 7183781 | 6.415624  | 7.7499  | 14.2200 | 2.8017  | 110.20357801 |
| 15 | 422  | 677626.0 | 7183796 | 7.8759  | 677611.1 | 7183788 | 5.0000  | 677620.3 | 7183792 | 6.237784  | 14.8287 | 7.7705  | 2.8759  | 115.22641336 |
| 16 | 416  | 677637.0 | 7183793 | 7.9775  | 677624.6 | 7183784 | 5.0000  | 677632.3 | 7183788 | 6.517345  | 12.4455 | 8.9477  | 2.9775  | 111.35860034 |
| 17 | 505  | 677624.3 | 7183781 | 5.7170  | 677621.3 | 7183779 | 5.0002  | 677622.5 | 7183780 | 5.279158  | 2.9917  | 1.9206  | 0.7168  | 5.74585902   |
| 18 | 503  | 677622.9 | 7183779 | 5.8013  | 677618.6 | 7183768 | 5.0000  | 677620.5 | 7183770 | 5.243955  | 4.3110  | 11.0611 | 0.8013  | 47.68440210  |
| 19 | 349  | 677637.8 | 7183769 | 9.1350  | 677624.0 | 7183759 | 5.0043  | 677631.2 | 7183764 | 7.251198  | 13.7029 | 9.4517  | 4.1307  | 129.51569993 |
| 20 | 372  | 677643.1 | 7183788 | 8.6975  | 677634.1 | 7183776 | 5.0012  | 677638.4 | 7183781 | 6.508780  | 9.0280  | 11.6536 | 3.6963  | 105.20870080 |
| 21 | 407  | 677649.5 | 7183787 | 8.2121  | 677636.5 | 7183779 | 5.0000  | 677645.7 | 7183781 | 6.612122  | 12.9824 | 8.0816  | 3.2121  | 104.91856384 |
| 22 | 341  | 677696.3 | 7183748 | 9.2324  | 677695.0 | 7183748 | 7.0580  | 677695.8 | 7183748 | 8.139682  | 1.3011  | 0.5624  | 2.1744  | 0.73173864   |
| 23 | 460  | 677692.2 | 7183747 | 7.0108  | 677674.4 | 7183741 | 5.0000  | 677678.2 | 7183744 | 5.570312  | 7.7506  | 5.0476  | 2.0108  | 46.15000606  |

Showing 1 to 23 of 518 entries, 14 total columns

FONTE: O autor (2022)

A partir do resultado quantitativo da delimitação das árvores (AD), foi possível calcular, além da densidade espacial de árvores (DA), o grau de fragmentação (GF) e o grau de dispersão (GD) do conjunto de árvores segmentadas, com base na extensão da área verde obtida e na média dos afastamentos entre pares de árvores adjacentes. Tais métricas calculadas são mostradas na TABELA 13.

TABELA 13 - MÉTRICAS DE PAISAGEM CALCULADAS ANTES DA GENERALIZAÇÃO 3D PARA OS DADOS ULS

| <b>AD</b> | <b>Extensão total da área (hectare)</b> | <b>Extensão da área verde (hectare)</b> | <b>DA (árvores/hectare)</b> | <b>GF (árvores/hectare de área verde)</b> | <b>GD (metros)</b> |
|-----------|-----------------------------------------|-----------------------------------------|-----------------------------|-------------------------------------------|--------------------|
| 518       | 26,01                                   | 6,56                                    | 19,9                        | 78,96                                     | 10,45              |

FONTE: O autor (2022)

Esses valores são usados para fins de comparação com os resultados obtidos após a agregação 3D das árvores.

#### 4.2.3 Generalização 3D

São apresentados nesta seção os resultados obtidos com a aplicação dos dois operadores de generalização 3D nas árvores de interesse delimitadas nos dados ULS.

##### 4.2.3.1 Agregação 3D

Realizada a operação de agregação 3D para as 518 árvores delimitadas (AD) nos dados ULS, foram obtidos os seguintes quantitativos apresentados na TABELA 14, considerando-se os dez conjuntos de limiares estabelecidos no QUADRO 9:

TABELA 14 - RESUMO QUANTITATIVO DA AGREGAÇÃO DAS 518 ÁRVORES NOS DADOS ULS (POR CONJUNTO DE LIMIARES)

| Conjunto de limiares | PAP  | APH | APHS<br>(% em relação a PAP) | AA<br>(% em relação a AD) | ANA<br>(% em relação a AD) | AM  | AR  | RNA   |
|----------------------|------|-----|------------------------------|---------------------------|----------------------------|-----|-----|-------|
| A                    | 2891 | 536 | 181<br>(6,26%)               | 207<br>(39,97%)           | 311<br>(60,03%)            | 181 | 492 | 5,01% |
| B                    | 2891 | 536 | 97<br>(3,35%)                | 121<br>(23,96%)           | 397<br>(76,04%)            | 97  | 494 | 4,63% |
| C                    | 2223 | 427 | 144<br>(6,47%)               | 177<br>(34,17%)           | 341<br>(65,83%)            | 144 | 485 | 6,37% |
| D                    | 2223 | 427 | 79<br>(3,55%)                | 109<br>(21,05%)           | 409<br>(78,95%)            | 79  | 488 | 5,79% |
| E                    | 1626 | 316 | 105<br>(6,45%)               | 145<br>(28,00%)           | 373<br>(72,00%)            | 105 | 478 | 7,72% |
| F                    | 1626 | 316 | 58<br>(3,56%)                | 88<br>(16,99%)            | 430<br>(83,01%)            | 58  | 488 | 5,79% |
| G                    | 1053 | 218 | 75<br>(7,12%)                | 113<br>(21,82%)           | 405<br>(78,18%)            | 75  | 480 | 7,33% |
| H                    | 1053 | 218 | 42<br>(3,98%)                | 69<br>(13,33%)            | 449<br>(86,67%)            | 42  | 491 | 5,21% |
| I                    | 608  | 135 | 42<br>(6,90%)                | 72<br>(13,90%)            | 446<br>(86,10%)            | 42  | 488 | 5,79% |
| J                    | 608  | 135 | 20<br>(3,28%)                | 36<br>(6,95%)             | 482<br>(93,05%)            | 20  | 502 | 3,08% |


FONTE: O autor (2022)

Assim como foi analisado para os dados ALS, observa-se no geral que à medida em que diminui o limiar de proximidade (sentido do conjunto A para o J), diminui também o número de pares de árvores consideradas próximas (PAP). Comparando-se os conjuntos que apresentam o mesmo limiar de proximidade (A e B; C e D; E e F; G e H; I e J), o número de pares próximos e similares (PAPHS) também diminui em decorrência de uma diminuição do limiar superior de tamanho relativo de área aproximada, que foi definido segundo o critério de Wang et al. (2015).

Constata-se assim que a diminuição simultânea dos limiares de proximidade e de tamanho relativo implicou o decréscimo do número de árvores mescladas e consequentemente o aumento do número de árvores não-agregadas, como se pode verificar para o conjunto limitante J, que apresentou o maior número de ANA e o menor de AM dentre todos os dez conjuntos de limiares; fato este que permite inferir ser o referido conjunto como o de menor tendência à generalização por agregação 3D.

Tal inferência é validada pelo menor valor da RNA calculado, conforme se observa no GRÁFICO 4, que mostra os valores da última coluna da TABELA 14.

GRÁFICO 4 - DADOS ULS (ÁREA DE ESTUDO 2): REDUÇÃO DO NÚMERO DE ÁRVORES (RNA) POR AGREGAÇÃO 3D



FONTE: O autor (2022)

Percebe-se que, dentre os dez conjuntos de limiares estabelecidos, o conjunto E foi o que propiciou a maior generalização por agregação 3D, quantificada neste caso por meio do maior valor da RNA, decorrente do menor número de árvores resultantes (mescladas e não-agregadas).

Além da análise da redução do número de árvores, pode-se analisar também como resultado da agregação 3D o impacto da existência de árvores mescladas no grau de fragmentação e de dispersão da área verde total. Na TABELA 15 são mostradas as variações dos graus de fragmentação e de dispersão do conjunto de árvores resultantes calculadas em relação às árvores delimitadas originalmente a partir da nuvem de pontos ULS.

TABELA 15 – RESUMO DAS MÉTRICAS DE PAISAGEM CALCULADAS DEPOIS DA AGREGAÇÃO 3D (DADOS ULS)


| Conjunto de limiares | DA (árvores/hectare) | GF (árvore/hectare de área verde) | RF (%) | GD (metros) | ADA (%) |
|----------------------|----------------------|-----------------------------------|--------|-------------|---------|
| A                    | 18,91                | 75,00                             | 5,01   | 17,58       | 68,22   |
| B                    | 18,99                | 75,30                             | 4,63   | 16,84       | 61,14   |
| C                    | 18,64                | 73,93                             | 6,37   | 17,63       | 68,71   |
| D                    | 18,76                | 74,39                             | 5,79   | 16,90       | 61,72   |
| E                    | 18,37                | 72,86                             | 7,72   | 17,81       | 70,43   |
| F                    | 18,76                | 74,39                             | 5,79   | 17,31       | 65,64   |
| G                    | 18,45                | 73,17                             | 7,33   | 17,35       | 66,02   |
| H                    | 18,87                | 74,84                             | 5,21   | 16,79       | 60,67   |
| I                    | 18,76                | 74,39                             | 5,79   | 16,91       | 61,81   |
| J                    | 19,30                | 76,52                             | 3,08   | 16,41       | 57,03   |

FONTE: O autor (2022)

Conforme o esperado, os valores dos percentuais de redução de fragmentação são significativamente iguais aos valores dos percentuais de redução do número de árvores mostrados anteriormente na TABELA 15, já que ambos os índices são calculados em função do número de árvores resultantes da agregação 3D e do número de árvores delimitadas originalmente, que permanecem inalterados no referido cálculo.


Nos GRÁFICOS 5 e 6 são mostrados os percentuais de redução do grau de fragmentação e do grau de dispersão dos conjuntos de árvores resultantes da agregação 3D.

GRÁFICO 5 - DADOS ULS (ÁREA DE ESTUDO 2): REDUÇÃO DO GRAU DE FRAGMENTAÇÃO DO CONJUNTO DE ÁRVORES (RNA) POR AGREGAÇÃO 3D



FONTE: O autor (2022)

GRÁFICO 6 - DADOS ULS (ÁREA DE ESTUDO 2): AUMENTO DO GRAU DE DISPERSÃO DO CONJUNTO DE ÁRVORES (ADA) POR AGREGAÇÃO 3D



FONTE: O autor (2022)

Comparando-se os dois gráficos, nota-se que os maiores valores dos dois índices calculados estão associados ao mesmo conjunto (E), e que há uma relação direta entre os valores de RF e de ADA obtidos, ou seja, reduzida a fragmentação do conjunto de árvores, estas ficaram mais dispersas pois aumentou o afastamento próximo médio entre elas.

Nota-se também que os menores valores obtidos para RF e ADA estão associados ao mesmo conjunto (J), ratificando assim sua tendência de menor generalização por agregação 3D.

#### 4.2.3.2 Simplificação 3D

Nesta seção são mostrados os resultados obtidos com as duas técnicas de compressão de nuvens de pontos empregadas para os dados ULS.

##### 4.2.3.2.1 Partição espacial por *octree*

Foi realizada a compressão por *octree* em todas as dez nuvens de pontos atualizadas por ID's resultantes da operação de agregação 3D, obtendo-se a mesma redução da quantidade de pontos para todas elas, considerando-se um mesmo número de subdivisões Q. Quanto ao espaço de armazenamento computacional, sua

redução também foi significativamente igual para todas as nuvens, já que estas se diferenciam apenas quanto aos ID's atualizados.


A fim de facilitar a análise dos resultados obtidos pelas partições por *octree*, na TABELA 16 e na FIGURA 60 são comparados quantitativamente e visualmente, para uma das nuvens de pontos resultante da agregação 3D (considerando o conjunto de limiares A), os resultados obtidos após nove e dez subdivisões.

TABELA 16 - COMPARATIVO DE REDUÇÃO DO ESPAÇO DE ARMAZENAMENTO E DA QUANTIDADE DE PONTOS PELA COMPRESSÃO DOS DADOS ULS POR *OCTREE*

|                                               | Nuvem resultante da agregação 3D (conjunto A) | Compressão por <i>Octree</i> |         |
|-----------------------------------------------|-----------------------------------------------|------------------------------|---------|
|                                               |                                               | Q=9                          | Q=10    |
| Unidade elementares (pontos)                  | 6.625.405                                     | 177.229                      | 542.841 |
| Redução do número de pontos (RNP em %)        | -----                                         | 97,32%                       | 91,80%  |
| Espaço de armazenamento (MB)                  | 245,866                                       | 7,720                        | 22,266  |
| Redução do espaço de armazenamento (REA em %) | -----                                         | 96,86%                       | 90,94%  |

Fonte: O autor (2022)

FIGURA 60 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE PONTOS ULS RESULTANTE DA SEGMENTAÇÃO (A) E O RESULTADO DE SUAS COMPRESSÕES POR *OCTREE* COM 10 (B) E 9 SUBDIVISÕES (C)



FONTE: O autor (2022)

Embora sem uma perceptível relação linear entre as reduções do número de pontos e do espaço de armazenamento computacional obtidas, foi verificada uma proporcionalidade inversa entre os percentuais calculados e o número de subdivisões, sendo os maiores valores (97,32% e 96,86%) associados ao menor valor de Q, no caso nove subdivisões.

Tal observação vai ao encontro do esperado para uma partição por *octree*, pois uma menor quantidade de subdivisões implicou menor número de pontos resultantes da compressão e consequentemente menor espaço de armazenamento computacional requerido, conforme explicado na seção 3.4.3.2.1.

#### 4.2.3.2.2 Aprendizado profundo não-supervisionado (*autoencoder*)

Assim como ocorreu para a compressão por *octree*, foram obtidas após a compressão por aprendizado não-supervisionado a mesma redução da quantidade de pontos para todas as nuvens de pontos resultantes da agregação 3D, considerando-se uma densidade resultante  $\mu$ . Quanto ao espaço de armazenamento computacional, sua redução também foi significativamente igual para todas as nuvens, já que estas se diferenciam apenas quanto aos ID's atualizados.


A fim de facilitar a análise dos resultados obtidos pelo *autoencoder*, na TABELA 17 e na FIGURA 61 são comparados quantitativamente e visualmente, para uma das nuvens de pontos resultante da agregação 3D (considerando o conjunto de limiares A), os resultados obtidos considerando-se densidades resultantes ( $\mu$ ) de 1 e 2 pontos/m<sup>2</sup>.

TABELA 17 - COMPARATIVO DE REDUÇÃO DE ESPAÇO DE ARMAZENAMENTO E QUANTIDADE DE UNIDADES ELEMENTARES PARA A COMPRESSÃO DOS DADOS ULS POR *AUTOENCODER*

|                                               | Nuvem resultante da agregação 3D (conjunto A) | Compressão por <i>autoencoder</i> |           |
|-----------------------------------------------|-----------------------------------------------|-----------------------------------|-----------|
|                                               |                                               | $\mu = 2$                         | $\mu = 1$ |
| <b>Unidade elementares (pontos)</b>           | 6.625.405                                     | 202.281                           | 101.141   |
| <b>Redução do número de pontos (%)</b>        | -----                                         | 96,94%                            | 98,47%    |
| <b>Espaço de armazenamento (MB)</b>           | 245,866                                       | 7,507                             | 3,754     |
| <b>Redução do espaço de armazenamento (%)</b> | -----                                         | 96,94%                            | 98,47%    |

FONTE: O autor (2022)

FIGURA 61 - COMPARAÇÃO VISUAL ENTRE UM EXTRATO DA NUVEM DE PONTOS ULS RESULTANTE DA SEGMENTAÇÃO (A) E O RESULTADO DE SUAS COMPRESSÕES POR *AUTOENCODER* COM DENSIDADE DE 2 (B) E 1 PONTO/M<sup>2</sup> (C)



FONTE: O autor (2022)

Diferentemente do que foi observado para a partição por *octree*, houve uma relação linear entre as reduções do número de pontos e do espaço de armazenamento computacional obtidas. Foi verificada também uma proporcionalidade inversa entre os percentuais calculados e a densidade de pontos da nuvem simplificada, sendo os maiores valores (98,47%) associados ao menor valor de  $\mu$ , no caso igual a 1.

Tal observação vai ao encontro do esperado para o *autoencoder*, pois uma menor densidade de pontos previamente definida implicou menor número de pontos resultantes da compressão e consequentemente menor espaço de armazenamento computacional requerido, conforme explicado na seção 3.4.3.2.2.

#### 4.2.4 Avaliação final dos resultados

Além da análise da redução do espaço de armazenamento computacional decorrente da diminuição da densidade de pontos pelas duas técnicas de compressão de nuvens de pontos empregadas, e também do comparativo entre as métricas de paisagem (fragmentação e dispersão) calculadas antes e depois da operação de agregação 3D, a avaliação final do desempenho do método desenvolvido para generalizar as árvores delimitadas a partir dos dados ULS pôde ser feita com base na correspondência com a cena 3D original.

Para tal, comparou-se os atributos estruturais das árvores generalizadas (resultantes dos operações de agregação e simplificação) com as árvores originais

delimitadas, considerando-se os dez conjuntos de limiares. Ressalta-se que para o cálculo de  $\Delta P_{c_i}$ ,  $\Delta h_{v_i}$  e  $\Delta S_{ap}$  mostrados na TABELA 18 foi novamente utilizada a função *tree\_metrics*, sendo utilizadas as nuvens de pontos atualizadas pelos ID resultantes da agregação, que foram salvas em arquivos .LAS, para fins de compatibilidade com o módulo *PointCloud* do padrão *CityGML 3.0*.

TABELA 18 – CORRESPONDÊNCIA DAS ÁRVORES GENERALIZADAS COM A CENA 3D ORIGINAL (DADOS ULS)

| Indicadores avaliados                           |        |           | Conjunto de limiares |       |       |       |       |       |       |       |       |       |  |
|-------------------------------------------------|--------|-----------|----------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|--|
|                                                 |        |           | A                    | B     | C     | D     | E     | F     | G     | H     | I     | J     |  |
| $\overline{\Delta P_{c_i}}$<br>(m)              | Octree | Q = 9     | 0,42                 | 0,46  | 0,43  | 0,45  | 0,43  | 0,46  | 0,45  | 0,46  | 0,47  | 0,48  |  |
|                                                 |        | Q = 10    | 0,31                 | 0,34  | 0,32  | 0,34  | 0,33  | 0,35  | 0,34  | 0,35  | 0,36  |       |  |
|                                                 | DePoCo | $\mu = 1$ | 0,23                 | 0,22  | 0,23  | 0,22  | 0,23  | 0,22  |       |       |       |       |  |
|                                                 |        | $\mu = 2$ | 0,15                 |       |       |       |       |       |       |       |       |       |  |
| $\overline{\Delta h_{V_i}}$<br>(m)              | Octree | Q = 9     | 0,16                 |       | 0,17  | 0,16  | 0,17  | 0,16  | 0,17  | 0,16  | 0,17  | 0,16  |  |
|                                                 |        | Q = 10    | 0,07                 |       |       |       |       |       |       |       |       |       |  |
|                                                 | DePoCo | $\mu = 1$ | 0,48                 | 0,46  | 0,49  | 0,46  | 0,48  |       |       | 0,47  |       | 0,45  |  |
|                                                 |        | $\mu = 2$ | 0,26                 |       | 0,27  | 0,26  |       | 0,27  | 0,26  | 0,27  | 0,26  |       |  |
| $\overline{\Delta S_{ap}}$<br>(m <sup>2</sup> ) | Octree | Q = 9     | 5,05                 | 5,66  | 5,39  | 5,77  | 5,63  | 5,85  | 5,83  | 5,79  | 4,81  | 5,93  |  |
|                                                 |        | Q = 10    | 2,28                 | 2,57  | 2,39  | 2,64  | 2,39  | 2,61  | 2,41  | 2,58  | 2,55  | 2,61  |  |
|                                                 | DePoCo | $\mu = 1$ | 11,96                | 12,87 | 12,72 | 13,31 | 13,09 | 13,55 | 13,30 | 13,62 | 13,58 | 13,64 |  |
|                                                 |        | $\mu = 2$ | 7,61                 | 8,57  | 8,05  | 8,77  | 8,48  | 9,02  | 8,61  | 8,94  | 8,96  | 9,07  |  |
| $S_{total}$<br>(hect)                           | Octree | Q = 9     | 62,44                |       |       |       |       |       |       |       |       |       |  |
|                                                 |        | Q = 10    | 64,23                |       |       |       |       |       |       |       |       |       |  |
|                                                 | DePoCo | $\mu = 1$ | 58,56                |       |       |       |       |       |       |       |       |       |  |
|                                                 |        | $\mu = 2$ | 60,97                |       |       |       |       |       |       |       |       |       |  |
| RV                                              | Octree | Q = 9     | 4,81                 |       |       |       |       |       |       |       |       |       |  |
|                                                 |        | Q = 10    | 1,47                 |       |       |       |       |       |       |       |       |       |  |
|                                                 | DePoCo | $\mu = 1$ | 10,73                |       |       |       |       |       |       |       |       |       |  |
|                                                 |        | $\mu = 2$ | 7,05                 |       |       |       |       |       |       |       |       |       |  |
| AE                                              | Octree | Q = 9     | 4                    |       |       |       |       |       |       |       |       |       |  |
|                                                 |        | Q = 10    | 2                    |       |       |       |       |       |       |       |       |       |  |
|                                                 | DePoCo | $\mu = 1$ | 17                   |       |       |       |       |       |       |       |       |       |  |
|                                                 |        | $\mu = 2$ | 12                   |       |       |       |       |       |       |       |       |       |  |
| PA<br>(%)                                       | Octree | Q = 9     | 0,81                 | 0,81  | 0,82  | 0,82  | 0,84  | 0,82  | 0,83  | 0,81  | 0,82  | 0,80  |  |
|                                                 |        | Q = 10    | 0,41                 | 0,41  | 0,41  | 0,41  | 0,42  | 0,41  | 0,42  | 0,41  | 0,41  | 0,40  |  |
|                                                 | DePoCo | $\mu = 1$ | 3,46                 | 3,44  | 3,50  | 3,48  | 3,56  | 3,48  | 3,54  | 3,46  | 3,48  | 3,39  |  |
|                                                 |        | $\mu = 2$ | 2,44                 | 2,43  | 2,47  | 2,46  | 2,51  | 2,46  | 2,5   | 2,44  | 2,46  | 2,39  |  |

FONTE: O autor (2022)

Observa-se, excetuando-se o deslocamento dos centroides, os demais tiveram seus maiores valores associados à arquitetura DePoCo, especificamente no caso de  $\mu = 1$ , permitindo constatar que a compressão realizada por aprendizado

profundo implicou as maiores variações acerca da altura relativa e da área da superfície das copas, bem como o maior número de árvores eliminadas.

Em relação às partições espaciais por *octree*, foram observados maiores valores dos índices calculados para o caso de menor subdivisão ( $Q = 9$ ).

No tocante aos índices RV e AE, todos os conjuntos limiares apresentaram o mesmo valor, já que o diferencial entre as nuvens de pontos resultantes no caso de uma mesma compressão realizada é apenas em relação aos ID's atualizados pela agregação 3D, sendo mantidas as quantidades de pontos das nuvens.

No caso dos índices  $\Delta P_{c_i}$  e  $\Delta h_{v_i}$  todos os valores calculados são inferiores a 1 metro, e os valores de  $\Delta S_{ap}$  são todos inferiores a 50 m<sup>2</sup>. Isso permite atestar que as reduções devidas à generalização 3D não implicaram em suficiente perda de informação que tornasse a representação das árvores resultantes da generalização 3D aplicada aos dados ULS incompatíveis ao LoD 2.

Como resultado final dos experimentos realizados com os dados ULS, foram obtidas dez nuvens de pontos (salvas em arquivos .LAS) contendo as árvores generalizadas, que puderam ser representadas em bancos de dados por geometria *multipoint* e associadas aos seus respectivos ID (*tree\_ID*), assim como ocorreu para os experimentos com os dados ALS.

A exemplo do que foi ressaltado para o caso dos dados ALS, os bancos de dados criados permitem o acesso às informações sobre a localização, o porte e a distribuição espacial das árvores urbanas mapeadas, também facilitando a confecção de inventários de arborização urbana.

### 4.3 COMPARATIVO ENTRE OS DOIS EXPERIMENTOS REALIZADOS

A partir dos resultados obtidos com os dois experimentos realizados na pesquisa, pode-se estabelecer um comparativo a fim de analisar a influência da amostragem dos dados utilizados e da paisagem das duas áreas de estudo, com base em diferentes indicadores, como mostra a TABELA 19.

TABELA 19 - COMPARATIVO ENTRE OS EXPERIMENTOS REALIZADOS (DADOS ALS X DADOS ULS)

| Indicador de comparação                |                                                                                           |             |        | Tipo de dados/Área de estudo |                            |
|----------------------------------------|-------------------------------------------------------------------------------------------|-------------|--------|------------------------------|----------------------------|
|                                        |                                                                                           |             |        | ALS<br>(Área de estudo 1)    | ULS<br>(Área de estudo 2)  |
| Filtragem                              | Redução após filtragem SOR (%)                                                            |             |        | 8,86                         | 9,75                       |
|                                        | Redução após filtragem CSF (%)                                                            |             |        | 39,65                        | 39,92                      |
|                                        | Redução após eliminação de pontos com altura menor que 5 metros e maior que 30 metros (%) |             |        | 11,58                        | 15,18                      |
| Classificação dos pontos não-terreno   | Acurácia global (%)                                                                       |             |        | 88,95                        | 94,44                      |
|                                        | Abrangência de pontos de vegetação rotulados (%)                                          |             |        | 50,80                        | 29,24                      |
| Segmentação de copas de árvores        | Número de árvores delimitadas                                                             |             |        | 851                          | 518                        |
|                                        | Densidade de árvores inicial (árvores/m²)                                                 |             |        | 28,6                         | 19,9                       |
|                                        | Grau de Fragmentação inicial (árvores/m²)                                                 |             |        | 67,30                        | 78,96                      |
|                                        | Grau de Dispersão inicial (metros)                                                        |             |        | 9,73                         | 10,45                      |
| Agregação 3D                           | Maior RNA/RF (%)                                                                          |             |        | 9,87<br>(conjunto I)         | 7,72<br>(conjunto E)       |
|                                        | Menor RNA/RF (%)                                                                          |             |        | 2,58<br>(conjunto D)         | 3,08<br>(conjunto J)       |
|                                        | Maior ADA (%)                                                                             |             |        | 52,20<br>(conjunto I)        | 70,43<br>(conjunto E)      |
|                                        | Menor ADA (%)                                                                             |             |        | 29,09<br>(conjunto A)        | 57,03<br>(conjunto J)      |
| Compressão das nuvens de pontos        | RNP (%)                                                                                   | Octree      | Q = 9  | 76,71                        | 97,32                      |
|                                        |                                                                                           |             | Q = 10 | 39,68                        | 91,80                      |
|                                        |                                                                                           | Autoencoder | μ = 1  | 74,07                        | 97,60                      |
|                                        |                                                                                           |             | μ =2   | 33,34                        | 92,67                      |
|                                        | REA (%)                                                                                   | Octree      | Q = 9  | 72,66                        | 98,47                      |
|                                        |                                                                                           |             | Q = 10 | 45,32                        | 96,94                      |
|                                        |                                                                                           | Autoencoder | μ = 1  | 72,65                        | 98,47                      |
|                                        |                                                                                           |             | μ = 2  | 45,32                        | 96,94                      |
| Correspondência com a cena 3D original | Maior ΔP <sub>c<sub>i</sub></sub> (m)                                                     |             |        | 0,37<br>(Autoencoder ;μ=1)   | 0,48 (Octree; Q=10)        |
|                                        | Menor ΔP <sub>c<sub>i</sub></sub> (m)                                                     |             |        | 0,14 (Octree; Q=10)          | 0,15<br>(Autoencoder; μ=2) |

|  |                                                          |                                       |                                       |
|--|----------------------------------------------------------|---------------------------------------|---------------------------------------|
|  | Maior $\overline{\Delta h_{V_i}}$ (m)                    | 0,62<br>(Autoencoder;<br>; $\mu=1$ )  | 0,48<br>(Autoencoder;<br>; $\mu=1$ )  |
|  | Menor $\overline{\Delta h_{V_i}}$ (m)                    | 0,06 (Octree;<br>Q=10)                | 0,07 (Octree;<br>Q=10)                |
|  | Maior $\overline{\Delta S_{approx_i}}$ (m <sup>2</sup> ) | 10,83<br>(Autoencoder;<br>; $\mu=1$ ) | 13,64<br>(Autoencoder; $\mu=1$ )      |
|  | Menor $\overline{\Delta S_{approx_i}}$ (m <sup>2</sup> ) | 1,27 (Octree;<br>Q=10)                | 2,28 (Octree;<br>Q=10)                |
|  | Maior RV (%)                                             | 7,35<br>(Autoencoder;<br>; $\mu=1$ )  | 10,73<br>(Autoencoder;<br>; $\mu=1$ ) |
|  | Menor RV (%)                                             | 1,26 (Octree;<br>Q=10)                | 1,47 (Octree;<br>Q=10)                |
|  | Maior PA (%)                                             | 3,85<br>(Autoencoder;<br>; $\mu=1$ )  | 3,56<br>(Autoencoder;<br>; $\mu=1$ )  |
|  | Menor PA (%)                                             | 0,48 (Octree;<br>Q=10)                | 0,41 (Octree;<br>Q=10)                |

FONTE: O autor (2022)

Pode-se constatar que para as filtrações SOR e CSF não houve significativa diferença nos percentuais de redução de pontos entre os dados ALS e ULS. Contudo, no tocante à classificação inicial dos pontos não-terreno, os dados ULS apresentaram maior acurácia global, podendo isso ser atribuído à maior densidade da nuvem de pontos, que permite obter menor erro na estimação dos atributos utilizados pelo algoritmo de classificação.

A influência da amostragem dos dados ULS nos resultados obtidos também pôde ser observada com base nos percentuais calculados para a etapa de simplificação 3D, considerando as duas técnicas de compressão utilizadas. Em ambas, a redução do número de pontos e do espaço de armazenamento foi significativamente maior do que as reduções observadas para os dados ALS. Porém, não é perceptível uma relação linear entre a redução da quantidade de pontos e do espaço de armazenamento, embora sejam diretamente proporcionais.

Em relação à influência das paisagens das áreas de estudo, a área 1 apresentou uma abrangência maior de pontos de vegetação rotulados, uma quantidade maior de árvores delimitadas e consequentemente maior densidade espacial de árvores, como consequências da área arborizada pertencente ao

complexo militar localizado no bairro da Pituba, que impactou em graus de fragmentação e de dispersão de árvores iniciais menores em relação à área 2.

As reduções de fragmentação e os aumentos de dispersão calculados após a agregação 3D apresentaram uma perceptível relação direta para os dados ULS, o que não foi observado para os dados ALS.

No tocante aos índices que quantificam a correspondência com a cena 3D original, não se tem indícios que permitam afirmar quais dados LiDAR apresentaram melhor desempenho em toda a generalização 3D. Porém, pode-se afirmar que os piores resultados em sua maioria foram obtidos pelo *autoencoder* com  $\mu = 1$  e os melhores com a partição por *octree* com 10 subdivisões.

Tal como ressaltado para o caso dos dados ALS, a partir de cada banco de dados criado para as árvores é possível acessar informações sobre a localização, o porte e a distribuição espacial das árvores urbanas mapeadas, facilitando assim a confecção de inventários que podem ser usados também em outras demandas além da execução de planos municipais de arborização urbana.

## 5 CONCLUSÕES E RECOMENDAÇÕES

Inserida no contexto do *BigData geoespacial* decorrente do atual desenvolvimento de tecnologias geoespaciais, a presente pesquisa contemplou a temática de generalização 3D como uma maneira de alcançar eficiência no mapeamento de vegetação urbana utilizando a tecnologia LiDAR, tendo como motivação a busca de uma solução de generalização 3D que permitisse extrair informações de localização, porte e distribuição espacial de árvores urbanas em modelos 3D compactos gerados a partir de nuvens de pontos ALS e ULS.

Como referência para a modelagem, adotou-se o padrão internacional *CityGML 3.0*, cuja recente atualização acrescentou a possibilidade de modelar vegetação por meio de nuvens de pontos, usando geometria implícita *multipoint*. Foi definido como o nível de detalhe a ser atingido o LoD 2, considerado compatível com o propósito de uso da solução buscada.

Os objetivos (geral e específicos) da pesquisa foram atingidos, tendo sido desenvolvido um método de generalização 3D fundamentado na adaptação para o caso 3D de uma combinação de dois operadores de generalização de mapas: agregação e simplificação. Para a agregação foram estabelecidas condições que exploraram medidas espaciais de proximidade (distância horizontal euclidiana) e semelhança (razão de alturas, de comprimentos e de áreas de copas) entre as árvores de interesse, considerando dez diferentes conjuntos de valores limiares para essas medidas, ao passo que para a simplificação foram empregadas duas diferentes técnicas de compressão de nuvens de pontos: partição espacial por *octree* e aprendizado profundo não-supervisionado (*autoencoder*).

A avaliação do método foi feita sob diferentes aspectos: computacionais, em que se analisou a redução do número de pontos e a consequente diminuição do espaço de armazenamento computacional; variação do grau de fragmentação e dispersão calculados para os conjuntos de árvores resultantes da agregação 3D em relação às árvores delimitadas originalmente, e a correspondência do resultado final obtido com a cena 3D original, em que se quantificou a perda de informações referentes aos atributos das árvores.

Foi possível analisar a relação dos resultados quantitativos obtidos pela operação de agregação 3D com os limiares estabelecidos, tendo sido observadas para todos os dez conjuntos de limiares reduções da densidade espacial de árvores e

do grau de fragmentação da área verde total, ambas devidas à redução do número de árvores resultantes, ocasionada pela mescla das árvores que atenderam aos critérios de proximidade e semelhança. Isso também implicou no aumento do grau de dispersão do conjunto das árvores resultantes observado para todos os dez limiares estabelecidos.

Comparando-se os resultados da simplificação obtidos pelo aprendizado profundo não-supervisionado e pela partição espacial por *octree*, e sobre a avaliação em relação à correspondência com a cena 3D original, observou-se que, no geral, os piores resultados foram obtidos pelo *autoencoder* com  $\mu = 1$  e os melhores com a partição por *octree* com 10 subdivisões. Porém, o aumento de  $\mu$  para 2 propiciou menores valores dos índices de variação calculados.

A partir da avaliação do método, valida-se a hipótese central de que o estabelecimento de condições envolvendo medidas-Gestalt de proximidade e semelhança exploradas na agregação das árvores e o emprego de uma compressão da nuvem de pontos permitem modelar, de maneira compatível com o LoD 2 *CityGML 3.0*, árvores urbanas de maneira compacta e realística a partir de dados LiDAR.

Como a abordagem da generalização 3D de vegetação urbana ainda é limitada a apoiar análises espaciais de outros elementos urbanos, carecendo da realização de estudos que contemplem suas aplicações específicas, a presente pesquisa mostrou-se inovadora, oferecendo as seguintes contribuições metodológicas: - quantificação de relações espaciais entre árvores por meio de medidas-Gestalt; - estabelecimento de limiares para essas medidas; - cálculo de métricas da paisagem para árvores; - comparação de duas técnicas de compressão de nuvens de pontos; - complemento de especificações do *CityGML 3.0*, principalmente para o caso da classe PC em geometria implícita e também para o novo módulo *Pointcloud*.

Há também uma contribuição teórica: a reconceptualização (para o domínio 3D) de fundamentos de generalização aplicados ao mapeamento tradicional. Isso se evidencia na adaptação dos operadores 2D aplicados e pelo atendimento às três questões levantadas por McMaster e Shea (1992) no tocante à realização de um processo de generalização: “por que generalizar?”, “como generalizar?”, “quando generalizar?”. Nesse sentido, a partir da definição do propósito de uso, do *LoD* desejado, da estratégia adotada, e do critério de avaliação do método, empregou-se

uma metodologia que permitiu atender a uma demanda específica, sendo constatada assim a validade e a reprodutibilidade do processo.

Além das contribuições teóricas e metodológicas relacionadas à temática de generalização 3D, outra contribuição ofertada por esta pesquisa é a solução apresentada para o problema da delimitação de árvores urbanas em dados LiDAR, tendo sido empregadas diferentes técnicas de processamento com o auxílio de algoritmos implementados em softwares próprios pra nuvens de pontos, que se mostraram eficazes para essa finalidade, gerando resultados satisfatórios.

As filtragens SOR e CSF se mostraram indispensáveis para a adequação dos dados utilizados 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 a importância do refinamento da classificação devido à disponibilidade de informações RGB correspondentes aos dados LiDAR utilizados, possibilitando o uso de critérios radiométrico-espectrais em complemento aos critérios geométricos adotados pelos algoritmos empregados. Em relação ao algoritmo de segmentação empregado, sua funcionalidade garantiu a extração dos atributos estruturais (das árvores) desejados.

Como foram utilizados dados LiDAR adquiridos por diferentes plataformas áreas e referentes a dois cenários urbanos distintos, fez-se um comparativo entre os resultados obtidos para os dados ALS e ULS considerando todas as etapas metodológicas. Exceto para a compressão por *autoencoder*, observou-se um desempenho melhor para os dados ULS, apontando assim a vantagem de seu uso, em face do avanço das tecnologias geoespaciais.

Evidenciado nesta pesquisa o potencial da tecnologia LiDAR para o mapeamento de arborização urbana, espera-se que os experimentos realizados possam servir como base para novos estudos e pesquisas que utilizem dados ALS e ULS para extração de informações que auxiliem análises espaciais do indispensável componente biótico das cidades, considerando escalas de uso adequadas a demandas específicas.

Por fim, ficam como sugestões e recomendações para trabalhos futuros:

1 – Repetir o fluxo de trabalho realizado, empregando: outros métodos de classificação e de segmentação de nuvens de pontos utilizando informações espectrais complementares (valores de intensidade e informações advindas de

sensores diferentes do LiDAR), assim como outros valores para os parâmetros explorados pelas rotinas de processamento, visando aumentar a acurácia da delimitação das árvores; dados adquiridos por sistemas LiDAR terrestres (TLS – *terrestrial laserscanning*);

2 – Generalização 3D de outros elementos vegetais com alturas maiores que 30 metros e menores que 5 metros;

3 – Geração de modelos 3D de árvores urbanas correspondentes ao LoD 3 do padrão *CityGML* 3.0;

4 – Detecção e quantificação, por variação temporal, de mudanças na vegetação urbana;

5 – Contribuição com estudos sobre simbolização 3D de vegetação urbana.

## REFERÊNCIAS

- ALONZO, M. G. **Urban forest ecosystem analysis using fused airborne hyperspectral and lidar data**. 2015. 211 p. Dissertation of Doctoral – Department of Geography, University of California, Santa Barbara, 2015.
- AMERICA SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING. **LiDAR division**. 2021. Disponível em: <https://www.asprs.org/divisions-committees/lidar-division>. Acesso em: 3 dez. 2021.
- ANDRADE E SILVA, D.; SANTOS, D. R. dos. Um Estudo de Caso sobre o Emprego da Técnica de Voxelização como Método para Generalização 3D de Arborização Urbana em Dados LiDAR Aerotransportado. **Revista Brasileira de Cartografia**, v. 74, n. 1, p. 50–66, 2022.
- ARNHEIM, R. **Arte e Percepção Visual**: uma psicologia da visão criadora. Trad. de Ivonne Terezinha de Faria. São Paulo: Cengage Learning, 2011.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 16246-1**: Florestas urbanas - Manejo de árvores, arbustos e outras plantas lenhosas - Parte 1: Poda. ABNT, 2013.
- BIONDI, D. Floresta urbana: conceitos e terminologias. In: Biondi, D. **Floresta Urbana**. 1ª ed. Curitiba: a autora, 2015. p. 11-27.
- 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.
- CARRILHO, A. C.; GALO, M.; DOS SANTOS, R. C. Statistical outlier detection method for airborne LiDAR data. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 42, n. 1, p. 87-92, 2018. DOI: <http://dx.doi.org/10.5194/isprs-archives-XLII-1-87-2018>.
- CHEN, Q., BALDOCCHI, D.D., GONG, P., KELLY, M., Isolating individual trees in a savanna woodland using small footprint LiDAR data. **Photogrammetric Engineering & Remote Sensing**, v. 72 n. 8, p. 923-932. 2006.
- COMITÊ DE TRABALHO INTERINSTITUCIONAL PARA ANÁLISE DOS PLANOS MUNICIPAIS DE ARBORIZAÇÃO URBANA NO ESTADO DO PARANÁ (MINISTÉRIO PÚBLICO DO PARANÁ). **Manual para elaboração do plano municipal de arborização urbana**. Curitiba, 2018. Disponível em <http://www.conexaoambiental.pr.gov.br/>. Acesso em 5 jan. 2021.

DENT, B. D.; TORGUSON, J.S.; HODLER, T.W. **Cartography: thematic map design**. 6th Ed. McGraw-Hill. ISBN 978-0-07-294382-5. 2009.

DJI. Especificações. **Zenmuse L1**. Shenzhen, China, 2021. Disponível em: <https://www.dji.com/br/zenmuse-l1>. Acesso em 24 out. 2021.

D'OLIVEIRA, M.V.N.; FIGUEIREDO, E.O.; PAPA, D.A. **Uso do Lidar como Ferramenta para o Manejo de Precisão em Florestas Tropicais**. Embrapa, 131 p, Brasília-DF, 2014.

D'OLIVEIRA, M. V. N.; BROADBENT, E. N.; OLIVEIRA, L. C.; ALMEIDA, D. R. A.; PAPA, D. A.; FERREIRA, M. E.; ZAMBRANO, A. M. A.; SILVA, C. A.; AVINO, F. S.; PRATA, G. A.; MELLO, R. A.; FIGUEIREDO, E. O.; JORGE, L. A. C.; JUNIOR, L.; ALBUQUERQUE, R. W.; BRANCALION, P. H. S.; WILKINSON, B.; COSTA, M.O. Aboveground Biomass Estimation in Amazonian Tropical Forests: a Comparison of Aircraft- and GatorEye UAV-borne LiDAR Data in the Chico Mendes Extractive Reserve in Acre, Brazil. **Remote Sensing**. v. 12, n. 1754. 2020. DOI:10.3390/rs12111754.

DELAZARI, L.S.; ERCOLIN FILHO, L. **UFPR CampusMap**. Centro de Pesquisas Aplicadas em Geoinformação (CEPAG). (UFPR. Projeto de Pesquisa). Curitiba, 2021. Disponível em: [www.campusmap.ufpr.br](http://www.campusmap.ufpr.br). Acesso em: 27 out. 2021.

DÖLLNER, J. Geospatial Artificial Intelligence: Potentials of Machine Learning for 3D Point Clouds and Geospatial Digital Twins. **PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science**, v. 88, n. 1, p. 15–24, 2020.

DOVRAT, O.; LANG, I.; AVIDAN, S. Learning to Sample. **arXiv:1812.01659 [cs, CV]**, 2019. DOI: 10.48550/arXiv.1812.01659.

FENG, Y.; THIEMANN, F.; SESTER, M. Learning Cartographic Building Generalization with Deep Convolutional Neural Networks. **ISPRS International Journal of Geo-Information**. v. 8, n. 258, 2019. DOI: <https://doi.org/10.3390/ijgi8060258>.

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.

FERREIRA, F. R. **Segmentação do espaço urbano por meio da tecnologia LiDAR aerotransportado**. 2014. 130 p. Dissertação de Mestrado – Departamento de Engenharia de Transportes, Universidade de São Paulo, São Paulo, 2014.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO). **State of the World's Forests**. 9ª ed. Rome: FAO, 2011.

GLANDER, T; DÖLLNER J. Automated cell based generalization of virtual 3D city models with dynamic landmark highlighting. In: 11<sup>TH</sup> ICA WORKSHOP ON GENERALIZATION AND MULTIPLE REPRESENTATION, 2008, Montpellier, France. **Proceedings...** Montpellier: 2008. p. 1–14.

GRANSHAW, S.I. **Photogrammetric Terminology**. Third Edition. The Photogrammetric Record, v. 31, n. 154, p. 210–252. 2016.

GUO, Q.; LI, W.; YU, H.; ALVAREZ, O. Effects of topographic variability and LiDAR sampling density on several DEM interpolation methods. **Photogrammetric Engineering & Remote Sensing**, v. 76, n. 6, p. 701–712, 2010. DOI: 10.14358/PERS.76.6.701.

HALLIDAY, D.; RESNIK, R.; KRANE, D. S. **Física 2**. 5ª Ed. Rio de Janeiro: LTC, 2004.

HERRERO, E. M; ELLUL, C.; MORLEY, J. Testing the impact of 2D generalisation on 3D models – exploring analysis options with an off-the-shelf software package. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-4/W10, 2018. DOI: <https://doi.org/10.5194/isprs-archives-XLII-4-W10-119-2018>.

HIRYE, M. C. M.; ALVES, D. S.; KUX, H. J. H. Mapeamento da vegetação urbana a partir de dados de sensoriamento remoto: estado da arte e perspectivas futuras. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18 (SBSR), 2017, Santos. **Anais...** Santos: 2017. p. 6922 – 6929.

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. Disponíveis em: < <https://www.ibge.gov.br/cidades-e-estados/ba.html>>;< <https://www.ibge.gov.br/cidades-e-estados/pr.html>>. Acesso em 26 abr. 2021.

ISENBURG, M. **LAStools Software Suite**. 2011. Disponível em: <<http://rapidlasso.com/lastools/download>>. Acesso em 20 maio 2021.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. 3ª ed. São José dos Campos: Parêntese, 2011.

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.

KADA, M.; KURAMIN, D. ALS point cloud classification using Pointnet++ and kpconv with prior knowledge. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLVI-4/W4-2021, p. 91–96, 2021. DOI: <https://doi.org/10.5194/isprs-archives-XLVI-4-W4-2021-91-2021>.

KASHANI, A. G., OLSEN, M. J., PARRISH, C. E., WILSON, N. A Review of LIDAR Radiometric Processing: From Ad Hoc Intensity Correction to Rigorous Radiometric Calibration. **Sensors**, v. 15, p. 28099 - 28128, 2015.

KIM, J. S.; LI, K. J. Simplification of geometric objects in an indoor space. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 147, p. 146–162, 2019.

KRAAK, M.J.; ORMELING, F. **Cartography: Visualization of Spatial Data**. 3. Ed. Pearson Education Limited. 2010

KUTZNER, T.; CHATUVERDI, T.; KOLBE, T.H. CityGML 3.0: New Functions Open Up New Applications. **Journal of Photogrammetry, Remote Sensing and Geoinformation Science**, v. 88, p. 43-61, 2020.

LEE, J.; JANG, H.; YANG, J; YU, K. Machine learning classification of buildings for map generalization. **ISPRS International Journal of Geo-Information**, v. 6, n. 10, p. 309, 2017.

LI, S., DRAGICEVIC, S., CASTRO, F.A., SESTER, M., WINTER, S., COLTEKIN, A., PETTIT, C., JIANG, B., 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.

LI, W.; Guo, G.; Jakubowski, M. K.; Kelly, M. A new method for segmenting individual trees from the LiDAR point cloud. **Photogrammetric Engineering & Remote Sensing**, v.78, n.1, p.75-84, 2012.

LI, X.; CHEN, W. Y.; SANESI, G.; LAFORTEZZA, R. Remote Sensing in Urban Forestry: Recent Applications and Future Directions. **Remote Sensing**, v. 11, n. 1144, 2019. DOI:10.3390/rs11101144.

LIU, T.; YANG, X. Monitoring land changes in an urban area using satellite imagery, GIS and landscape metrics. **Applied geography**, v. 56, p. 42-54, 2015. DOI: <http://dx.doi.org/10.1016/j.apgeog.2014.10.002>.

MACKANESS, W. A.; RUAS, A. Evaluation in the Map Generalisation Process. In: MACKANESS, W. A.; RUAS, A.; SARJAKOSKI, L. T. **Generalisation of Geographic Information: Cartographic Modelling and Applications**. 1<sup>a</sup> Ed. Amsterdam: Elsevier, 2007. p. 89-111.

MACKANESS, W. A.; RUAS, A.; SARJAKOSKI, L. T. **Generalisation of Geographic Information: Cartographic Modelling and Applications**. 2<sup>a</sup> Ed. Amsterdam: Elsevier, 2011.

MAGALHÃES, I. A. L.; XAVIER, A. C. Caracterização e Avaliação das Respostas Espectrais de Alvos no município de Itapemirim, ES, por meio de Sensoriamento Remoto Orbital. **Revista Brasileira de Geografia Física**, v.11, n.03, p. 1010-1025, 2018.

McMASTER, R. B.; SHEA, K. S. **Generalization in Digital Cartography**. 1<sup>a</sup> 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 of Geoinformation**, v. 4, p. 1055 – 1075, 2015. DOI:10.3390/ijgi4031055.

OPEN GEOESPACIAL CONSORTIUM (OGC). **OGC City Geography Language (CityGML) Encoding Standard**, 2022.

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.

PEDRINI, H.; SCHWARTZ, W.R. **Análise de imagens digitais: princípios, algoritmos e aplicações.** 1ª ed. Rio de Janeiro: Editora Thomson Pioneira, 2008.

POINT CLOUD LIBRARY (PCL). Module Octree. **Overview.** 2021. Disponível em: <[https://pointclouds.org/documentation/group\\_octree.html](https://pointclouds.org/documentation/group_octree.html)>. Acesso em: 15 out. 2021.

PONTE, E.; ROCH, M.; LEINENKUGEL, P.; DECH, S.; KUENZER, C. Paraguay's Atlantic Forest cover loss e Satellite-based change detection and fragmentation analysis between 2003 and 2013. **Applied Geography**. v. 79, p. 37 – 49, 2017.

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. 268 p. Doctoral dissertation – Department of Geography, University of Liège, 2019.

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.

RAMDANI, F. Urban Vegetation Mapping from Fused Hyperspectral Image and LiDAR Data with Application to Monitor Urban Tree Heights. **Journal of Geographic Information System**, v. 5, n.4, p. 404-408, 2013. DOI: 10.4236/jgis.2013.54038.

REGNAULD, N.; McMASTER, R. B. A Synoptic View of Generalisation Operators. In: **Generalisation of Geographic Information: Cartographic Modelling and Applications**. International Cartographic Association. 2007, p. 37-66.

RENSLOW, M.S. **Manual of airborne topographic LiDAR**. American Society for Photogrammetry and Remote Sensing, Bethesda, 2012.

RIEGL LASER MEASUREMENT SYSTEMS GmbH (RIEGL). Products. **Airborne scanning**. Horn, 2019. Disponível em:

<[http://riegl.com/uploads/tx\\_pxriegl/downloads/RIEGL\\_VQ-480II\\_Datasheet\\_2019-10-16.pdf](http://riegl.com/uploads/tx_pxriegl/downloads/RIEGL_VQ-480II_Datasheet_2019-10-16.pdf)>. Acesso em 04 jun. 2021.

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. H.; SALE, R. D.; MORRISON, J. L. **Elements of Cartography**. 4ª ed. Nova York: John Wiley & Sons, 1978.

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.

RUSU, R. B.; MARTON, Z. C.; BLODOW, N.; DOLHA, M.; BEETZ, M. Towards 3D point cloud based object maps for household environments. **Robotics and autonomous systems**. v. 56, p. 927-941, 2008. DOI: 10.1016/j.robot.2008.08.005.

RUTZINGER, M.; HÖFLE, B. HOLLAUS, M.; PFEIFER, N. Object-Based Point Cloud Analysis of Full-Waveform Airborne Laser Scanning Data for Urban Vegetation Classification. **Sensors**. v. 8, p. 4505-4528, 2008. DOI: 10.3390/s8084505.

SANTOS, K. S. M. **Deteção de árvores em povoamentos de Pinus spp. a partir de nuvens de pontos derivados de imagens ópticas de RPAS a partir da análise de máximo global**. 2018. 99 f. Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Curitiba (PR), 2018.

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.

SESTER, M. Cartographic generalization. **Journal of Spatial Information Science**, n. 21, pp. 5–11, 2020. DOI:10.5311/JOSIS.2020.21.716

SESTER, M. FENG, Y., THIEMANN, F. Building generalization using deep learning. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-4, 2018. DOI: <https://doi.org/10.5194/isprs-archives-XLII-4-565-2018>.

SHAN, J; TOTH, C. K. **Topographic laser ranging and scanning: principles and processing**. Boca Raton: CRC Press, 2009.

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.

SILVA, D. L. A. **Geração e Avaliação de produtos interferométricos dos dados ALOS/PALSAR FBD E PLR para classificação de cobertura da terra na Amazônia**. 154 p. Dissertação de Mestrado - Programa de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

SLOCUM, T.A.; McMASTER, R.B.; KESSLER, F.C.; HOWARD, H.H. **Thematic Cartography and Geographic Visualization**. 3. ed. Upper Saddle River, NJ: Pearson Prentice Hall, 2009.

THOMAS, H.; QI, C.R.; DESCHAUD, J.; MARCOTEGUI, B.; GOULETTE, F.; GUIBAS, L.J. KPConv: Flexible and Deformable Convolution for Point Clouds. In: IEEE/CVF Intl. Conf. on Computer Vision (ICCV), **Proceedings**. 2019.

WANG, Y., ZHANG, L., P., MATHIOPOULOS, P. T., DENG, HAO. A Gestalt rules and graph-cut-based simplification framework for urban building models.

**International Journal of Applied Earth Observation and Geoinformation**. v. 35, p.247–258, 2015. DOI: <http://dx.doi.org/10.1016/j.jag.2014.09.012>.

WEHR, A.; LOHR, U. Airborne Laser Scanning – An Introduction and Overview. **ISPRS Journal of Photogrammetry & Remote Sensing**. v. 54, p. 68-82. 1999.

WEINMANN, M. **Reconstruction and Analysis of 3D Scenes From Irregularly Distributed 3D Points to Object Classes**. 1<sup>a</sup> 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.

WEINMANN, M.; WEINMANN, M.; MALLET, C.; BRÉDIF, M. A Classification-Segmentation Framework for the Detection of Individual Trees in Dense MMS Point Cloud Data Acquired in Urban Areas. **Remote Sensing**, v. 9, n. 277, 2017. DOI: 10.3390/rs9030277ff.

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.

WIESMANN, L.; MILIOTO, A.; CHEN, X.; STACHNISS, C.; BEHLEY, J. Deep Compression for Dense Point Cloud Maps. **IEEE Robotics and Automation Letters**. 2021. DOI: 10.1109/LRA.2021.3059633.

XIAO, W.; ZAFOREMSKA, A.; SMIGAJ, M.; WANG, Y.; GAULTON, R. Mean Shift Segmentation Assessment for Individual Forest Tree Delineation from Airborne Lidar Data. **Remote Sensing**. 2019, v. 11, n. 1263. 2019. DOI: <https://doi.org/10.3390/rs11111263>

XIE, Y.; TIAN, J.; ZHU, X. X. Linking Points With Labels in 3D: A Review of Point Cloud Semantic Segmentation. **IEEE Geoscience and remote sensing magazine**, v.8, n.4, p. 38–59, 2020. DOI: 10.1109/MGRS.2019.2937630.

XU, Y.; STILLA, U. Toward Building and Civil Infrastructure Reconstruction From Point Clouds: A Review on Data and Key Techniques. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 2857–2885, 2021.

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.