


UNIVERSIDADE FEDERAL DO PARANÁ

FABIANO PEIXOTO FREIMAN

DEFINIÇÃO E REPRESENTAÇÃO DA CORPORA GEOSPACIAL PARA MAPAS
INDOOR 3D A PARTIR DE NUVEM DE PONTOS

CURITIBA
2022



FABIANO PEIXOTO FREIMAN

DEFINIÇÃO E REPRESENTAÇÃO DA CORPORA GEOSPACIAL PARA MAPAS
INDOOR 3D A PARTIR DE NUVEM DE PONTOS

Tese apresentada ao Programa 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

CURITIBA
2022

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

Freiman, Fabiano Peixoto

Definição e representação da corpora geospacial para mapas indoor 3D a partir de nuvem de pontos / Fabiano Peixoto Freiman. – 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: Daniel Rodrigues dos Santos

1. Dados geoespaciais. 2. Aprendizado do computador. 3. Mapa tridimensional. 4. Corpora geospacial. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Ciências Geodésicas. III. Santos, Daniel Rodrigues dos. IV. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



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 **FABIANO PEIXOTO FREIMAN** intitulada: **DEFINIÇÃO E REPRESENTAÇÃO DA CORPORA GEOSPACIAL PARA MAPAS INDOOR 3D A PARTIR DE NUVEM DE PONTOS**, 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, 15 de Dezembro de 2022.

Assinatura Eletrônica
15/12/2022 12:55:56.0
DANIEL RODRIGUES DOS SANTOS
Presidente da Banca Examinadora

Assinatura Eletrônica
15/12/2022 13:30:22.0
JOÃO VITOR MEZA BRAVO
Avaliador Externo (UNIVERSIDADE FEDERAL DE UBERLÂNDIA)

Assinatura Eletrônica
15/12/2022 11:35:37.0
IVANILDO BARBOSA
Avaliador Externo (INSTITUTO MILITAR DE ENGENHARIA)

Assinatura Eletrônica
15/12/2022 11:23:54.0
SILVANA PHILIPPI CAMBOIM
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

AGRADECIMENTOS

Agradeço a todos que direta ou indiretamente fizeram parte da minha formação acadêmica, profissional e/ ou pessoal. Aos colaboradores da Universidade Federal Rural do Rio de Janeiro (UFRRJ), em especial aos professores do curso de Engenharia de Agrimensura e Cartográfica (2016). Aos integrantes do Programa de Pós-graduação em Ciências Geodésicas e colaboradores da Universidade Federal do Paraná (UFPR), nomeadamente ao professor orientador Daniel Rodrigues dos Santos. Aos professores componentes da banca de qualificação e defesa da Tese, Silvana Philippi Camboim, João Vitor Meza Bravo e Ivanildo Barbosa. Aos colegas de trabalho da Universidade Federal da Bahia (UFBA). Aos familiares e amigos (Dona Dulce, Antônio, Alessandra, Alex, Loram, Marcus, Jorge, Karina, Fabíola, Suzana, Camila, Ihasmyn, Allan, Pedro Paulo, Davison, Marciano, Sergio, Lais, Dudu, Zé Eduardo, Elias, e outros mais) pelo carinho, paciência, diversões e incentivo. E por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo fornecimento de auxílio financeiro no primeiro ano de doutoramento.

RESUMO

O termo *corpora* geoespaciais é definido como um conjunto de dados geoespaciais, sistematizados segundo determinados critérios de maneira que sejam representativos do espaço que se deseja mapear, e pode, a partir de concepções probabilísticas e combinatórias analisar a colocabilidade de um dado geoespacial em decorrência da descrição do ambiente de interesse, buscando revelar respostas a partir de observações estatísticas e identificação de padrões de uso para uma coleção de amostras digitais, fazendo parte da Programação da Linguagem Natural, subárea do Aprendizado de Máquina. No contexto tridimensional, *corpora* geoespaciais 3D podem ser formulados por conjuntos de nuvens de pontos LiDAR e apresentam alto custo computacional para armazenamento, manipulação e visualização. Além disso, não é um conjunto de dados estruturado e que apresente semântica. Para estruturar e extrair conhecimento formalizado destes *corpora* geoespaciais 3D é proposto um método de generalização cartográfica 3D usando aprendizado de máquina. A metodologia é baseada na Hipótese da Naturalidade aplicada sobre *corpora* geoespaciais 3D e na parcimônia da descrição geométrica de ambientes *indoor*. O método é dividido em 4 etapas. Primeiramente, a partir da análise de autossimilaridade estatística de *corpora* geoespaciais 3D foram propostos operadores de simplificação. Segundo, foram definidos aspectos semânticos dos *corpora* analisados para extração de *corpora* 3D especializados de elementos construtivos empregando uma estratégia de aprendizado de máquina. A terceira etapa consistiu na agregação e simplificação dos *corpora* conforme feições planas usando o algoritmo RANSAC. Finalmente, é aplicado uma estratégia de agregação de superfícies planas em subespaços, baseada na parcimônia da descrição. Os experimentos foram realizados em seis conjuntos de dados provenientes de um sistema LiDAR terrestre, no modo estático. Os resultados obtidos demonstraram que o aprendizado de máquina e a parcimônia da descrição, explorando a Hipótese da Naturalidade e o contexto da Linguagem Natural, auxiliaram na definição e representação estruturada de *corpora* geoespaciais 3D para ambientes *indoor*. Os operadores de simplificação reduziram a massividade do conjunto de pontos em 86%. Enquanto a sua aplicação associada ao processo de agregação estruturou e reduziu a massa de dados em 94%.

Palavras-chave: Hipótese da Naturalidade. Parcimônia da descrição. Nuvem de pontos LiDAR. Aprendizado de Máquina. *Corpora* Geoespaciais.

ABSTRACT

The term geospatial corpora is defined as a set of geospatial data, systematized according to certain criteria so that they are representative of the space to be mapped, and can, based on probabilistic and combinatorial concepts, analyze the collocation of a geospatial data in the occurrence of the description of the environment of interest, seeking to reveal answers from statistical observations and identification of usage patterns for a collection of fingerprints, as part of Natural Language Programming, subarea of Machine Learning. In the three-dimensional context, 3D geospatial corpora can be formulated by sets of LiDAR point clouds and present a high computational cost for storage, manipulation and visualization. Furthermore, it is not a structured and semantic dataset. To address this problem, a method for 3D cartographic generalization of LiDAR points clouds using deep learning is proposed. The proposed method is based on the naturalness hypothesis centered on LiDAR point clouds and parsimony of the geometric description of indoor environments. The contribution of the proposed four-fold. First, a set of operators for simplification tasks is defined from a LiDAR point clouds correlation statistical technique. Second, a deep learning technique is used for LiDAR point clouds semantic segmentation. Third, the RANSAC algorithm is executed to fit planar surfaces. Finally, a parsimony descriptor-based aggregation strategy is investigated. The proposed method was tested on six sets of LiDAR point clouds. The experimental results have demonstrated that by exploring the naturalness hypothesis centered on LiDAR point clouds, indoor environment modeling was successfully obtained for LoD2. The operators for simplification reduced the high volume of the LiDAR data by around 86%. On the other hand, the aggregation task showed that the LiDAR data can be reduced by around 94%.

Palavras-chave: Naturalness Hypothesis. parsimony of the geometric description. LiDAR Point Clouds. Deep Learning. Aggregation. Simplification. Geospatial Corpora.

LISTA DE FIGURAS

FIGURA 1-	ORGANIZAÇÃO DO TRABALHO	23
FIGURA 2 -	APLICAÇÕES DE MODELOS GEOMÉTRICOS 3D DE CIDADE.....	25
FIGURA 3 -	NUVENS DE PONTOS 3D (A) SLT (ESTÁTICO) (B) SLA	26
FIGURA 4 -	FLUXO DE PROCESSAMENTO DE NUVENS DE PONTOS	28
FIGURA 5 -	NUVENS DE PONTOS LIDAR (A) HIPSOMÉTRICA (B) SEGMENTADA (C) CLASSIFICADA	29
FIGURA 6 -	SEMANTIZAÇÃO (A) PARTES ESTRUTURAIS (B) MOBILIÁRIO	31
FIGURA 7 -	REDE NEURAL (a) SIMPLES (b) PROFUNDA (c) DIAGRAMA.....	32
FIGURA 8 -	MAPAS INTRNOS X MODELOS	40
FIGURA 9 -	LOD <i>CityGML</i> 2.0	41
FIGURA 10 -	DERIVAÇÃO DO GRAFO DE ADJACÊNCIA DO ESPAÇO <i>INDOOR</i> .	43
FIGURA 11 -	MODELO CONCEITUAL DE GENERALIZAÇÃO (MCMASTER E SHEA, 1992)	48
FIGURA 12 -	Nº DE PUBLICAÇÕES EM GENERALIZAÇÃO CARTOGRÁFICA	52
FIGURA 13 -	ÁREAS DE CONCENTRAÇÃO EM GENERALIZAÇÃO CARTOGRAFICA.....	53
FIGURA 14 -	PRINCÍPIAS PALAVRAS EMPREGADAS NOS TÍTULOS DOS ARTIGOS	55
FIGURA 15 -	PRINCIPAIS LACUNAS DE PESQUISA.....	60
FIGURA 16 -	NUVENS DE PONTOS LiDAR x MUNDO REAL E O VIRTUAL 3D ...	62
FIGURA 17 -	CORPUS LINGÜÍSTICO <i>VERSUS</i> CORPUS GEOESPACIAL	64
FIGURA 18 -	CARACTERÍSTICAS ESSENCIAIS DAS NUVENS DE PONTOS.....	66
FIGURA 19 -	AUTOMAÇÃO DE TAREFAS NA ESTRUTURAÇÃO DE NUVENS DE PONTOS LIDAR	69
FIGURA 20 -	CONJUNTO EXPERIMENTAIS (a) CONJUNTO I (b) CONJUNTO II..	80
FIGURA 21 -	FLUXOGRAMA DE APLICAÇÃO	81
FIGURA 22 -	DETERMINAÇÃO DA CURVATURA DE UM PONTO	82
FIGURA 23 -	VOXELIZAÇÃO (a) ORIGINAL (b) GRADE 3D (VOXEL).....	83
FIGURA 24 -	ESTRUTURAÇÃO OCTREE (a) CONJUNTO I (b) CONJUNTO II.....	84
FIGURA 25 -	VALORES DE RUGOSIDADE (a) CONJUNTO I (b) CONJUNTO II....	85
FIGURA 26 -	VALORES DE RUGOSIDADE (a) CONJUNTO I (b) CONJUNTO II....	86
FIGURA 27 -	VALORES DE RUGOSIDADE (a) CONJUNTO I (b) CONJUNTO II....	86
FIGURA 28 -	NUVENS DE PONTOS LiDAR SIMPLIFICADAS A PARTIR DO VOXEL	87
FIGURA 29 -	RESULTADO DO REGISTRO DE NUVENS DE PONTOS	88
FIGURA 30 -	PROCESSO DE SIMPLIFICAÇÃO (a) NP INTERMEDIÁRIA (b) NP FINAL	89
FIGURA 31 -	CONJUNTOS EXPERIMENTAIS.....	97
FIGURA 32 -	FLUXO DEEP LEARNING DE SIMPLIFICAÇÃO	97
FIGURA 33 -	EXPERIMENTOS: DADOS SIMPLIFICADOS	99
FIGURA 34 -	TAXA DE SIMPLIFICAÇÃO.....	101

FIGURA 35 -	CARACTERÍSTICA GEOMÉTRICAS (a) VETORES NORMAIS (b) AGREGAÇÃO.....	103
FIGURA 36 -	ARQUITETURA RNC APLICADA NO PROCESSO DE AGREGAÇÃO.....	109
FIGURA 37 -	AGREGAÇÃO DE PONTOS EM SUPERFÍCIES PLANAS.....	112
FIGURA 38 -	RESULTADOS GERAIS DO PROCESSO DE AGREGAÇÃO DE PONTOS	114
FIGURA 39 -	ELEMENTOS ESTRUTURAIS AGRUPADOS (HORIZONTAIS E VERTICAIS).....	116
FIGURA 40 -	DELIMITAÇÃO DE SUBESPAÇOS POR FEIÇÕES VERTICAIS	117
FIGURA 41 -	ERROS PREDITIVOS (a) ESTRUTURAIS (b) PORTAS E JANELAS (c) MOBÍLIA.....	117
FIGURA 42 -	OBJETOS GERAIS AGREGADOS (CADEIRAS, MESAS, ARMÁRIOS, etc.).....	119
FIGURA 43 -	REPRESENTAÇÃO DA PRECISÃO DE AGREGAÇÃO PONTUAL E ROTULAÇÃO	120
FIGURA 44 -	AGREGAÇÃO PONTUAL (a) ALGORITMO CONNECTED COMPONENT (b) DL.....	121
FIGURA 45 -	ESTIMATIVAS DE PLANOS ALGORITMO RANSAC (a) CONJUNTO I (b) CONJUNTO II	122
FIGURA 46 -	TRANSFORMAÇÃO DE PONTOS PARA AGREGADOS PONTUAIS (a) ELEMENTOS VERTICAIS (b) ELEMENTOS HORIZONTAIS.....	123
FIGURA 47 -	AGREGADOS PONTUAIS (a) VISTA SUPERIOR (b) SUPERIOR INTERNA (2º ANDAR).....	125
FIGURA 48 -	ESTIMATIVA DE PLANOS HORIZONTAIS E VERTICAIS (a) 2º PAVIMENTO) (b) 1º PAVIMENTO	126
FIGURA 49 -	ESTIMATIVA DE PLANOS HORIZONTAIS E VERTICAIS (a) 2º PAVIMENTO) (b) 1º PAVIMENTO	127
FIGURA 50 -	IDENTIFICAÇÃO DE SUBESPAÇOS	129
FIGURA 51 -	FLUXO (a) NUVEM DE PONTOS LiDAR BRUTA (b) PROCESSO DE SIMPLIFICAÇÃO (c) DETERMINAÇÃO DE AGREGADOS PONTUAIS CONFORME RÓTULOS (d) ESTIMATIVA DE PLANOS (e) CORREÇÕES (f) OTIMIZAÇÃO	132
FIGURA 52 -	RELACIONAMENTO TOPOLÓGICO (a) NUVEM DE PONTOS LiDAR (b) PLANOS ADJACENTES	133
FIGURA 53 -	ÁREAS OCLUSAS (a) VISÃO FRONTAL (b) VISÃO LATERAL	135
FIGURA 54 -	ELEMENTOS ESTRUTURAIS AGREGADOS (HORIZONTAIS E VERTICAIS) E DEFINIÇÃO DE PLANOS CANDIDATOS	137
FIGURA 55 -	DEFINIÇÃO DE SUBESPAÇOS (a) CONJUNTO I (b) CONJUNTO II (c) CONJUNTO III (d) CONJUNTO IV (e) CONJUNTO V (f) CONJUNTO VI	138
FIGURA 56 -	HN CENTRADA EM NUVEM DE PONTOS LiDAR E COMPILAÇÃO DE SUBESPAÇOS (a) CONFIGURAÇÃO VETORES NORMAIS (b) SUBESPAÇO.....	138

FIGURA 57 -	CONSTRUÇÃO DE SUBESPAÇOS (a) METODOLOGIA (b) POISSON (c) TRIANGULAÇÃO	139
FIGURA 58 -	INFLUÊNCIA DE ÁREAS E OCLUSÕES (a) METODOLOGIA (b) POISSON (c) TRIANGULAÇÃO	140
FIGURA 59 -	EDIFICAÇÃO (a) AGREGADOS PONTUAIS (b) SUBESPAÇO TÉRREO (c) SUBESPAÇO 1º ANDAR	141
FIGURA 60 -	FORMAÇÃO DE SUBESPAÇOS (a) VISÃO EXTERNA (b) VISÃO INTERNA	142
FIGURA 61 -	PROBLEMAS (a) ERRO DE ESTIMAIVA (b) PLANO OBLÍQUO (ESCADA)	144

LISTA DE QUADROS

QUADRO 1 - DESAFIOS NA CONSTRUÇÃO DE REPRESENTAÇÕES.....	18
QUADRO 2 - APLICAÇÕES DE NUVENS DE PONTOS	27
QUADRO 3 - PESQUISAS EM GENERALIZAÇÃO CARTOGRÁFICA (2021).....	57
QUADRO 4 - ESTRUTURA CONCEITUAL DO PROCESSO DE GENERALIZAÇÃO ...	72
QUADRO 5 - EXEMPLOS DE MÉTRICAS PERSPECTIVAS DE AUTOSSIMILARIDADE	73
QUADRO 6 – CARACTERÍSTICAS DOS MÉTODOS DE PROCESSAMENTO DE NUVENS DE PONTOS	107
QUADRO 7 – PARÂMETROS EMPREGADOS NO MÉTODO PROPOSTO	122
QUADRO 8 – CARACTERÍSTICAS DOS MÉTODOS DE PROCESSAMENTO DE NUVENS DE PONTOS LiDAR	143

LISTA DE TABELAS

TABELA 1 -	NÚMERO DE PONTOS REMANESCENTE NO CONJUNTO INTERMEDIÁRIO	88
TABELA 2 -	NÚMERO DE PONTOS – NUVENS FINAIS.....	89
TABELA 3 -	RAZÃO DE SIMPLIFICAÇÃO	91
TABELA 4 -	Nº DE PONTOS REMANESCENTES.....	100
TABELA 5 –	PRECISÃO DE PREDIÇÃO DO ALGORITMO (ESTRUTURAS) ...	118
TABELA 6 –	ACURÁCIA E PRECISÃO DE PREDIÇÃO DO ALGORITMO (OBJETOS)	120

LISTA DE ABREVIATURAS OU SIGLAS

2D	- Bidimensional
3D	- Tridimensional
AM	- Aprendizado de Máquina
BDG	- Banco de Dados Geográfico
BIM	- Sistema de Informação Geográfica 3D
CAD	- <i>Computer Aided Design</i>
CityGML	- <i>City Geography Markup Language</i>
CG	- Computação Gráfica
DP	- <i>Deep Learning</i>
ES	- Engenharia de Software
IFC	- <i>Industry Foundation Classes</i>
ICA	- <i>International Cartographic Association</i>
LiDAR	- <i>Light Detection and Ranging</i>
LoD	- <i>Level of Detail</i>
MMQ	- Minimização dos Mínimos Quadrados
OGC	- <i>Open Geospatial Consortium</i>
SIG 3D	- Sistema de Informação Geográfica 3D
SS	- Segmentação Semântica
RN	- Redes Neurais
RNC	- Redes Neurais Convolucionais

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	16
1.1 CONSIDERAÇÕES INICIAIS	16
1.2 PROBLEMA DE PESQUISA E MOTIVAÇÃO	17
1.3 POTENCIAL DE CONTRIBUIÇÃO	21
1.4 OBJETIVOS.....	22
1.5 ORGANIZAÇÃO DO TRABALHO	23
 CAPÍTULO 2 - REVISÃO DE LITERATURA	25
2.1 NUVENS DE PONTOS LIDAR.....	26
2.1.1 Segmentação e classificação de nuvens de pontos LiDAR.....	28
2.1.1.1 Segmentação Semântica	30
2.1.1.2 Estratégias baseadas em DL	32
2.2 CARTOGRAFIA <i>INDOOR</i>	35
2.2.1 Espaço interno	36
2.2.2 Mapa <i>indoor</i>	39
2.2.3 Padrões para informações espaciais de espaços internos	40
2.2.4 IndoorGML	42
2.3 GENERALIZAÇÃO CARTOGRÁFICA	44
2.3.1 Aspectos teóricos e evolutivos	46
2.3.2 Aspectos bibliométricos	51
2.3.3 Desafios na generalização cartográfica	57
2.4 CONCLUSÕES DO CAPÍTULO	60
 CAPÍTULO 3 - GENERALIZAÇÃO E NUVENS DE PONTOS LIDAR.....	62
3.1 CORPUS GEOESPACIAL	63
3.2 HIPÓTESE DA NATURALIDADE CENTRADA EM NUVENS DE PONTOS	66
3.2.1 Aplicação da HN centrada em nuvem de pontos LiDAR	69
3.3 GENERALIZAÇÃO 3D DE NUVENS DE PONTOS LIDAR.....	70
3.4 CONCLUSÕES DO CAPÍTULO	74
 CAPÍTULO 4 - SIMPLIFICAÇÃO POR SIMILARIDADE	76
4.1 TRABALHOS RELACIONADOS	77
4.2 PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO	79
4.2.2 Simplificação baseada em voxelização	83
4.3 RESULTADOS E DISCUSSÕES.....	84
4.3.1 Determinação de pontos de borda e intermediários	85
4.3.2 Simplificação baseada em voxel	87
4.3.3 Método Proposto <i>Versus</i> Outros Métodos De Simplificação.....	90

4.2	CONCLUSÕES DO CAPÍTULO	92
CAPÍTULO 5 - SIMPLIFICAÇÃO BASEADA EM HN		94
5.1	PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO	96
5.2	RESULTADOS E DISCUSSÕES.....	99
5.3	MÉTODO PROPOSTO <i>VERSUS</i> OUTROS MÉTODOS DE SIMPLIFICAÇÃO ..	100
5.4	CONCLUSÕES DO CAPÍTULO	102
CAPÍTULO 6 - AGREGAÇÃO DE SUPERFÍCIES PLANAS BASEADA NA HN		103
6.1	TRABALHOS RELACIONADOS	104
6.1.1	Principais abordagens	105
6.2	PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO	108
6.2.1	Método.....	108
6.2.1.1	Otimização RNC	109
6.2.1.2	Estimativa e agregação de pontos em superfícies planas	112
6.3	RESULTADOS E DISCUSSÕES.....	114
6.3.1.	Métricas de avaliação	115
6.3.2	Avaliação dos resultados	115
6.3.2.1	Comparação com métodos tradicionais.....	120
6.3.2.2	Transformação de agregados pontuais em superfícies planas	121
6.3.3	Implementação e detalhes de performance	123
6.3.4	Discussões	124
6.4	CONCLUSÕES E RECOMENDAÇÕES DO CAPÍTULO	128
CAPÍTULO 7 - AGREGAÇÃO DE NUVEM DE PONTOS EM SUBESPAÇOS		129
7.1	PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO	131
7.1.1	MÉTODO	131
7.1.1.1	Definição do algoritmo.....	131
7.1.1.2	Remoção de pontos espúrios e minimização de oclusões	132
7.1.1.3	Definição de fases e superfícies paramétricas	134
7.1.1.4	Otimização.....	136
7.2	RESULTADOS E DISCUSSÕES.....	136
7.2.1	Discussões	140
7.3	CONCLUSÕES E RECOMENDAÇÕES DO CAPÍTULO	144
CAPÍTULO 8 - CONSIDERAÇÕES FINAIS		145
8.1	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	146
REFERÊNCIAS		149

CAPÍTULO 1 - INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

Um modelo tridimensional (3D) de cidade consiste em uma representação computacional 3D de elementos urbanos (internos e externos a edificações) (BILJECKI et al., 2016). Cada objeto representado é uma estrutura 3D que consiste, quando completamente modelada, em elementos geométricos, topológicos e informações semânticas, e a sua utilização vem se destacando devido aos novos paradigmas relacionados a construção de *Smart Cities* e *Digital Twins Cities* (BILJECKI et al., 2016; ARROYO OHORI et al., 2018; TANG et al., 2020; DÖLLNER, 2020).

Atualmente, a construção geométrica de representações 3D é baseada em nuvens de pontos 3D que podem ser obtidas com o emprego de sensores LiDAR (*Light Detection and Ranging*). Na prática, o LiDAR é capaz de gerar valores de ângulos horizontais e verticais, e distâncias do sensor são empregados para a aquisição de nuvens de pontos LiDAR, classificadas como dados espaciais geométricos de base para a construção de representações 3D (DÖLLNER, 2020). A partir de nuvens de pontos LiDAR pode-se construir as abstrações 3D do mundo real e, também, ser acrescentado atributos semânticos (GAROFALO; FARENGA, 2019; POUX, 2019).

Este processo é possibilitado devido as nuvens de pontos LiDAR, bem como ambientes geoespaciais, apresentarem características geométricas repetitivas independente das infinitas variações que possam apresentar, principalmente em ambientes *indoor*. Segundo Döllner (2020), as nuvens de pontos LiDAR podem ser caracterizadas como enunciados geoespaciais o que permite que sejam exploradas computacionalmente a partir de métodos estatísticos. Portanto, pode ser entendida como um corpus geoespacial 3D, e nesta concepção, faz parte do processo da Linguagem Natural (LN) – conceito proveniente da Linguística de Corpus (LC).

Na área da LC um conjunto de amostras linguísticas (corpora, plural de corpus) sistematicamente coletado é analisado para identificar a dinâmica e os significados das palavras. Tem como objetivo a exploração de corpora linguísticos suficientemente extensos em amplitude, de maneira que sejam representativos da totalidade do uso linguístico por evidências extraídas por meio de computador (SÁNCHEZ, 1995). A Ciência da Computação objetiva entender a representatividade de corpora e gerar hipóteses e soluções a partir do Processamento

da Linguagem Natural (PLN), preocupando-se não somente com um objeto isolado, mas com o entendimento semântico de toda a estrutura (BRODEUR et al., 2003).

Devido as limitações cognitivas e a mutação da língua em decorrência do dia a dia, a maioria dos enunciados humanos são muito mais simples, repetitivos e previsíveis a partir da aplicação de métodos estatísticos modernos (HINDLE et al., 2016), fato que se repete quando se analisa nuvens de pontos LiDAR. A partir da definição de Sánchez (1995) no âmbito da linguística, conjuntos de geodados 3D coletados sobre uma determinada perspectiva recaem sobre o conceito de corpora geoespaciais 3D, ou seja, conjuntos de dados geoespaciais 3D coletados sistematicamente de acordo com a necessidade, suficientemente extensos em amplitude de maneira que sejam representativos da totalidade do âmbito geoespacial analisado, dispostos e explorados em ambiente computacional, com a finalidade de propiciar resultados vários e úteis para descrição e análise geoespacial.

A formação de corpora geoespaciais 3D está relacionada com a compilação de um banco de dados geográfico, que quando formado por nuvens de pontos LiDAR esbarra em um problema recorrente, principalmente quando estão relacionados a quesitos geométricos, isto é, as características intrínsecas às nuvens de pontos LiDAR. Quando densas, podem retratar ambientes geoespaciais, entretanto consomem uma grande quantidade de armazenamento e são puramente geométricas, com ausência de informações topológicas ou semânticas sobre os objetos (POUX, 2019; DÖLLNER, 2020). Estes fatores impossibilitam que a exploração destes corpora 3D seja efetivamente representativa da realidade física em meio digital, sendo necessário aplicar processos computacionais para a adequação de corpora geoespaciais 3D a uma utilização específica, recaindo sobre um processo de generalização cartográfica 3D.

No entanto, regras e operadores computacionais para o contexto 3D não estão completamente disponíveis (SESTER, 2020) e necessitam de estratégias adequadas de generalização 3D em relação ao nível de detalhamento (*Level of Detail* – LoD) exigido por uma determinada aplicação.

1.2 PROBLEMA DE PESQUISA E MOTIVAÇÃO

A generalização cartográfica digital tem como propósito reduzir a base de dados primária para um mínimo necessário, mas mantendo as propriedades espaciais relevantes do conjunto (MCMASTER; SHEA, 1992; SESTER, 2020; SCHIEWE, 2021). Ao usar uma abordagem computacional, uma separação é feita entre o conteúdo de informação do sistema e

a apresentação dessas informações em forma gráfica, que pode ser uma imagem; um mapa; ou um modelo cartográfico (MOREHOUSE, 1995).

Deste modo, o processo de generalização cartográfica de um corpus geoespacial 3D não está restrito aos requisitos de visualização, mas a manipulação do conjunto de dados que dão origem aos corpora 3D analisados. Além das razões usuais da Cartografia para operacionalizar a generalização, no âmbito digital, também é necessário considerar os aspectos econômicos, a qualidade e as razões multipropósito (MULLER, 1991; CEBRYKOW, 2017). Logo, corpora geoespaciais 3D devem ser manipulados a partir de algoritmos para derivar corpora secundários (especializados) ou para produzir uma representação do mundo real em um ambiente digital, considerando um LoD específico.

As nuvens de pontos LiDAR brutas, neste contexto, compõem o principal elo entre o mundo real e o virtual (POUX, 2019), e cada uma forma um corpus geoespacial 3D primário empregado como informação geométrica para a compilação de representações, ou seja, um corpus geoespacial 3D é tido como uma amostra representativa do espaço. As dificuldades para sua exploração estão relacionadas às características dos dados geoespaciais que o compõem. No caso de uma nuvem de pontos LiDAR os principais obstáculos estão relacionados com a sua estrutura, um conjunto massivo e não ordenado de pontos com coordenadas x, y, z, despojado de aspectos de conectividade, topologia ou semântica, tornando-o de difícil interpretação (QUADRO 1) (POUX, 2019; DÖLLNER, 2020; STILLA, 2020).

QUADRO 1 - DESAFIOS DE PROCESSAMENTOS E ANÁLISE DE CORPORA 3D

Problemas	Descrição
Ruídos e oclusões	Dados não estruturados e apresentam erros aleatórios e sistemáticos. Estes erros estão associados à construção do próprio sensor, ao processo de registro de nuvens de pontos LiDAR ou do <i>Simultaneous Localization and Mapping</i> (SLAM). Além disso, a presença de ruídos causados por superfícies reflexivas, ou transparentes, como os vidros, inserem ruídos na cena perfilada, ocasionando dificuldades na interpretação de estruturas (paredes, teto, piso etc.). Áreas oclusas inserem desafios para estimar estruturas completas.
Massividade	No processo de representação 3D de ambientes, os algoritmos devem lidar com corpora 3D massivos, que crescem exponencialmente conforme o tamanho da área que se deseja representar. Portanto, estratégias de simplificação (subamostragens) para minimizar a complexidade de cálculos computacionais sobre os corpora são necessários.
Segmentação e classificação	Interpretar os corpora 3D formado por nuvens de pontos LiDAR é uma tarefa desafiadora devido à alta redundância, aleatoriedade de distribuição de pontos e a falta de estrutura explícita deste conjunto de dados sendo necessário aprimoramento de métodos automáticos para segmentar e extrair informações semânticas sobre corpora ambíguos e dinâmicos.

FONTE: O autor (2021).

Consonante ao QUADRO 1, os corpora geoespaciais 3D formados por nuvens de pontos LiDAR são massivos e crescem exponencialmente conforme se aumenta a área e a frequência de perfilamento, além de serem isentos de semântica (ERVAN; TEMELTAŞ; 2019; JI et al., 2019; ZOU et al., 2021). Esses fatores justificam a necessidade da redução de volumes de dados para que o processamento computacional de extração de semântica e estruturação do conjunto seja eficiente. O problema central é a necessidade da aplicação de métodos que permitam selecionar e classificar os objetos presentes no ambiente e, conseqüentemente, definir suas relações de distribuição espacial. Desta forma é possível minimizar a massividade de corpora 3D e interpretá-los.

A formação de corpora 3D sem nenhum tipo de processamento tem uma função representativa da realidade espacial, entretanto, para obter relacionamentos espaciais e representações coerentes é necessário aplicar processos computacionais para extrair conhecimento formalizado. Neste caso, utiliza-se de corpora 3D gerais como fonte para criação e representação de corpora especializados de acordo com um determinado objetivo empregando aspectos da LN. O ideal é aplicar um método que seja capaz de lidar com os obstáculos, como presença de ruídos, áreas oclusas e a densidade de pontos, além de atender a um propósito específico em decorrência das necessidades do usuário e do tipo de espaço de interesse, que no caso deste trabalho são ambientes internos a edificações.

Na LN e análise de software, a derivação de corpora especializados é frequentemente baseada em abordagens de Aprendizado de Máquina (AM) que são aplicadas para compreender corpora linguísticos, fornecendo instrumentos eficazes para analisar se um determinado domínio de problema corresponde ou tem propriedades estatísticas semelhantes a grandes corpora gerais de LN. Busca revelar respostas para fenômenos como uma abordagem metodológica teórica e metateórica a partir de observações estatísticas e identificação de padrões de uso de uma coleção de amostras digitais (SARDINHA, 2004). A descoberta mais importante nessa área é que o conjunto de dados que forma os corpora apresentam enunciados repetitivos e, em consequência, previsíveis a partir de processos estatísticos (DÖLLNER, 2020).

Considerando que as nuvens de pontos LiDAR são enunciados espaciais, que compõem corpora geoespaciais 3D, bem como o ambiente geoespacial, são em última análise, estatisticamente repetitivos, permitindo modelá-las por meio de métodos matemáticos e algoritmos computacionais. As nuvens de pontos LiDAR, portanto, constituem corpora geoespaciais 3D aos quais a tecnologia de AM pode ser aplicada aproveitando as propriedades

estatísticas de distribuição estimadas sobre corpora gerais formado por nuvens de pontos LiDAR brutas para que se derive corpora geoespaciais 3D especializados da realidade.

Considerando que as nuvens de pontos LiDAR formam corpora geoespaciais 3D, Döllner (2020), seguindo o esquema de argumentação originalmente criado para Engenharia de Software (HINDLE et al., 2016) formulou a Hipótese da Naturalidade (HN) para este contexto: *"as nuvens de pontos LiDAR no domínio geoespacial são menos complexas e apresentam repetibilidade. Suas propriedades estatísticas são previsíveis e podem ser interpretadas a partir de métodos estatísticos e linguagem de programação, sendo aproveitadas para análises geoespaciais"*. Logo, a interpretação desse conjunto de dados baseada em AM pode, de forma eficiente e robusta, organizar e generalizar corpora geoespaciais 3D sem esquemas de modelagem explicitamente definidos, minimizando os principais desafios, a saber: a falta de estrutura e semântica (POUX, 2019; XUE et al., 2020).

Além disso, técnicas de AM podem ser usadas para derivar corpora 3D geoespaciais mais simples que o original, acelerar os fluxos de trabalho e auxiliar na construção de representações 3D. Note que, esses fatores recaem sobre aspectos da generalização cartográfica. Entretanto, ainda é incipiente estratégias computacionais que visem estes processos considerando os aspectos de corpora geoespaciais 3D formados por nuvens de pontos LiDAR. Ademais, os questionamentos são relacionados aos aspectos de ambientes externos (BILJECKI et al., 2016), sendo que ambientes *indoor* demandam atributos diferentes (KIM; LI, 2019) relacionados a confecção de espaços virtuais para a navegação e orientação de usuários de uma determinada edificação.

Assim, os procedimentos aplicados para simplificar, agregar e representar corpora geoespaciais também devem basear-se sobre aspectos do ambiente a ser representado. No caso de ambientes internos, busca-se considerar que corpora geoespaciais 3D especializados devem incidir sobre parcimônia da descrição (TULSIANI et al., 2018), ou seja, o significado do todo é composto pelo significado de geometrias auto similares, recaindo sobre o conceito de estrutura fractal (MANDELBROI, 1975). Nesse contexto, deriva-se corpora geoespaciais 3D especializados sobre a perspectiva de que um ambiente *indoor* é formulado por geometrias planas que em conjunto definem uma série de subespaços não sobrepostos, conforme IndoorGML¹ (2020) (LI, et al., 2008; ZLATANOVA et al., 2014; DIAKITÉ et al., 2017).

¹ IndoorGML. Disponível em: <http://docs.opengeospatial.org/is/14-005r5/14-005r5.html#12>. Acesso em: 12 jun. 2021.

Logo, considerando que corpora geoespaciais 3D são bases primárias para a construção e representação virtuais 3D e fazem parte da LN, e ambientes *indoor* são formulados computacionalmente pela parcimônia da descrição, o seguinte problema de pesquisa foi definido: 1) Como sistematizar corpora geoespaciais 3D formados por nuvens de pontos LiDAR de maneira que possam propiciar resultados úteis para a descrição e análise de ambientes internos como uma etapa introdutória na geração de mapas 3D de ambientes *indoor*?

Neste quesito, a partir de técnicas de AM realiza-se a interpretação da HN para corpora geoespaciais 3D (dados brutos) detectando graus de similaridade entre as propriedades geométricas de nuvens de pontos LiDAR para a compilação de corpora geoespaciais 3D especializados; com entendimentos semânticos da estrutura interna de uma edificação. Isso é possível devido a consideração de que nuvens de pontos LiDAR são enunciados estatisticamente previsíveis. Devido a esta previsibilidade, a partir de algoritmos computacionais, é possível inferir graus de similaridade geométrica para generalizar corpora geoespaciais 3D não estruturados e semantizados. Então: se um conjunto de nuvens de pontos LiDAR proveniente do perfilamento de ambientes *indoor* formam corpora geoespaciais 3D que apresentam previsibilidade estatística e matemática, então, a partir da exploração da HN por meio de algoritmos computacionais realiza-se a análise, interpretação e generalização de corpora geoespaciais 3D de nuvens de pontos. Transformando-os em corpora geoespaciais 3D específicos, organizados e estruturados geometricamente conforme distribuição espacial dos elementos que os compõem.

Partindo-se deste pressuposto, na Subseção 1.3 é apresentado o potencial de contribuição deste trabalho.

1.3 POTENCIAL DE CONTRIBUIÇÃO

Quando se trata de generalização de corpora geoespaciais 3D no domínio da construção de representações digitais de ambientes *indoor*, dois aspectos são passíveis de contribuição: a) Pressupostos e; b) Metodologia de generalização. O primeiro diz respeito à identificação de quais LoDs serão necessários para representação 3D de ambientes internos, especificando restrições e operadores de generalização 3D para definir um escopo central, considerando a quantidade de dados e o desempenho computacional. A metodologia definirá como generalizar, em consonância com as imposições exigidas para ambientes internos, a formação, caracterização e definição de corpora geoespaciais 3D.

Dos métodos empregados para a generalização e derivação de corpora geoespaciais 3D, a simplificação é o operador largamente implementado (XUAN et al., 2018; DOVRAT et al., 2019; ZOU et al., 2021), em sua maioria, para ambientes externos. Para ambientes internos, as estratégias são raras e não consideram aspectos de agregação para a compilação de geometrias 3D topologicamente consistentes. Consequentemente, é necessária uma solução que possibilite simplificar e interpretar corpora geoespaciais 3D conforme características de ambientes *indoor*.

Baseado na HN centrada em corpora geoespaciais 3D e motivado pela necessidade de desenvolvimento de soluções de generalização 3D aplicadas a ambientes internos que, segundo Sester (2020), não estão completamente disponíveis, este trabalho de pesquisa apresenta as seguintes contribuições:

- 1) Foram definidos pressupostos gerais de generalização cartográfica 3D considerando as características de ambientes internos para projetar adequadamente operadores de simplificação e agregação, baseados na parcimônia da descrição e HN centrada em corpora geoespaciais 3D, bem como para minimizar a massividade de processamento de forma automática;
- 2) Foi empregada uma variação AM para a generalizar corpora geoespaciais 3D formados por nuvens de pontos LiDAR, segmento-os em corpora 3D especializados de acordo com a semântica de cada elemento que compunha a cena perfilada, conforme rotulação definida pela interpretação da autossimilaridade;
- 3) Foram discutidas estratégias de generalização 3D que possibilitem a minimização de custo computacional e de armazenamento, além de inserir novos conceitos relacionados a formação de corpora geoespaciais 3D.

Para alcançar estas premissas, os objetivos listados na Subseção 1.4 foram traçados.

1.4 OBJETIVOS


O objetivo geral deste trabalho é implementar um fluxo estratégico de generalização de corpora geoespaciais 3D formados por nuvens de pontos LiDAR baseado em técnica de AM e parcimônia da descrição como etapa preliminar para a definição e representação de corpora geoespaciais 3D especializados conforme abstrações geométricas de ambientes internos. Para alcançar o objetivo geral foram definidos os seguintes objetivos específicos:

- a) Identificar os aspectos do processo de generalização cartográfica de corpora geoespaciais 3D considerando características de espaços internos;
- b) Propor operadores de generalização cartográfica, baseados em (a), para simplificar subespaços de ambientes internos previamente perfilados;
- c) Aplicar uma estratégia AM para auxiliar na simplificação, agregação e interpretação de corpora geoespaciais 3D baseada na autossimilaridade, considerando premissas definidas em (b);
- d) Agregar subespaços conforme parcimônia da descrição como um processo de otimização dos resultados definidos em (c);
- e) Verificar a aplicabilidade da HN centrada em nuvens de pontos LiDAR e parcimônia da descrição para generalizar corpora geoespaciais 3D e construir representações geométricas virtuais de ambientes internos a edificações.

Na Subseção 1.6 é apresentada a organização e estruturação deste trabalho.

1.5 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado em 8 Capítulos, conforme ilustrado no fluxograma da FIGURA 1.



FONTE: O autor (2022).


Primeiramente, no Capítulo 1 é descrita a problematização do trabalho em conjunto com os objetivos. No Capítulo 2 os principais tópicos relacionados a temática discutida são apresentados e foram empregados para a confecção dos processos propostos. No Capítulo 3, discute-se aspectos centrados na nuvem de pontos LiDAR, e como formam corpora geoespaciais 3D. No Capítulo 4, apresenta-se um processo prático de simplificação corpora 3D baseado no princípio da similaridade. Já nos Capítulos 5 e 6, processos de AM são empregados para explorar a potencialidade do corpus geoespacial 3D, respectivamente, para simplificar e extrair geometrias significativas do conjunto primário de dados. No Capítulo 7, emprega-se um processo de otimização para inferir subespaços completos. Por fim, as conclusões são apresentadas no Capítulo 8. A compilação desses Capítulos deu origem às seguintes publicações científicas:

- 1) FREIMAN, F. P.; SANTOS, D. R. dos. Generalização Cartográfica: Desafios e Perspectivas. **Revista Brasileira de Cartografia**, [S. l.], v. 74, n. 3, p. 772–788, 2022.
- 2) FREIMAN, F. P.; SANTOS, D. R. dos; REIS, A. R. N. 3D Cartographic Generalization of LiDAR Points Cloud Based on the Principle of Self-Similarity of a Deterministic Fractal Structure. **Anuário de Geociências** (Aceito para publicação)
- 3) FREIMAN, F. P.; SANTOS, D. R. dos. Generalização Cartográfica 3D de Nuvens de Pontos LiDAR usando Deep Learning: um estudo de caso em ambientes internos. XII Colóquio de Ciências Geodésicas e V Simpósio Brasileiro de Geomática. 2022 (**Trabalho premiado na área de Cartografia** – Capítulo Brasil e Chile da IEEE/GRSS).

CAPÍTULO 2 - REVISÃO DE LITERATURA

O principal desafio na construção de representações de ambientes urbanos relaciona-se ao ciclo de vida de uma cidade, é o fato de ser dinâmico e a sua complexidade se modifica consoante ao crescimento populacional. São espaços heterogêneos, fragmentados e dispersos com usos e conteúdos sociais diversificados. É um sistema que além de sua expansão horizontal tem, globalmente, a tendência de expansão vertical devido às limitações de espaços vazios em centros urbanos (YING et al., 2017). A expansão ocasiona demandas por novas tecnologias e formas de representação da paisagem, inserindo relevância no contexto da cartografia tridimensional (3D) que pode ser aplicada em uma gama de tarefas potenciais relacionadas ao planejamento e gestão do solo urbano (FIGURA 2).

FIGURA 2 - APLICAÇÕES DE MODELOS GEOMÉTRICOS 3D DE CIDADE



FONTE: O autor (2022).

Dentre as possibilidades de aplicação, devido aos seres humanos realizarem grande parte de suas tarefas diárias em ambientes internos (*indoor*), o mapeamento e sua representação 3D vêm se destacando, principalmente em construções amplas e de grande circulação de pessoas, como aeroportos, museus e hospitais. Áreas como a Cartografia e a indústria da Arquitetura, Engenharia e Construção (AEC) apresentam interesse nesta temática e inserem conceitos como a Cartografia *Indoor* 3D e o BIM, respectivamente. Partindo deste contexto, o Capítulo pretende apresentar os principais tópicos relacionados a esta temática: nuvens de pontos LiDAR (Seção 2.1), Cartografia Indoor (Seção 2.2) e aspectos gerais da generalização cartográfica (Seção 2.3).

2.1 NUVENS DE PONTOS LIDAR

Uma nuvem de pontos LiDAR (FIGURA 3) é basicamente um conjunto de pontos dotados de um sistema de coordenadas 3D $\{x, y, z\}$ (+ atributos, a depender das características do sensor empregado) no espaço euclidiano. Podem ser adquiridas por sensores² LiDAR (*Light Detection and Ranging*), no modo dinâmico ou estático em plataformas aéreas (Sistema LiDAR Aéreo – SLA) e/ou terrestres (SLT) e/ou sensores de profundidade. Sensores passivos, como as câmeras (térmica, infravermelha e RGB) também são ferramentas comuns para a criação de nuvens de pontos LiDAR por meio de Fotogrametria e da Visão Computacional.

FIGURA 3 - NUVENS DE PONTOS 3D (A) SLT (ESTÁTICO) (B) SLA



FONTE: O autor (2022).

A nível regional as nuvens de pontos LiDAR (geralmente provenientes do SLA) são empregadas e associadas a dados fotogramétricos para fins de mapeamento e construção de produtos cartográficos bidimensionais (2D) (QUADRO 2). Atualmente, estratégias em níveis locais e municipais buscam aprimorar as técnicas de processamento para que representações 3D possam ser efetivamente empregadas em análises espaciais, gestão e monitoramento de estruturas, além de atividades de planejamento urbano. No contexto de uma representação 3D, uma nuvem de pontos é o nível de abstração mais baixo de um ambiente, a partir da qual é possível construir modelos geométricos e extrair informações semânticas. Devido à variedade de sensores e processos de aquisição, elas são representações 3D universais e aplicadas para representar tridimensionalmente qualquer tipo de objeto físico, paisagem, regiões geográficas ou infraestruturas, em diferentes escalas e precisões (DÖLLNER, 2020).

² Neste trabalho não serão descritos os princípios de funcionamento de cada sensor. Informações adicionais podem ser obtidas em Shan; Toth (2018).

QUADRO 2 - APLICAÇÕES DE NUVENS DE PONTOS

Escala	Sensor	Aplicação
Em nível de objeto	Câmeras (Fotogrametria Terrestre), SLT (Método de Triangulação)	Identificação de alvos, inspeções de estruturas, Engenharia Reversa, controle de qualidade, criação de jogos.
Em nível local	SLT (modo estático ou dinâmico) (<i>Hand-held Laser Scanner</i> , <i>Backpack-Mounted Laser Scanner</i>) e Sistemas de Aeronaves Remotamente Pilotadas (<i>Remotely Piloted Aircraft Systems</i> – RPA)	Navegação autônoma, inspeção de edificações (<i>indoor/ outdoor</i>), BIM, Cartografia <i>indoor</i> , planejamento e gestão da construção, cálculo de volumes, monitoramento agrícola, robótica, mapas de navegação e determinação de rotas de emergências, documentação e arquitetônica histórica e representação 3D.
Em nível municipal	SLT (no modo estático e dinâmico) e SLA e Fotogrametria área (Câmeras)	Sistema de Informação Geográfico (3D), construção de modelos 3D de cidades, <i>Digital Twin City</i> , simulações ambientais e urbanas aplicadas ao planejamento urbano, Cadastro 2D e 3D, ciências forenses, agricultura de precisão, análises ambientais, segurança pública, inspeção de infraestruturas, gestão de serviços públicos e veículos autônomos.
Em nível regional	Fotogrametria Aérea e SLA	Mapeamento topográfico, monitoramento ambiental, agricultura de precisão, simulações de eventos adversos, estudos de paisagem, mineração e exploração de recursos naturais.

FONTE: O autor (2022).


Segundo Poux (2019) os desafios da utilização desses geodados (independentemente do sensor empregado) estão relacionados propriamente com as suas características estruturais, que os torna ambíguos (densidade de pontos variável, presença de ruídos, erros sistemáticos e aleatórios). Ademais, o desenvolvimento de softwares não acompanhou a mesma evolução dos sensores e técnicas de aquisição. Portanto (embora bem estabelecidas), nuvem de pontos LiDAR não é o tipo de dado padrão preferido pelos usuários. As limitações estruturais dificultam a automação dos fluxos de trabalho, necessitando de desenvolvimentos de sistemas de armazenamento, processamentos inteligentes e interoperáveis (POUX, 2019).

Devido a estas limitações, pesquisas científicas se debruçam sobre as etapas que compõem o fluxo de processamento aplicado sobre uma nuvem de pontos LiDAR: registrar³, segmentar, classificar e reconstruir nuvens de pontos 3D. Além de pesquisadores individuais, grupos internacionais demonstram interesse nesta temática para produzir geoinformação 3D, como, por exemplo, a *European Spatial Data Research* (EuroSDR Comissão 2 – *Modelling and Processing*), *International Cartographic Association* (ICA – *Commission Sensor Driven Mapping*), *International Society for Photogrammetry and Remote Sensing* (ISPRS –

³ Na literatura, o problema de registro de nuvens de pontos LiDAR pode ser denominado de Alinhamento de nuvens de pontos LiDAR, ou ainda na Fotogrametria, como orientação relativa (registro de pares de nuvens de pontos LiDAR) e orientação absoluta (registro global de nuvens de pontos LiDAR).

Commission II – Photogrammetry) e o Amsterdam Institute for Advanced Metropolitan Solutions.

As pesquisas buscam soluções para duas questões no fluxo de processamento apresentadas por Xu; Stilla (2021): 1) Como adquirir nuvens de pontos LiDAR? e 2) Qual o fluxo de trabalho que deverá ser aplicado? (FIGURA 4).



FONTE: Adaptado de Xu; Stilla (2021).

A partir disto, as etapas de segmentação e classificação são tarefas que recaem sobre o primeiro estágio de generalização (DLM) quando se objetiva trabalhar com nuvens de pontos LiDAR, buscando selecionar, eliminar e reduzir classes e subclasses de dados para serem posteriormente simbolizadas no processo de modelagem geométrica. Neste estudo, são discutidos aspectos centrais das tarefas de segmentação e classificação como processos de atribuição de semântica a uma nuvem de pontos LiDAR (Subseção 2.1.1), e não são discutidos àqueles relacionados à aquisição, registro e reconstrução 3D. Para detalhes nos tópicos não abordados, Xu; Stilla (2021).


2.1.1 Segmentação e classificação de nuvens de pontos LiDAR

As nuvens de pontos LiDAR representam em 3D as cenas perfiladas, entretanto, cada ponto pertencente ao conjunto contém pouca ou nenhuma informação semântica, mas possuem atributos matemáticos quantificáveis – conforme Hipótese da Naturalidade -. A produção de

um mapa 3D requer o uso da nuvem de pontos LiDAR para fornecer dados geométricos e semânticos obtidos por processos denominados de segmentação e classificação. A segmentação não é uma temática recente e muitos dos conceitos empregados no processamento de nuvens de pontos LiDAR são provenientes da área da Fotogrametria e do Sensoriamento Remoto aplicados às imagens 2D. No caso do mapeamento 3D de ambientes internos, a segmentação consiste na subdivisão do conjunto de dados em regiões que representam subcomponentes que configuram o espaço interno, como, por exemplo, paredes, pisos, tetos (elementos estruturais) e mobiliário empregados como dados de origem para modelar um espaço em ambiente virtual (FIGURA 5).

Na FIGURA 5(a) a visualização é realizada por meio da posição 3D, empregando hipsometria para visualização. O processo representativo não fornece uma visão da composição física do ambiente, contudo, quando se examina os pontos coletivamente são reveladas feições que o constitui a partir de um processo de segmentação, como ilustrado na FIGURA 5(b). A classificação ocorre quando é possível extrair conjuntos de pontos a partir de seu significado semântico, como os pertencentes a estrutura de uma edificação - FIGURA 5 (c) -.

FIGURA 5 - NUVENS DE PONTOS LIDAR (A) HIPSOMÉTRICA (B) SEGMENTADA (C) CLASSIFICADA



FONTE: O autor (2022).

O objetivo da operação de segmentação ($\theta\aleph$) envolve encontrar algoritmos que permitam separar corretamente cada ponto (p) pertencente a uma nuvem de pontos $\aleph$ (EQUAÇÃO 1), definindo semântica (rótulos - θp) (SITHOLE, 2005).

$$\theta\aleph = \{\theta p | \forall p \in \aleph\} \quad (1)$$

⁴ ARMENI, I.; SENER, O.; ZAMIR, A. R.; et al. 3D Semantic Parsing of Large-Scale Indoor Spaces, p.1534–1543, 2016. Disponível em: https://openaccess.thecvf.com/content_cvpr_2016/html/Armeni_3D_Semantic_Parsing_CVPR_2016_paper.html Acesso em: 31/5/2022.

O resultado de $\theta\aleph$ são segmentos (s) que apresentam propriedades semelhantes:

$$S = \{s | s \subset \aleph\} \quad (2)$$

$$\theta\aleph \Rightarrow S \quad (3)$$

$$U_{s_i} = \aleph \text{ em que } |s_i| > 0 \quad (4)$$

$$s_i \cap s_j = \emptyset, \text{ em que } i \neq j \quad (5)$$

Cada segmento (s) é um subconjunto de $\aleph$, caracterizado pelo operador de segmentação (θ) implementado. Existem diferentes abordagens para esta tarefa e podem ser subdivididos em 2 grupos: geométricos e semânticos. A segmentação geométrica geralmente subdivide uma nuvem de pontos LiDAR com base em suas discontinuidades ou semelhanças entre grupos de pontos (SITHOLE, 2005). Técnicas baseadas em geometrias segmentam uma nuvem de pontos LiDAR a partir da homogeneidade estrutural dos objetos que correspondem a um grupo. Em cenas urbanas, que em certa medida apresentam objetos contínuos e repetitivos, os métodos de segmentação geométrica são empregados largamente (principalmente para extração de superfícies planas).

Em geral, para a segmentação geométrica, quatro categorias se destacam: segmentação baseada em modelos, em crescimento por regiões, em agrupamentos (cluster) e em otimização de energia (XU; STILLA, 2021). Apesar de serem propostas importantes no fluxo de processamento discutido, as estratégias de segmentação geométrica não são apresentadas neste trabalho, devido o foco centrar-se na aplicação de métodos de segmentação semântica (SS), conforme Subtópico 2.1.1.1.

2.1.1.1 Segmentação Semântica

O termo SS é amplamente empregado na Visão Computacional, em especial em aplicações recentes que empregam AM e é, em Fotogrametria e Sensoriamento Remoto, sinônimo para o termo classificação (XIE et al., 2020), processo destinado à inserção de rótulos a cada segmento (s) de uma nuvem de pontos LiDAR. Antes dos métodos de SS, foram largamente empregados algoritmos de segmentação geométrica, visando agrupar pontos com similaridades geométricas e estatísticas (XUE et al., 2021) (FIGURA 6). Independente da estratégia de classificação, os algoritmos são compostos por três etapas: a análise de componentes geométricos e estatísticos (descritores 3D), a descrição da geometria com base na

vizinhança local e a classificação de todos os pontos com base em descrições geométricas (XU; STILLA, 2020).

FIGURA 6 - SEMANTIZAÇÃO (A) PARTES ESTRUTURAIS (B) MOBILIÁRIO



FONTE: O autor (2022).


A partir destas três etapas, os algoritmos de classificação analisam as características geométricas de cada ponto em relação a sua vizinhança imediata 3D (V), calculando uma matriz de covariância 3D (T). Neste ponto, é necessário transformar dados puramente geométricos em informações semânticas. Weinmann et al. (2013) mencionam que muitas das abordagens de análise geométrica de uma vizinhança local de uma nuvem é baseada nos autovalores ($\lambda_1, \lambda_2, \lambda_3$) de T com $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ ou em propriedades geométricas ou estatísticas especiais, como a soma dos autovalores ($\sum \lambda$), entropia intrínseca (E_λ), anisotropia (A_λ), planaridade (P_λ), linearidade (L_λ), curvatura (C_λ), esfericidade (E_λ), verticalidade (V), altura (Z) e densidade de pontos (D); definidas como métricas perspectivas de auto similaridade (Capítulo 3).

A classificação, como já mencionado, é realizada com base em uma vizinhança local, da posição espacial do ponto e de sua distribuição dentro da vizinhança para que as características geométricas sejam extraídas e então selecionadas (XU, STILLA, 2020). Com base em recursos geométricos, um classificador treinado (supervisionado) pode atribuir semântica ao ponto a partir de um conjunto de treinamento $Y = \{c_i\}$ em que c_i consiste em um conjunto de n amostras com $i = 1, \dots, n$. Cada amostra de treinamento $c_i = (x_i, l_i)$ encapsula um vetor de características geométricas $x_i \in R^d$ em um espaço d dimensional e; opcionalmente, os seus respectivos rótulos que identificam cada classe $l_i \in \{1, \dots, nc\}$, em que nc representa o número de classes (WEINMANN et al, 2013). O conjunto de pontos a ser classificado é denominado de conjunto teste $Y^* = \{c_i^*\}$, em que c_i^* consiste em um conjunto de m amostras encapsuladas em um novo vetor $x_i^* \in R^d$, e suas respectivas classes $l_i^* \in \{1, \dots, nc\}$ (WEINMANN et al., 2013).

Para esta tarefa muitas abordagens foram propostas nos últimos anos, considerando aspectos geométricos e estatísticos de nuvens de pontos LiDAR. Atualmente, com o avanço tecnológico pesquisadores têm conduzido experimentos por meio de algoritmos AM, como Máquinas de Vetor de Suporte, Random Forest (YU et al., 2011; NI et al., 2017), e a aplicação de Redes Neurais Artificiais – RNA - (estratégias *Deep Learning* - DL) (QI et al., 2017; QI; YI et al., 2017; KOMARICHEV et al., 2019) que vêm ganhando destaque devido aos resultados promissores, conforme destacado no Subtópico 2.1.1.2, que segue.

2.1.1.2 Estratégias baseadas em DL

O DL compreende uma classe de técnicas na área de AM em que os modelos consistem em múltiplas camadas de processamento (Redes Neurais - RNs), e é possível que a partir de um conjunto de amostras (treinamento) os algoritmos aprendam a representar dados com diferentes níveis de abstração (HAYKIN, 2007). Uma RNA consiste em uma camada de entrada, uma camada de saída e pelo menos 1 camada oculta (RN Simples) e cada uma delas é formada por neurônios artificiais (FIGURA 7), quando uma RN é composta por n camadas ocultas trata-se de um problema DL (RN Profunda – RNP).



FONTE: O autor (2022).

Nesta configuração, uma entrada x_j (conjunto de treinamento, para um processo de classificação supervisionada), conectado a um neurônio k , são estímulos cujas ligações com o corpo celular artificial são realizadas por canais de comunicação (sinapse) associados a um determinado peso w_{kj} - FIGURA 7(c) -. Os dados de entrada são associados ao neurônio por uma função de ativação, gerando um nível de atividade. Caso este nível ultrapasse um certo limite, a unidade processadora produzirá uma determinada resposta. A chave para o aprendizado profundo é que as camadas de recursos usados na rede não são fornecidas, mas são decididas pela rede em si (HAYKIN, 2007). Na EQUAÇÃO 6 este processo é expresso matematicamente, em que u_k é a saída do combinador linear. O sinal de saída do neurônio (y_k) pode ser expressa conforme EQUAÇÃO 7, em que $\phi(.)$ é a função de ativação do neurônio.

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (6)$$

$$y_k = \phi(u_k) \quad (7)$$

A função $\phi(.)$ é um elemento importante, pois, é responsável por decidir se um neurônio deve ser ativado ou não, ou seja, decide se a informação contida em um neurônio artificial é importante para o processo ou pode ser dispensada. Existem várias estratégias de ativação, como pode ser verificado em Haykin (2007), e à medida que a AM evolui existe a necessidade de atualizações e desenvolvimentos rebuscados, sendo uma temática em aberto e em desenvolvimento. Após o término do treinamento, o desempenho do modelo é avaliado em um conjunto desconhecido, permitindo estimar a capacidade de classificação do modelo que pode ser adaptado e aplicado para classificar diferentes tipos de dados, como as nuvens de pontos.

Estratégias foram propostas para aprimorar o processo de definição de semântica a uma nuvem de pontos LiDAR (DÖLLNER, 2020) e podem ser divididas em duas categorias: baseado em dados estruturados e em pontos (BELLO et al., 2020). Métodos baseados em estruturas são projetados sob um tipo distinto de RN, denominada de Convolutacional (RNC) (*Convolutional Neural Networks*). As RNCs são especializadas em detectar padrões e decifrá-los a partir de camadas convolucionais, que consistem em filtros que realizam a detecção de padrões. Este processo emprega filtros gradientes (*kernels*) para detectar recursos (BELLO et al., 2020).

O principal desafio é que RNC requer uma grade estruturada, fator que não caracteriza nuvens de pontos LiDAR, uma vez que apresenta distribuição discreta e aleatória. Para resolução da problemática duas abordagens foram propostas, a baseada em voxel e em imagens (XU; STILLA, 2020). Métodos baseados em voxel convertem nuvem de pontos LiDAR em uma estrutura de voxel 3D de tamanho $X \times Y \times Z$ com núcleos 3D de tamanho $x \times y \times z$ com $x, y, z \leq X, Y, Z$ e são executadas duas tarefas: estruturar o conjunto e aprender com as observações. O emprego de voxels em RNC são eficientes, entretanto, requer alto consumo de memória na estruturação devido a convolução sobre regiões vazias. Já os métodos baseados em imagens aproveitam a consistência de RNC no âmbito 2D e as aplicam no âmbito 3D, comprimindo uma nuvem de pontos LiDAR em uma coleção matricial. A vantagem desta subcategoria é a possibilidade de analisar texturas, o que não é possibilitado pelo voxel, todavia, este último possibilita a análise de profundidade.

Observa-se que nas abordagens anteriores a ideia é estruturar as nuvens de pontos, pois, ao contrário de problemas usuais, não é possível aplicar diretamente uma RNC para sua semantização devido à falta de uma estrutura rígida. A ideia básica é explorar a HN centrada em nuvens de pontos para agrupar pontos com características estatísticas semelhantes e atribuí-los em uma classe específica. As técnicas baseadas em pontos, portanto, apresentam uma vantagem: permitem a aplicação de RN diretamente sobre o conjunto bruto. O algoritmo denominado de PointNet (QI et al., 2017) foi o primeiro criado em uma base não estruturada e é origem de diversas abordagens. A entrada do PointNet é uma nuvem de pontos LiDAR bruta $\mathbf{X} = R^{N \times d}$, em que N representa o número de pontos e os valores das coordenadas 3D de cada ponto. A chave do algoritmo é o emprego de uma função simétrica $g(\cdot)$ (*pooling max*) que possibilita a RN alcançar invariância de permutação, mesmo para uma função que receberá apenas 3 números (x, y, z).

A função simétrica gera um vetor de recursos global para os pontos de entrada com parâmetros aprendidos, que após n camadas da RN é possível atribuir rótulos aos pontos. Uma limitação do método é não considerar a dependência local de vizinhança, o que permite suscetibilidade a erros de classificação (BELLO et al., 2020). Com base no PointNet, outras abordagens foram propostas para analisar localmente a distribuição dos pontos, como o PointNet++ (QI; YI et al., 2017) que realiza a análise dos pontos a partir de regiões. Os algoritmos A-CNN (KOMARICHEV et al., 2019) e PointNetCNN (LI et al., 2018) analisam k vizinhos mais próximos e a direção de vetores normais antes de aplicar a função de simetria do PointNet. Grafos também foram empregados em conjunto com o PointNet com o objetivo de

minimizar o obstáculo básico do processamento da nuvem de pontos LiDAR: o custo computacional (LANDRIEU; SIMONOVSKY, 2017).

Independente da categoria do método, a SS desenvolvidas por estratégias DL são populares e são frequentemente aplicadas como tarefas intermediárias na reconstrução de representações 3D de ambientes e objetos (não abordados neste trabalho) gerando modelos de primitivas 3D rotuladas, explorando a HN centrada em nuvens de pontos (DÖLLNER, 2020). A geração de um modelo geométrico 3D é a etapa final do fluxo de processamento de uma nuvem, no qual uma nuvem não estruturada e isenta de semântica é transformada em um recurso estruturado capaz de receber informações externas e possibilitar a construção de um sistema robusto e especializado. Apesar dos avanços tecnológicos atuais, ainda existem aspectos significativos que devem ser investigados e superados, como a eficiência e eficácia dos métodos, a generalidade do uso e a robustez computacional relacionada a interpretação dos dados 3D e seu custo de armazenamento e processamento (XU, STILLA; 2020).

Este campo é uma mistura heterogênea de diferentes disciplinas (Arquitetura, Fotogrametria, Sensoriamento Remoto, Cartografia e Ciências da Computação) e a nuvem de pontos LiDAR é um dos elementos a ser considerado em conjunto a aspectos computacionais, e, o seu fluxo de processamento deve ser aprimorado para reduzir tempo de tratamento e atribuição semântica, minimizar operações manuais e custo de armazenamento que cresce consonante ao tamanho da área a ser representada e frequência de perfilamento do sensor. A sinergia prospera com a presença de padrões que garantam que os dados sejam acessíveis e utilizáveis por todos os envolvidos (CityGML, IFC, IndoorGML, etc.), sendo utilizado como uma plataforma de pesquisa e de colaboração.

Na Seção 2.2 são apresentados os aspectos gerais da Cartografia *Indoor*, contexto de interesse neste trabalho.

2.2 CARTOGRAFIA *INDOOR*

A construção de representações de ambientes internos é uma atividade antiga que vem sendo desenvolvida desde plantas até representações que visam fornecer informações para evacuação em casos de emergências, geralmente realizada a partir de linhas 2D que insere dificuldades no processo de interpretar espaços interiores (CHEN; CLARKE; 2019; NIKOOHEMAT et al., 2020). Recentemente os avanços tecnológicos em Sensoriamento Remoto, Fotogrametria e a Computação Gráfica permitiram a expansão de uma representação 2D para 3D (CHEN; CLARKE, 2019), fator que associado ao crescimento da demanda por

representações internas impulsionou o desenvolvimento científico e tecnológico relacionado à temática.

O crescimento populacional de áreas urbanas é um dos fatores relacionados ao aumento do interesse em construir representações internas. A população urbana vem aumentando nos últimos anos e a projeção segundo a ONU é que até 2050 70% da população mundial residam em áreas urbanas, inserindo importância na representação interna de edificações, além de mesclá-las com seu contexto *outdoor*. A aplicação mais óbvia para o mapeamento 3D *indoor* envolve a extensão de serviços baseados em localização espacial dos usuários no interior de edificações (*location-based-service* – LBS), expandido para 3D tanto para questões financeiras (de navegação interna e localização de lojas e produtos) até mesmo a entrega automatizada a partir de robôs (LIU, et al., 2021; FU et al., 2021). Contudo, não somente a navegação e localização ganharão espaço, mas também o auxílio ao planejamento urbano e regional de uma cidade, uma vez composta pela junção de ambientes internos e externos, e não somente por este último mencionado.

O avanço tecnológico de aquisição de dados 3D é um dos pilares que sustenta este processo. Atualmente, os *hardware* de sensores de Sensoriamento Remoto e Fotogrametria permitem a aquisição de dados em um curto intervalo de tempo. No contexto 3D, como dito no Capítulo 1, as nuvens de pontos são dados espaciais de base para a construção geométrica de modelos 3D de ambientes internos que podem ser dotados de significado semântico conforme com o propósito da aplicação. Técnicas de extração e interpretação de nuvem de pontos ainda devem ser aprimoradas, abrindo várias faixas de pesquisa, entretanto, com o desenvolvimento recente na computação gráfica e na robótica a construção de modelos 3D já é uma realidade, mesmo necessitando de algumas adaptações segundo o fluxo de processamento adotado. Para explorar este fluxo de trabalho é necessário definir algumas questões intrínsecas a temática, como os conceitos relacionados a um espaço e ao mapa *indoor*, discutidos na Subseção 2.2.1 e 2.2.2, respectivamente.

2.2.1 Espaço interno

A delimitação e definição de espaço interno é essencial para construir representações 3D, pois é a partir disto que se pode determinar onde começa o exterior e termina o espaço interior (CHEN; CLARKE, 2019). Conforme *IndoorGML* (2020), a concepção de espaços internos se diferencia daquela usualmente empregada para espaços externos. Esta diferença produz a necessidade de adaptação de conceitos, padrões de informações espaciais e modelos

de dados para atender os requisitos de aplicações. Li (2008) definiu espaços internos limitados por elementos arquitetônicos, tais como portas, paredes, tetos, janelas, pavimentos e escadas. Esta definição proposta por Li foi a base para a criação de conceitos, além de regras para a sua exposição e interpretação de dados.

Zlatanova et al. (2014) também empregaram o termo espaço interno quando diz respeito a um local sobre uma estrutura fechada artificialmente projetada e desenvolvida para apoiar atividades humanas, quando se diz respeito ao contexto urbano. Diferentemente de Li (2008), na concepção de Zlatanova, espaços internos são formados não somente por estruturas, mas por um conjunto de subespaços internos (o padrão *IndoorGML* denomina de subespaços como espaço celular - *cellular space* -), recursos, atividades e agentes que coletivamente formam um espaço completo.

Um subespaço (nesta concepção) diz respeito a qualquer subdivisão de um espaço interno em partes menores (que podem ser classificados como navegáveis – quando se diz respeito a quartos, corredores, salas, etc. – e como subespaços inertes – ou não navegáveis, como paredes, tetos e piso –), que são parcial ou totalmente delimitados por fronteiras, tendo ou não significado semântico e conectados com subespaços vizinhos, ou seja, forma uma compartimentação lógica (arranjo espacial topologicamente consistente) de recursos e atividades conforme o uso de uma edificação. Diakité et al. (2017) apresentam uma ideia semelhante a Zlatanova et al. (2014), mencionando que o espaço interno é uma estrutura hierárquica, independentemente de sua complexidade e tamanho. Esta estrutura é projetada conforme utilização do ambiente que é implicitamente projetado a partir da configuração geométrica de recursos estruturais (portas, janelas, corredores, etc.) ou por meio de uma configuração de mobiliário específico.

Chen; Clarke (2019) mencionam que apesar das definições existentes na literatura compartilharem semelhanças, ainda existem incompletudes nas definições e espaços intermediários não são abrangidos. Yan et al. (2019) propuseram a inserção de um terceiro grupo de espaço para abranger aqueles de difícil classificação em internos ou externos. O primeiro grupo proposto continua sendo o espaço interno, configurado basicamente por um ambiente completamente fechado por estruturas (bordas superiores, inferiores e laterais), o espaço externo é aquele ao “ar livre” comumente percebido como ilimitado na direção vertical. Em terceiro, encontra-se a classificação *semi-indoor* que abrange espaços de difícil classificação em apenas interior ou exterior (como por exemplo, viadutos, postos de gasolina pontos de ônibus e varandas) por possuírem características de ambos os grupos (interno e externo), mas não podem ser classificados como um dos dois.

Chen; Clarke (2019) denominou os espaços intermediários como “*Quasi-indoor*” e “*Quasi-outdoor*”, associando-os ao contexto da Cartografia. Esta classificação é realizada a partir de análises de topologia de limiar, relacionada ao senso de lugar de cada produtor da representação (aspectos subjetivos). Em sua forma física, o limiar consiste no limite da estrutura de um edifício que permite isolar o seu interior do espaço externo. O interessante é que o limiar entre um espaço interno e o externo consiste na transição entre estas duas localidades, por este fato além de um espaço A e um espaço B, existe o espaço de limiar (“*Quasi-indoor*” e “*Quasi-outdoor*”). Os autores afirmam que quando o limiar diz respeito ao espaço de uma parede, ele é desprezível, mas quando ocupa um espaço significativo, como uma varanda ou átrio, tem-se a formação de um espaço intermediário de transição entre interno e externo.

Cada definição apresentada aborda aspectos distintos, sendo universal um estado de total fechamento e isolamento do mundo exterior na tentativa de capturar a essência de espaços internos e, em consequência, ramificar paradigmas e teorias específicas. Seguindo a literatura, um espaço interno está relacionado aos ambientes (edificações) completamente fechados por elementos construtivos regulares, entretanto, não o é. Por exemplo, as cavernas são elementos naturais e não apresentam aspectos construtivos de edificações e estruturas regulares, mas conceitualmente pode ser inserida dentro do contexto do mapeamento *indoor*, tendo os mesmos paradigmas e limitações. Além disso, ambientes internos podem ser compostos por elementos naturais (como os jardins internos), que na concepção de Chen e Clark (2019), encontra-se na classificação de “*Quasi-indoor*”, necessitando de contextualização semântica quando busca construir uma representação cartográfica de um ambiente interno, independente do objetivo da aplicação.

A definição de espaço interno é de difícil assimilação e é subjetivo definir qual ambiente deve ser representado e classificado em uma representação interna conforme o objetivo da aplicação que definirá os requisitos geométricos e semânticos para a construção de uma abstração, seja no contexto 2D ou 3D. A *IndoorGML* aborda este contexto e separa as aplicações como segue: 1) Gestão de componentes da construção e instalações internas e; 2) Representação e aproveitamento do espaço interno.

O grupo destinado à gestão e operação de componentes construtivos e instalações internas tem o foco na construção, gerenciamento e tomada de decisão dos processos construtivos e da vida útil de uma edificação de forma integrada e interoperável (propósito do BIM), ou seja, todo o processo está relacionado a aspectos construtivos que estão associados a uma representação 3D, mas não se interessa pela navegação do espaço interno por um determinado usuário. O segundo grupo é focado no uso e localização espacial, preocupando-se

não somente com elementos construtivos, mas com o espaço e seu inter-relacionamento (semântico e topológico). A partir desta configuração é possível traçar uma diferenciação entre BIM e mapa 3D. Enquanto o BIM é centrado na gestão da construção (caracterizando-se pelo objetivo do padrão *Industry Foundation Class* - IFC), o mapa *indoor* 3D é centrado na representação do espaço e sua utilização por um usuário (caracterizando o objetivo do padrão *IndoorGML*). Logo, um modelo BIM não é considerado como uma representação cartográfica 3D *indoor*, como destacado na Subseção 2.2.2.

2.2.2 Mapa *indoor*


Muitas vezes, o processo de criação de um mapa é direcionado para ambientes externos, todavia, pode ser expandido para o contexto do mapeamento *indoor* (seja no âmbito 2D ou 3D), uma vez que mapas internos são ferramentas empregadas para simbolizar geometrias de espaços fechados ou “*Quasi-internos*”, e, são aplicados para fins de comunicação cartográfica e análise espacial. Chen; Clarke (2019) mencionam que o termo mapeamento de ambientes internos muitas vezes é empregado como sinônimo de modelagem interna, uma vez que este processo busca representar espacialmente os objetos que formam o ambiente, inserindo-lhes semântica. Entretanto, os autores mencionam que existe uma separação entre mapas e modelagem aplicados a ambientes internos, e os termos são empregados de forma equivocada (em algumas ocasiões com significados idênticos, noutras justapostos).

Chen; Clarke (2019) abordaram esta ambiguidade realizando uma comparação do significado de mapas e de modelos de ambientes físicos. De forma ampla, os autores mencionam que modelos são representações de algo do mundo real para auxiliar na compreensão humana ou da máquina, o que recai sobre a definição de mapa. Contudo, existe uma diferença de paradigma quando se considera a área da Cartografia. Esta discussão é baseada na FIGURA 8, em que os autores comparam o processo de modelagem científica típica com analogias linguísticas, abrangendo o contexto da Cartografia *Indoor*. A construção de abstrações (processo metafórico) deve ser baseada sobre observações do mundo real (dados brutos) processadas e modeladas geometricamente para gerar abstrações.

Ambos os termos (modelagem e mapa de ambientes internos) buscam a construção de abstrações, mas com processos e objetivos distintos. Chen e Clarke (2019) os separa em dois grupos: modelo e mapa *indoor*. Os modelos são caracterizados como representações literais com ausência de semântica, enquanto mapas internos são abstrações figurativas do mundo real, ricas em semântica. No contexto 3D, nuvens de pontos reincidentem sobre modelos de dados, ao

passo que o padrão *IndoorGML* é classificado como uma representação digital. Intermediariamente, normas como CityGML, o IFC (para o caso do BIM) e desenhos CAD apresentam características de ambos, tanto de modelo de dados, quanto de representações, sobrepondo-se com a Cartografia *Indoor*. Todavia, não abordam os paradigmas centrados no usuário, como a localização e navegação em espaços internos a edificações.

FIGURA 8 - MAPAS INTRNOS X MODELOS



FONTE: Adaptado de Chen, Clarke (2019).

O processo de representação ainda se encontra em fase de desenvolvimento, e a construção de mapas internos oferece desafios e oportunidades para pesquisas futuras. Por exemplo, representações internas podem ser baseadas em CAD (no caso 2D), em modelos 3D (empregando normas internacionais) ou a partir de sistemas de detecção remota empregando sensores de aquisição de dados espaciais. No caso do CAD e o BIM, arquitetos e engenheiros os empregam para a gestão predial (CHEN; LUO, 2014). No enquadramento da detecção remota, a Fotogrametria e o Sensoriamento Remoto empregam sensores para a realização de medições promovendo leituras brutas do ambiente digitalizado por meio de nuvens de pontos ou modelos de malhas, sem considerar o contexto cartográfico (CHEN; CLARKE; 2019).

Chen; Clarke (2019) mencionam que apesar dos esforços, nenhuma iniciativa fornece uma estrutura abrangente para a cartografia, mas representam aspectos importantes para o contexto de representação para ambientes internos.

2.2.3 Padrões para informações espaciais de espaços internos

Os padrões (modelos) tem a função de formalizar a coleta de dados, a manutenção e o desenvolvimento de software. Atualmente existem 3 modelos que comumente são aplicados a

ambientes internos: *CityGML*, *IndoorGML* e IFC. Os padrões relacionados a este campo de pesquisa trabalham com o conceito de nível de detalhamento (LoD) que se destina, conforme Biljecki et al. (2016), a diferenciar as representações em várias escalas de modelos semânticos 3D, denotando aderência do modelo à sua contraparte do mundo real e com implicações diretas na sua usabilidade. O padrão *CityGML* 2.0, por exemplo, define 5 instâncias que aumentam sua complexidade geométrica e semântica segundo o nível de detalhamento exigido pelos objetivos da aplicação (FIGURA 9).

FIGURA 9 - LOD *CityGML* 2.0



FONTE: Biljecki et al. (2016).

Um LoD reflete a qualidade do design do modelo (principalmente no contexto geométrico) e os vários requisitos de uma proposta e uso da representação (GRÖGER; PLÜMER; 2012). Segundo Biljecki et al. (2016) diferentes LoD de um mesmo objeto, considerando um mundo contínuo, são discretizados conforme funções progressivas e monotônicas dos valores das métricas pré-estabelecidas (complexidade, dimensionalidade, aparência (textura), coerência e dados dos atributos), ou seja, cada LoD discretizado (i) é uma coleção de valores de n métricas resultantes da discretização de suas funções (que podem ser discretas ou contínuas), conforme EQUAÇÃO 8:

$$LoD(i) = [L_1 \ L_2 \ ... \ L_n] = [f_1(i) \ f_2(i) \ ... \ f_n(i)] \ i \in R, n \in Z \quad (8)$$

Este processo permite ao produtor do modelo definir o necessário para modelar tridimensionalmente um ambiente, considerando que LoD é o grau de correspondência entre o modelo 3D e o objeto no mundo real. No caso do *CityGML* 2.0, o LoD4 inclui a possibilidade da representação de ambientes internos, compostos por quartos, portas internas e escadas (BILJECKI et al., 2016), abrangendo métricas de complexidade e dimensionalidade compatíveis com um ambiente interno. Apesar do *CityGML* 2.0 apresentar detalhamento para o ambiente interno, suas especificações são centradas para aplicações externas a edificações, e ambos diferem em aspectos conceituais e requisitos práticos (como, por exemplo, os sensores

de aquisição de dados espaciais empregados), reforçando a necessidade de definir um padrão dedicado à temática interna, como o IFC.

O padrão IFC é um formato de intercâmbio de informação por usuários e fornecedores BIM, centrado no interior de edificações. A *BuildingSMART International* (anteriormente denominada de *International Alliance for Interoperability*) estabeleceu o IFC para representar elementos de construção e suas propriedades geradas como modelos orientados a objetos em formato XML contendo estruturas de dados geométricas e não geométricas (buildingSMART, 2021). Apesar do IFC e do *CityGML* apresentarem semelhanças, os paradigmas de modelagem diferem devido aos contextos de aplicação, interno para o BIM e externo para o SIG 3D (ARROYO OHORI et al., 2018). Ademais, ambos os formatos não refletem totalmente as propriedades dos espaços internos, como a topologia (KANG; LI, 2017).

No domínio do SIG 3D são representados os elementos a partir de superfícies fechadas, enquanto no domínio do BIM é tipicamente empregado primitivas volumétricas e paramétricas (TANG et al., 2020), não existindo a preocupação com as relações espaciais entre os elementos representados (corredores, quartos, salas, janelas e portas), fatores essenciais em processos de análises aprimoradas, como a definição de rotas em caso de emergências (NIKOOHEMAT et al., 2020). Contudo, conforme Chen; Clarke (2019), para construção de representações cartográficas 3D de ambientes internos é necessário considerar aspectos espaciais, consonante aos apresentados na *IndoorGML* (Subseção 2.1.4).

2.2.4 IndoorGML


Como dados adquiridos para mapear um ambiente externo, dados espaciais de ambientes internos apresentam o ciclo de vida de coleta, gerenciamento, compartilhamento e análise espacial. Entretanto, devido às suas peculiaridades, necessita-se de uma teoria espacial interna básica para apoiar esta iniciativa, e um modelo de dados para ambientes internos é uma parte central deste processo (KANG; LI, 2017). Com este intuito, a *IndoorGML* foi publicada pela *Open Geospatial Consortium* (OGC) incluindo propriedades de geometria, espaço simbólico interno e topologia de rede, atendendo a requisitos espaciais de ambientes internos e possibilitando sua integração com outros padrões, como o *CityGML*. O padrão *IndoorGML* fornece recursos de codificação para informações espaciais internas e cobre requisitos de navegação e relacionamentos topológicos, considerando os componentes arquitetônicos e os diferentes usos de um ambiente.

No contexto de interiores de edificações, empregam-se a identificação dos espaços como unidades celulares (subespaços). Para determinar estas células o modelo deve ser definido (limitado) em 2D ou 3D, de modo possível para estimar a célula que contém a posição de um observador. Portanto, a representação de cada célula deve ser limitada por uma superfície fechada, um polígono para o caso 2D ou um sólido para o caso 3D (KANG; LI, 2017). A percepção de célula é um requisito básico para o mapeamento *indoor* e é um conceito chave na *IndoorGML*, a saber: um espaço celular C pertencente a um espaço U e é definido como um conjunto de células, de modo que para quaisquer pares de células $c_i, c_j \in C$, tem-se: 1) $c_i \cap c_j = \{ \}$; 2) $\cup c_i \subseteq U$ e 3) Cada célula c tem um identificador (*id*) associado.

O espaço interno, neste contexto, é representado como subespaços celulares, a sua menor unidade organizacional. Com ausência de sobreposições, mas limites comuns, aspectos topológicos de conectividade em redes (grafos) e adjacência, sendo a geometria apresentada conforme especificações da ISO 19107. A especificação de espaços celulares é o primeiro processo para a construção de um mapa interno e, uma vez determinadas (identificadores e geometria), descreve-se as relações topológicas entre células adjacentes (INDOORGML, 2020). Neste caso, cada célula 3D ou 2D é reduzida em um vértice (v) e as relações de adjacência são transformadas em arestas unidimensionais (a).

O conjunto de vértices e arestas são transformados em um grafo de adjacência $G = (v, a)$ no espaço interno (FIGURA 10).

FIGURA 10 - DERIVAÇÃO DO GRAFO DE ADJACÊNCIA DO ESPAÇO *INDOOR*



FONTE: Adaptado de IndoorGML (2020)

O grafo de adjacência permite derivar conectividade, classificando as arestas em espaços navegáveis (como as portas, corredores e salas) ou não navegáveis (como as paredes).

Se uma aresta indicar o limite de uma porta, então dois vértices estão conectados por uma aresta navegável, enquanto se apresentarem apenas aspectos de adjacências não existe a possibilidade de navegação. O IndoorGML está focado no uso de espaços internos navegáveis em que objetos podem ser localizados, considerando aspectos de acessibilidade, posicionamento e navegação em ambientes internos (MORTARI et al., 2019) para diferentes aplicações, como evacuação de edifícios e gerenciamento de desastres, conforme as prerrogativas do projeto Map4Society, navegação de robôs (ZOU et al., 2021) e serviços baseados em localização (LIU, et al., 2021; FU et al., 2021)).

2.3 GENERALIZAÇÃO CARTOGRÁFICA

Sester (2020) menciona que a representação mais antiga foi feita em uma placa de argila mostrando regiões ao redor de Nuzi, Mesopotâmia, empregando fortemente aspectos da generalização, ou seja, a seleção de alguns objetos para serem representados de uma forma esquemática, aplicando um processo de redução de dados geoespaciais para um mínimo necessário (SCHIEWE, 2021), a partir de técnicas que constituem o processo de generalização cartográfica que tem como intuito clássico melhorar a legibilidade e a compreensão dos dados por parte do usuário.

A afirmativa levantada por Sester está relacionada às definições inseridas no relatório intitulado de *Cartographic Generalization* produzido em 1987, pela *National Oceanic and Atmospheric Administration* (NOAA). Segundo este relatório, no contexto da Cartografia, todas as representações são reduções de alguma parte do ambiente e é impraticável, indesejável e até mesmo impossível representar o planeta Terra em uma escala 1:1, isto gera consequências, como a perda da clareza devido à superlotação e a passagem de um contexto específico para um geral (a partir da importância visual dos elementos geográficos conforme demanda de produção), necessitando aplicar operações de eliminação, ampliação e deslocamentos, como exemplos, para ajustar os elementos representados às restrições gráficas impostas pela escala de representação.

O conjunto de operadores aplicados ao processo de compatibilização dos elementos geográficos às restrições gráficas, inseridas em uma determinada escala, é reduzido ao tópico conjunto de generalização cartográfica, em que se aplica um fluxo de trabalho para a confecção de mapas (seja no âmbito analógico ou digital). A finalidade da generalização (no contexto clássico) é produzir mapas respeitando requisitos de exatidão, conteúdo de informação e legibilidade. Este processo está fortemente conectado a representações multi-escala e a multi-

representações de um mesmo conjunto. A generalização cartográfica, portanto, é um conjunto de operações empregado para apoiar o processamento de dados espaciais de entrada e representá-los em escalas múltiplas, obtendo representações facetadas, desenvolvidas e aplicadas conforme necessidade e objetivos do produtor de um mapa, sendo correspondente às regras impostas por um determinado nível de abstração (SESTER, 2020).

A generalização é o processo aplicado para adequar os dados de uma representação a uma nova escala respeitando os princípios de comunicação cartográfica realizada por meio de duas etapas: 1) Seleção das informações e; 2) Aplicação dos operadores de generalização (condicionados à escala e ao formato do produto) (NOAA, 1987). Isto posto, a generalização inicia com um processo de seleção de objetos, considerando uma relação hierárquica de importância entre as feições que compõem o conjunto representado seguido pelo emprego de operadores de generalização. Auxiliam na construção de representações legíveis e eficientes para o caso tradicional (generalização analógica) (SCHIEWE, 2021). Portanto, um dos problemas associados à generalização cartográfica é definir quais informações precisam ser mantidas e transmitidas no processo de generalização que dependerá, além do objetivo da representação, o tipo de primitiva gráfica (ponto, linha ou área) (YAN; WEIBEL, 2008).

A etapa de seleção é formulada como uma consulta dicotômica, na qual define se a informação é importante ou não (NOAA, 1987), identificando-as como relevantes ou irrelevantes ao propósito do mapa. Posteriormente a etapa 2 (aplicação dos operadores) pode ser estabelecida e a generalização executada a partir de regras de manipulação. Estas regras incluem aspectos de semântica e são implementadas e executadas por meio dos operadores de generalização (SESTER, 2020). A aplicação dos operadores deve ser executada a partir da distribuição espacial dos elementos a serem generalizados, além de suas características geométricas. Este processo é relevante devido à necessidade de se definir os operadores e a ordem de aplicação adequada.

O principal problema é selecionar os operadores corretos e aplicá-los seguindo um ordenamento coerente em relação ao contexto analisado. Devido a este processo apresentar níveis de subjetividade somados à heterogeneidade dos ambientes físicos, a automatização do processo de generalização é o principal desafio e é um problema de pesquisa a ser superado. Para entender as tendências e as inúmeras possibilidades científicas e técnicas relacionadas ao

processo de generalização, foi realizada uma pesquisa bibliométrica na base de dados *Web of Science (WoS)*⁵ e a plataforma *Scopus*⁶.

2.3.1 Aspectos teóricos e evolutivos

Existem várias propostas de definição de generalização cartográfica, todavia, devido à complexidade e à subjetividade da temática, uma teoria única é difícil de implementar. Dentre as teorias existentes, Robinson et. (1995) define a generalização cartográfica como um conjunto de procedimentos aplicados em uma base de dados geoespaciais com o intuito de adequá-los a uma representação cartográfica em uma nova escala de representação, respeitando requisitos da comunicação e legibilidade. Esta definição é corroborada pelas afirmativas levantadas pela *Swiss Society of Cartography (SSC, 2002)*, que define o tema como um processo de simplificação gráfica de mapas de grande escala, conforme o detalhamento do produto a ser representado e considerando aspectos de uso, precisão posicional, características e representação gráfica coerentes (comumente empregado no contexto da produção de cartas topográficas).

Uma definição semelhante é proposta pela *International Cartography Association (ICA, 1973)*: a generalização cartográfica é o processo de seleção e de representação simplificada de detalhes apropriada à escala e/ou ao propósito do mapa, com o intuito, conforme McMaster e Shea (1992) (em uma conjuntura digital), de derivar de uma fonte de dados geoespacial, um conjunto cartográfico codificado simbólica ou digitalmente, através da análise cartométrica e da aplicação de transformações espaciais e de atributos. Estes dois processos consistem nas etapas que constituem a generalização cartográfica: a seleção de informações e a aplicação de operadores de generalização condicionados à escala e ao formato do produto. Respectivamente, estas etapas representam análises baseadas na avaliação semântica do conjunto de dados e na definição de restrições gráficas condicionais.

Com o desenvolvimento da cartografia digital, a generalização passou a ser aplicada na manipulação de bases cartográficas digitais, com o intuito de automatizar o processo para novos conceitos e diferentes aplicações. Os desenvolvimentos relacionados à temática são desafiadores e automatizá-los em um ambiente digital ainda é uma questão central que a Cartografia Moderna enfrenta. Inclusive, observando um panorama histórico, as primeiras

⁵Banco de dados científico internacional – *Web of Science*. Acesso café (CAPES/MEC). Disponível em: <https://www-periodicos-capes-gov-br.ezl.periodicos.capes.gov.br/index.php> Acesso em: 10, mai. 2022.

⁶ Banco de dados científico internacional - *Scopus*. Acesso café (Portal de Periódicos CAPES/MEC). Disponível em: <https://www-periodicos-capes-gov-br.ezl.periodicos.capes.gov.br/index.php> Acesso em: 03, ago. 2022.

tentativas de generalização cartográfica buscavam solucionar problemas restritos, como as feições lineares em que se aplica o algoritmo de Douglas e Peucker (1973) ou de ponto e área (TOPFER; PILLEWIZER, 1966). Com base nesses estudos e no amadurecimento dos conceitos e dos ideais, outros autores propuseram metodologias e aspectos conceituais para melhor compreender os elementos e o processo de generalização cartográfica.

Segundo McMaster e Shea (1992), as etapas que constituem a generalização cartográfica são complexas, subjetivas e holísticas. Os resultados e procedimentos empregados dependerão do operador, de suas experiências e perspectivas em relação ao objeto de estudo. O principal problema é selecionar operadores de generalização corretos e aplicá-los seguindo um ordenamento coerente em relação ao contexto analisado (SESTER, 2020). No âmbito digital é necessário expender processos objetivos, para formalizar a escolha de operações de generalização (LI; OPENSHAW, 1993). A proposição para esse problema foi o desenvolvimento de modelos conceituais para sistematizar elementos e definir estratégias de generalização como um todo. A principal razão para o desenvolvimento de modelos é facilitar o acesso a dados no ambiente SIG, no qual o usuário interage com geo-objetos sem conhecimento da sua representação interna, enquanto a generalização cartográfica é impulsionada por princípios da comunicação, as quais não funcionam independentemente, sendo a primeira precursora da segunda.


Conforme Cerbrykow (2017), os modelos conceituais são tentativas de abordar este processo de forma geral em direção a permitir a distinção de etapas básicas e de seus relacionamentos espaciais. Os modelos na fase digital foram divididos em duas etapas: 1) A generalização do modelo de dados (*digital landscape model* - DLM) e; 2) a generalização do modelo cartográfico digital (*digital cartographic model* - DCM). O primeiro estágio é tratado como a preparação do BDG (seleção, eliminação e redução de classes e de subclasses), ou seja, a modelagem orientada a dados para o segundo estágio, responsável por gerar o produto cartográfico adequado ao propósito e à visualização do mapa (derivação de representações secundárias num contexto multi-escala). Essa afirmação é corroborada por MIÜLLER et al. (1995) que mencionam que a principal distinção entre o ponto de vista digital e o cartográfico analógico é a possibilidade de manipulação do BDG no primeiro caso, independente da representação cartográfica.

Vários modelos, portanto, foram propostos para oferecer uma base teórica para a compreensão desse problema, como os desenvolvidos por McMaster e Shea (1992), Ratajski (1967), Morison (1974), Nickerson e Freeman (1986) e Brassel e Weibel (1988). Segundo esses autores, conhecer a generalização cartográfica significa extrair as estruturas características

básicas dos dados geoespaciais para identificar os procedimentos necessários, desde a formalização dos operadores e suas aplicações até a exibição dos dados geoespaciais em um produto cartográfico. Todos os trabalhos supracitados buscavam definir como a generalização cartográfica deveria incorporar-se em um ambiente digital. Uma das alternativas para responder esse questionamento foi proposta por McMaster e Shea (1992), um modelo conceitual de generalização largamente aceito até os dias atuais.

McMaster e Shea (1992) entendem a generalização como uma transformação de dados espaciais e de atributos realizada para fornecer conteúdo adequado à representação, em conformidade com sua escala e baseado em três questionamentos: por que (objetivos filosóficos), quando e como generalizar? (FIGURA 11).

FIGURA 11 - MODELO CONCEITUAL DE GENERALIZAÇÃO (MCMASTER E SHEA, 1992)



FONTE: O autor (2022).

Os objetivos filosóficos (comunicabilidade, requisitos e recursos computacionais) justificam e provocam a possibilidade de generalização em meio digital e fornecem a base teórica para o segundo estágio do modelo conceitual de McMaster e Shea (1992), em que se busca responder quando generalizar. Essa segunda etapa está associada à afirmativa de Li; Openshaw (1993), os quais mencionam que o motivo da generalização está na relação entre legibilidade gráfica e escala. McMaster e Shea (1992) caracterizam essa análise como avaliação cartométrica (condições geométricas, espaciais e de transformação), informações de base para solucionar o terceiro questionamento: como generalizar? A etapa que define como generalizar é responsável pela determinação dos operadores de generalização, classificados em espaciais

(simplificação, suavização, agregação, união, colapso, refinamento, exagero, realce e deslocamento) e de atributo (classificação e simbolização), adotados para a realização de transformações geométricas e semânticas.

Independente do modelo conceitual empregado, o objetivo da aplicação do processo de generalização é semelhante. Segundo Brassel e Weibel (1988), no contexto analógico, os processos são usados como uma etapa preparatória para a confecção de mapas. No contexto da generalização orientada a modelos conceituais, preocupa-se não apenas com a exibição, mas também com o contexto de redução de dados que permita minimizar custo computacional de processamento e armazenamento. O objetivo é a aplicação de algoritmos gerenciáveis para diferentes usos, minimizando requisitos de memória e maximizando a eficiência computacional (processamentos analíticos em SIG e transferência de dados em rede, como exemplos). Os dados de saída não são mapas propriamente ditos, mas dados pré-processados para uso em ambientes SIG, contendo processos completamente formalizados sem habilidades de decisões gráficas subjetivas.

Neste quesito, apesar das proposições dos modelos conceituais no âmbito digital e da ampla adoção do modelo de McMaster e Shea (1992), a inserção de novas tecnologias e procedimentos de representação dos ambientes insere desafios em relação à automatização e à aplicação das estratégias de generalização cartográfica. A automação dessas atividades requer a compreensão da relação entre diferentes objetos presentes no conjunto de dados e o seu valor informativo, necessitando definir estratégias e formulações a partir de um conjunto de regras, para geração de conhecimento e/ou descoberta de padrões. As dificuldades estão relacionadas às características intrínsecas aos dados geoespaciais que formam o BDG primário e à heterogeneidade dos ambientes a serem mapeados.

Apesar das dificuldades, um conjunto de dados geoespacial faz parte da Linguagem Natural (LN), entendida como qualquer forma de linguagem desenvolvida naturalmente pelo ser humano. Este conceito é proveniente da Linguística de Corpus (LC) (SÁNCHEZ, 1995), área de lingüística que analisa um conjunto de amostras linguísticas (corpus) para identificar a dinâmica e os significados das palavras no contexto do Processamento da Linguagem Natural (PLN) (FINATTO; LOPES; CIULLA, 2015), uma subárea da Ciência da Computação e da linguística que estuda os problemas de geração e de compreensão automática de línguas humanas naturais. Dentro da área científica da LC, objetiva-se coletar e explorar os corpora linguísticos sistematizados e suficientemente extensos em amplitude, de maneira que sejam representativos da totalidade do uso linguístico, a partir de evidências empíricas extraídas por meio de computador (SÁNCHEZ, 1995).

A Ciência da Computação objetiva entender a representatividade de um corpus e gerar hipóteses e soluções a partir do PLN, preocupando-se não somente com um objeto isolado, mas com o entendimento semântico de toda a estrutura, em que a percepção e a cognição humana desempenham um papel importante e, devido às limitações cognitivas e à mutação da língua em decorrência do dia a dia, a maioria dos enunciados humanos são mais simples, repetitivos e previsíveis, a partir da aplicação de métodos estatísticos modernos (HINDLE et al., 2016). Na área da LC, um corpus linguístico é analisado para identificar a dinâmica e os significados das palavras. No âmbito geoespacial, um conjunto de geodados (corpus geoespacial) é processado e interpretado para significar ambientes geoespacializados. Em ambos os casos, computacionalmente o propósito é segmentar e extrair informações para gerar conhecimento automático sobre os aspectos analisados. No âmbito cartográfico, a PNL é empregada para compreender o contexto geoespacial de eventos e permite derivar significados de um corpus de maneira automatizada, por evidências empíricas extraídas por meio de computador (esses conceitos são abordados em detalhes no Capítulo 3).

A partir de um corpus geoespacial, a generalização cartográfica envolve o contexto cognitivo humano para interpretá-lo, extrair conhecimento e definir quais as informações são necessárias para a compilação de um objetivo em específico. Isto está relacionado com as decisões do analista em saber como generalizar ou resolver potenciais conflitos. No processo manual, é simples implementar essas estratégias holísticas (MCMASTER; SHEA, 1992), entretanto, no digital, soluções subjetivas são de difícil implementação (ZHANG et al., 2021).

As soluções encontradas partem do princípio de que a generalização cartográfica é decomposta em processos computacionais, seguindo o contexto do PLN e considerando que o domínio geoespacial apresenta repetibilidade geométrica e semântica; logo, é possível, a partir de métodos estatísticos e uma linguagem formalizada de programação computacional, interpretar e generalizar um corpus geoespacial. Nesse quesito, observa-se que operadores de generalização cartográfica - como definidos por McMaster e Shea (1992) - e algoritmos de generalização têm uma relação hierárquica. Enquanto o operador define a transformação que deve ser alcançada, o algoritmo computacional é empregado para implementar uma transformação particular em decorrência da análise do corpus geoespacial. Nesse caso, os operadores de generalização são independentes do modelo de dados ou das classes de uso específicas (estradas, edificações, hidrografia, etc.).

Assim, a generalização cartográfica no âmbito digital deve ser subdividida em um conjunto de operadores de generalização que consigam solucionar problemas específicos automaticamente quando couber (BANASIK ET AL., 2022). Isto acarreta dificuldades quando

se muda o BDG primário e as suas características geométricas e/ou as estatísticas não refletem o conjunto anteriormente analisado. Fator que influencia nos desenvolvimentos científicos recentes e na evolução dos métodos de generalização digital que buscam entender como implementar transformações, independentemente do corpus geoespacial que se deseja generalizar (SUN et al., 2016; SESTER et al., 2018; DUO; YU et al., 2020; ZHANG, 2021).

Para analisar as pesquisas recentes são apresentados aspectos bibliométricos na Subseção 2.3.2, como segue.

2.3.2 Aspectos bibliométricos


Para analisar os modelos da literatura científica quantitativamente, foram considerados artigos publicados entre os anos de 1980 e 2021 e recuperados a partir da análise dos tópicos *Cartographic Generalization* e *Map Generalization*. Foi aplicado um processo computacional automático para a seleção de artigos de forma consistente, eliminando redundâncias a partir da análise dos títulos e possíveis trabalhos que não abordam a temática propriamente dita, mas que foram inseridos como resultados nas buscas de cada plataforma. No total, 1256 trabalhos foram selecionados, abordados por pesquisadores de diferentes países. No gráfico da FIGURA 12, é ilustrado o crescimento de pesquisas relacionadas à temática. Mesmo apresentando variações anuais, o saldo é crescente e positivo, fator que demonstra ainda a necessidade de aprimoramentos e de investigação.

A partir da FIGURA 12, em 1980, são listados os dois primeiros artigos que discutem aspectos da generalização cartográfica, enquanto no ano de 2021 soma-se um total de 1256 trabalhos que desenvolvem técnicas ou discussões relacionadas ao tema (artigos de revisão). Apesar de a bibliometria sugerir o início das pesquisas em 1980, propostas anteriores são observadas, como Steward (1974) e Töpfer; Pillewizer (1966) (listados na plataforma Google Acadêmicos), que trazem aspectos teóricos importantes. No entanto, o crescimento foi lento até os anos de 1990, década em que houve o aumento de atividades relacionadas à automação por meio de computadores.

As agências nacionais de mapeamento se esforçaram para automatizar processos manuais, e pesquisadores da década foram atraídos pelo desafio do processo de generalização cartográfica computacional, abrindo várias faixas de pesquisas. As discussões abertas deram início à produção científica, abordadas por grupos como a ICA, a partir da comissão nominada de *Commission on Generalization and Multiple Representation* (Comissão de Generalização e representação múltipla). Atualmente, a proposta das discussões se relaciona ao

desenvolvimento de métodos automatizados que permitam a criação e a exibição de informações geoespaciais em diferentes níveis de detalhe, considerando uma variedade de tecnologias de aquisição de dados geoespaciais e de processamento disponíveis atualmente.

FIGURA 12 - Nº DE PUBLICAÇÕES EM GENERALIZAÇÃO CARTOGRÁFICA



FONTE: O autor (2022).

Sester (2020) esclarece essa afirmativa a partir da exemplificação do desenvolvimento de sensores de aquisição de dados espaciais que permitem coletar geoinformação de forma altamente distribuída (LiDAR, câmeras, GNSS, etc.), além de novas formas de mapeamento, como o colaborativo, que fornecem um fluxo de informações atualizadas, por diferentes sensores, pessoas e instituições que não necessariamente tenham o foco centrado no mapeamento topográfico tradicional, mas no monitoramento, na representação e na análise espacial dos elementos que compõem o ambiente, a partir de um processamento integrado de diferentes fontes de geoinformação, com diferentes resoluções e densidades (GENCARELLI et al., 2022).

Esses fatores implicam na necessidade de generalizar quando se trabalha com fontes de dados de forma incremental, ou seja, a realização da homogeneização dos variados conjuntos de dados que compõem um BDG em um processo de integração. Ademais, a generalização digital pode ser usada para permitir uma compreensão rápida, apoiar uma análise com um nível de detalhamento grosseiro para um refinado e processar dados em um LoD ideal para uma tarefa, minimizando custo computacional e de armazenamento em BDG (BILJECKI et al., 2016).

Os desafios inseridos no âmbito digital associados ao avanço tecnológico recente apresentam aspectos multidisciplinares e atrai pesquisadores de diferentes áreas, como os especialistas em BDG e modelagem ontológica, em geometria computacional e análise espacial, informática e designer de interface, serviços de web, modelagem baseada em agentes e a maioria dos profissionais da Cartografia. Observa-se, na FIGURA 13, que na categoria denominada de Geografia (que na plataforma WoS se subdivide em Geografia e Geografia Física) concentram-se o maior número de publicações, seguido pelas áreas de Ciências da Computação que engloba a generalização no âmbito computacional, aspectos de armazenamento em BDG (BILJECKI et al., 2016) e o desenvolvimento de operadores de generalização a partir da implementação de algoritmos heurísticos (ZHANG et al., 2021), genéticos (SUN et al., 2016) e de AM (SESTER et al., 2018; DUO; ZHENG et al., 2021).

FIGURA 13 - ÁREAS DE CONCENTRAÇÃO EM GENERALIZAÇÃO CARTOGRAFICA



FONTE: O autor (2022).

Dentre as iniciativas recentes, algoritmos computacionais são desenvolvidos e aprimorados para a materialização computacional de operadores de generalização (processos relacionados à geometria computacional e análise espacial), como simplificação de feições lineares (COURTIAL et al., 2020; ZHENG et al., 2021) e simplificação e agregação de edificações (SESTER; et al., 2018; DUO et al., 2021) por meio de AM. Estes algoritmos são aplicados para compilar cartas topográficas e para materializá-los é necessário que se tenha um conjunto de dados amostral relativamente extenso para treinar o modelo AM de forma adequada. A maioria das abordagens trabalha com dados no formato matricial. Iniciativas que empregam dados no formato vetorial são raras devido à complexidade do processo.

Outras estratégias também são empregadas frequentemente, como Sue et al. (2016), que a partir de algoritmos genéticos desenvolveram um operador de deslocamento. No contexto web, a generalização cartográfica apresenta um aspecto importante devido à prevalência de mapas em ambientes digitais que permitem operações de zoom e visão panorâmica em várias extensões e escalas (GRÖBE; BURGHARDT, 2021), envolvendo aspectos de modelagem ontológica (BILJECKI et al., 2016; MEMDUHOGLU; BASARANER, 2021), e interação com o usuário (GAFFURI, 2011).

Outra vertente da generalização não a aplica na compilação de produtos cartográficos, mas visa a minimização da redundância do conjunto de dados geoespacial primário, como o da generalização cartográfica 3D (SESTER, 2020). Para alcançar este objetivo, a principal estratégia é aplicação de operadores de simplificação (HUBO et al., 2006; ELSEBERG et al., 2013; HUANG et al., 2020), que buscam minimizar o conjunto de geodados sem perdas excessivas, constituindo estratégias de minimização do custo computacional de processamento e de armazenamento do conjunto de dados original.

Esse processo está relacionado diretamente ao BDG e relaciona-se com a modelagem ontológica e a geometria computacional. Em um ambiente SIG, por exemplo, a visualização é essencial para exploração, interpretação e comunicação de dados. Aplicações independentes exigem graus variáveis de detalhes e necessidades de modelagem da informação geográfica em diferentes LoDs, em que o fenômeno seja mais bem compreendido. O principal problema, no ponto de vista de produção de dados, é que a gestão e a manutenção dos dados são limitadas pelos requisitos de precisão.

No Brasil, existem algumas iniciativas que discutem a temática de generalização cartográfica, principalmente no contexto da produção de cartas topográficas de forma automatizada; prática não aplicada operacionalmente no país. Dentre as iniciativas, as discussões são orientadas em virtude de avaliações cartométricas a partir da detecção de problemas geométricos resultantes da redução de escala, da definição de operadores e da adoção de uma simbologia adequada seguindo os princípios de McMaster e Shea (1992), como em Tuara et al. (2010) e Comé e Sluter (2015).

Essas mesmas perspectivas são levantadas e aplicadas em ambientes web, com discussões relacionadas a multiescala, simbolização e aplicação de operadores de generalização, como em Pombo e Sluter (2010) e Graça e Fiori (2015). A materialização de operadores de generalização por meio de algoritmos computacionais também é abordada. Nessa perspectiva, pode-se citar Gruppi et al. (2016) e Firkowski (2002), ambos os trabalhos abordam a implementação de operadores de simplificação. O primeiro para feições lineares e, o segundo,

para superfícies topográficas. Observa-se que a generalização cartográfica é uma área multidisciplinar e envolve uma lista extensa de subtópicos relacionados. Para ilustrá-los, na FIGURA 14 são apresentados os termos-chave empregados nos títulos dos artigos selecionados a partir da busca bibliométrica.

FIGURA 14 - PRINCÍPIAS PALAVRAS EMPREGADAS NOS TÍTULOS DOS ARTIGOS



As propostas atuais são relacionadas ao processo digital, buscando o desenvolvimento de algoritmos para automatizar a atividade, definindo operadores, o tratamento holístico das propriedades geométricas e os seus relacionamentos para a generalização do corpus geoespacial que integra um BDG. Constata-se que as estratégias de generalização automática se transformam vide os objetivos dos seus idealizadores e em função da primitiva geométrica analisada. Todavia, os operadores considerados importantes são definidos conforme a visão e o entendimento do analista acerca do contexto global, inserindo a generalização em um processo subjetivo e holístico, tornando a sua automatização um desafio (MCMASTE; SHEA, 1992).

A maioria das estratégias atuais buscam integrar o conhecimento cartográfico em tarefas automatizadas e estão relacionadas com aspectos gráficos, como a análise de características geométricas (FORBERG, 2007; BILJECKI et al., 2016, DU et al., 2022), a designação de símbolos cartográficos (BARTONĚK; ANDĚLOVÁ, 2022) e definição de padrões (DYER et al., 2022), relacionando-se com três aspectos: 1) Critérios e especificações técnicas atuais (normatizações, padrões e especificações técnicas); 2) Análise das características geométricas e semânticas do conjunto de dados que integra o BDG primário e;

3) Definição de regras automáticas de generalização cartográfica digital materializadas por linguagem de programação.

Esses tópicos devem ser estudados não apenas para analisar as regras de generalização cartográfica implementadas, mas para avaliar o sucesso do processo. No contexto digital, deve-se considerar as limitações dos ambientes computacionais, que necessitam representar formalmente o conhecimento cartográfico para generalizar de forma automática, uma vez que os algoritmos são baseados em lógica, modelos e ontologias. O principal desafio está relacionado ao questionamento: como expressar o conhecimento dos especialistas em cartografia a partir de métodos computacionais sistematizados para a resolução dos problemas associados à generalização cartográfica?

Apesar dos avanços, uma resposta consistente para o questionamento supracitado ainda não foi completamente formalizada. Desenvolvimentos recentes buscam implementar operadores de generalização cartográfica a partir de diferentes estratégias computacionais. A maioria das pesquisas se concentrou em questões similares, como o desenvolvimento de operadores de simplificação de linhas ou polígonos, sendo que questões mais complexas como orientação de objeto, propósito geral da generalização digital e requisitos de BDG não são frequentemente discutidas.

Dos trabalhos selecionados na pesquisa bibliométrica, no QUADRO 3, são apresentados os desenvolvidos no ano de 2021, selecionados a partir da aplicação do método Proknow-C (ENSSLIN, et al., 2010). Dos 24 trabalhos listados, 7 propuseram a implementação de operadores de generalização cartográfica digital. Dentre a amostra analisada, os autores propuseram a realização de generalização de feições específicas com primitivas geométricas do tipo linha (estradas e hidrografia) ou polígono (edificações), empregando algoritmos heurísticos e/ou AM que apresentam a capacidade de realização de seleção e de extração de feições de uma base de dados geoespacial. A princípio, os algoritmos demonstram performance adequada ao proposto pelos autores, entretanto, quando empregada em uma base de dados específica.

Considerando a aplicação em outros contextos, os procedimentos implementados não apresentam os mesmos resultados, devido à impossibilidade de definir uma sequência ou uma ordem fixa para a aplicação de operadores de generalização que seja universalmente aceita para todas as escalas ou propósitos, sendo ainda um desafio a ser superado. Esse fato está associado à necessidade de identificação dos objetivos da generalização no contexto digital, ou seja, definição de quando e como generalizar a partir do desenvolvimento de um conjunto específico de métodos para abstrações e reduções de dados e discriminar a relação entre redução, qualidade e representação dessa base.

QUADRO 3 - PESQUISAS EM GENERALIZAÇÃO CARTOGRÁFICA (2021)

Autores	Estratégia de generalização cartográfica
Cheng et al. (2021)	Adaptação do algoritmo Douglas-Peucker para a generalização cartográfica de redes hidrográficas. Aplicação de processos de simplificação.
Skopeliti et al. (2021)	Processo de generalização cartográfica para extração de linhas de costa de um MDT, seguindo as restrições impostas pela <i>International Hydrographic Organization</i> (IHO). Aplicação de processos de simplificação, agregação, exagero e omissão.
Li et al. (2021)	Generalização de MDT de áreas submarinas. Aplicação de algoritmos heurísticos para extração de pontos e ponderação para aplicação de processos de interpolação.
Zheng et al. (2021)	Generalização cartográfica de estradas. Aplicação de estratégias de Redes Neurais Convolucionais (RNC).
Zhang et al. (2021)	Deteção de conflitos na representação de estradas em uma análise multi-escala. Emprega o algoritmo <i>K-order</i> para identificar e analisar vizinhança para o refinamento geométrico de topologia.
Liu et al. (2021)	Reconhecimento e extração automática de polígonos que representam edificações. Empregam estratégias baseadas em RNP em uma estrutura de grafos.

FONTE: O autor (2022).

Independentemente da proposta implementada, a eficiência e a precisão dos resultados obtidos com a implementação dos operadores são fatores determinantes para o desenvolvimento e a seleção de um algoritmo apropriado (MCMASTER; SHEA, 1992). Para tarefas tradicionais e em contextos específicos, os procedimentos computacionais de generalização existentes são eficientes e se assemelham com às de generalização manual. Todavia, uma solução padronizada relativa a novas tecnologias e a demandas relacionadas ao mapeamento é de difícil implementação, fator que insere desafios e lacunas científicas a serem investigadas (Subseção 2.3.3).

2.3.3 Desafios na generalização cartográfica

Apesar do progresso e do número de desenvolvimentos relacionados à generalização, a temática ainda é um desafio para a Cartografia (SCHIEWE, 2021), principalmente quando se relaciona às novas tecnologias empregadas para a representação cartográfica ou aos desenvolvimentos computacionais de processamento de dados geoespaciais. Em um primeiro momento, a implementação de operadores se dava por processos matemáticos e estatísticos empregados para a materialização digital do processo de generalização, no entanto, o contexto geoespacial nem sempre é considerado (CEBRYKOW, 2017). Para considerar a conjuntura geoespacial, surge o conceito de sistemas especializados (BANASIK et al., 2022), sobre o qual se busca criar regras que refletem o conhecimento e a experiência humana por meio de formulações algorítmicas em meio digital, todavia essa tarefa é complexa, e a maioria dos sistemas desenvolvidos nunca foram completamente implementados ou aceitos na prática.

Estratégias intermediárias ainda buscam a formalização do conhecimento cartográfico necessário para a automatização da generalização e a combinação de estratégias baseadas em estatística e em matemática, com sistemas especializados, denominado pelo seu precursor, Weibel (1991), de inteligência ampliada. Nesse caso, o analista controla e decide os procedimentos a serem empregados. Uma desvantagem do processo está relacionada à falta de contextualização espacial e à necessidade de experiência no processo de generalização cartográfica por parte do analista. Métodos baseados em regras também foram propostos para automatizar a generalização cartográfica.

Conforme Jones e Ware (2005), esses procedimentos são denominados de sistemas de modelagem baseados em restrições. Para sua implementação, um mapa recém-elaborado deve atender a condições pré-determinadas, como, por exemplo, o estabelecimento de dimensões de objetos relacionados a um LoD específico. Em sistemas comerciais, a maioria dos processos de generalização são classificados como semiautomáticos, com aplicação de operadores de generalização de forma individualizada, como a agregação ou a simplificação de formas geométricas. Apesar dos desenvolvimentos, o principal desafio é a ausência de abordagens abrangentes que considerem todo o corpus geoespacial de um BDG primário e a influência desse relacionamento ao geoespacial.

No contexto geral, os algoritmos de generalização cartográfica são eficientes para a maioria das tarefas relacionadas à construção de representações, porém, para o contexto digital, ainda se necessita de avanços significativos para tarefas específicas. Entretanto, a interdependência das operações e as necessidades de implementação de meios de controle de qualidade automáticas inserem limitações. Segundo Jones e Ware (2005), trabalhos científicos das últimas décadas buscaram solucionar a problemática, no entanto, os resultados apresentaram limitações que estão presentes ainda atualmente. Parte dessas limitações estão relacionadas com as inadequações das implementações dos operadores de generalização associadas à dificuldade do estabelecimento de um conjunto de regras apropriadas para um conjunto de situações com características específicas. Atualmente, alguns esforços estão concentrados nesse aspecto, com implementação de técnicas de AM, uma das novas tecnologias promissoras de desenvolvimento na temática.

Sester (2020) relaciona essas problemáticas e as insere um contexto tecnológico recente. A autora lista 3 tópicos de interesse global. O primeiro diz respeito ao potencial de métodos de AM e RNA aplicados para resolver problemas de generalização. A ideia central é usar conjuntos de dados existentes e treinar um modelo supervisionado para generalizar automaticamente uma base cartográfica. As RNAs são aplicadas nessa tarefa devido ao avanço

de sistemas computacionais associado à disponibilidade crescente de dados de entrada que possam ser empregados como exemplos para o treino dos algoritmos supervisionados (SESTER et al., 2018; FENG et al., 2019; COURTIAL et al., 2020; LIU et al., 2021).

A tarefa é encontrar uma solução criativa para um problema complexo. O objetivo imediato é revelar regras subjacentes para uma ferramenta versátil que produz uma versão em escala de um determinado conjunto de dados de entrada, principalmente para dados em formato vetorial, uma vez que os métodos de AM são aplicados com frequência em dados matriciais. Os processos de generalização cartográfica com base na AM são conhecidos como métodos baseados no conhecimento. Geralmente são implementados seguindo regras relacionadas ao conhecimento geométrico (tamanho, forma, distância), estrutural (relacionamentos entre feições) e/ou processual (operações de sequenciamento de operadores de generalização).

O segundo tópico listado por Sester (2020) é a aquisição de dados de forma incremental e a criação de representações, a partir de métodos de aquisição de dados espaciais, de forma distribuída. O processo de generalização cartográfica nesse aspecto é aplicado na compilação de dados de diferentes fontes para a construção de um produto em um LoD pré-definido a ser acessado por dispositivos eletrônicos, como estações *Desktop* ou dispositivos móveis (que apresentam requisitos e desafios específicos). Por exemplo, para representar tridimensionalmente uma edificação, necessita-se de dados em diferentes perspectivas, a nível terrestre (interno e externo) e a nível aéreo, utilizando câmeras ou sensores LiDAR.

O desafio é integrar os diferentes blocos de informação, considerando as peculiaridades dos dados de base. Nesse caso, a generalização é necessária para garantir que a representação resultante estará em um estado consistente, mesmo que o objeto completo não seja capturado. Uma abordagem computacional hierárquica permite armazenar um modelo preliminar grosseiro e incrementalmente pode ser refinado, uma vez que mais dados estejam disponíveis (BILJECKI et al., 2016) e considerando os princípios da generalização. Os fatores supracitados estão relacionados a aspectos recentes e inovadores, como por exemplo a utilização da *Internet of Things* (IoT) (RAY, 2018) e a construção de representações que compõem sistemas de Smart Cities e *Digital Twins* (DÖLLNER, 2020; XUE et al., 2020).

Por fim, menciona-se a generalização cartográfica 3D como o terceiro ponto que necessita de desenvolvimento científico e que permanece um desafio. Enquanto no processo usual se aprimora a legibilidade do produto, aqui, é requerido a redução da demanda de armazenamento, a simplificação do processamento dos dados e a análise de um nível grosseiro para um refinado (BILJECKI et al., 2016; TANG et al., 2020). O principal problema é que esse processo exige tarefas de generalização, entretanto, os operadores não estão completamente

definidos e dependerão da finalidade do aplicativo. Alguns esforços vêm sendo realizados, principalmente na generalização de edificações (FORBERG, 2007; TANG et al., 2020), na construção de Modelos Digitais de Terreno (MDTs) e nos estudos da paisagem (JENNY, 2021).

Nesse âmbito, abrem-se ao menos 3 lacunas científicas (FIGURA 15): 1) Implementação de algoritmos de AM para generalização de estruturas não regulares em formato vetorial; 2) Aplicação de processos de generalização cartográfica em dados geoespaciais adquiridos de forma incremental, respeitando a qualidade da geoinformação e 3) Definição e implementação de regras de generalização cartográfica 3D.

FIGURA 15 - PRINCIPAIS LACUNAS DE PESQUISA



FONTE: O autor (2022).

Estes três tópicos estão relacionados com o surgimento das novas tecnologias de aquisição de dados e de processos de representação e a utilização de um corpus geoespacial que necessita de minimização do conjunto de geodados e de procedimentos computacionais formais para a significação espacial de forma adequada. Ademais, pode-se citar a necessidade do desenvolvimento de métodos que permitam a análise e o conhecimento estrutural do conjunto de dados. Para isso é necessário o desenvolvimento de ferramentas que permitam expressar e interpretar a complexidade da distribuição e relações espaciais entre os elementos que compoñham uma base cartográfica, para que os operadores de generalização sejam adequadamente aplicados.

2.4 CONCLUSÕES DO CAPÍTULO

Os aspectos de generalização cartográfica e as estratégias existentes funcionam de uma forma satisfatória para contextos específicos. Todavia, na era digital, existem lacunas importantes a serem investigadas, e a generalização cartográfica automatizada continua sendo

um dos maiores desafios na manutenção, apresentação e recuperação de um corpus geoespacial com um LoD que atenda aos requisitos dos usuários e dos serviços de acesso público. Generalizar automaticamente um conjunto de dados geoespaciais digitais dependem de soluções de problemas relacionados à materialização computacional dos operadores de generalização que necessitam de uma ligação imediata com a compreensão e a percepção humana.


Necessita-se do desenvolvimento de novas técnicas que facilitem o acesso em redes de dados que crescem exponencialmente em sistemas Desktops e/ou dispositivos móveis, considerando aspectos específicos do corpus geoespacial analisado (como por exemplo o 2D e o 3D). A generalização cartográfica, portanto, é um tema desafiador e necessita de avanços tecnológicos para projetar e oferecer aos usuários representações, produtos e dados cartográficos de maneira eficiente. Para isso, é necessário adequar as bases de dados por processos específicos de classificação, filtragem, agregação e integração de informações geoespaciais, para apresentá-las de maneira ideal em diferentes níveis de representação.

No Capítulo 3, discute-se o contexto da generalização cartográfica 3D, a formação de um corpus geoespacial 3D e sua relação com a HN centrada em nuvens de pontos LiDAR.

CAPÍTULO 3 - GENERALIZAÇÃO E NUVENS DE PONTOS LIDAR

Uma nuvem de pontos LiDAR é uma representação 3D universal e pode retratar diferentes objetos físicos, paisagens, regiões geográficas ou infraestruturas em escalas e com precisões diversas a depender da plataforma e sensores empregados. A aquisição destes geodados, como mencionado no Capítulo 2 (QUADRO 2), é baseada em tecnologias que inclui o SLA ou o SLT, mapeamento móvel – plataformas dinâmicas terrestres -, câmeras RGB-D, imagens ou sondas multifeixes (DÖLLNER, 2020). No contexto cartográfico 3D as nuvens de pontos LiDAR são onipresentes. São aplicadas como dados de base primários para o monitoramento ambiental, planejamento urbano (JANECKA, 2017), BIM (NIKOOHEMAT et al., 2020) e o SIG 3D (BILJECK et al., 2016), sendo o principal elo entre o mundo real e o 3D computacional (POUX, 2019), como mostra a FIGURA 16.

FIGURA 16 - NUVENS DE PONTOS LiDAR x MUNDO REAL E O VIRTUAL 3D



A principal característica desses geodados consiste na ausência de qualquer informação estrutural, hierárquica ou relacionada à semântica. A falta de topologia e conectividade, no entanto, é um aspecto que representa, simultaneamente, vantagens e desvantagens (DÖLLNER, 2020). A principal vantagem está na possibilidade de interpretar a nuvem de pontos LiDAR com base na distribuição aleatória e na relação matemática com a vizinhança imediata do conjunto de pontos que a constitui. Todavia, processá-la é uma tarefa desafiadora e sintetizada por alto custo computacional. Ademais, é um geodado adquirido em um determinado período, sem especificações estruturadas e semântica. Há, portanto, uma forte

demanda por soluções que permitam enriquecer nuvens de pontos LiDAR considerando seus aspectos geométricos e estatísticos.

Este processo é possível devido à consideração de que nuvens de pontos LiDAR fazem parte da LN na representação e interpretação de ambientes geoespaciais formando um *corpus* Geoespacial 3D, interpretado a partir de linguagem de programação formalizada, conforme discutido na Subseção 3.3.

3.1 CORPUS GEOESPACIAL

Um corpus é um termo proveniente da Linguística, definido como um conjunto de dados linguísticos (oral e/ou escrito da língua), sistematizados segundo determinados critérios, suficientemente extensos em amplitude, de maneira que sejam representativos da totalidade do uso linguístico, dispostos de tal modo que possam ser processados por computador, com a finalidade de proporcionar resultados variados e úteis para a descrição e análise (SANCHEZ, 1995). É explorado de forma empírica pela Linguística de Corpus (LC) por meio de algoritmos computacionais. Em síntese, um corpus é tido como representativo da linguagem (idioma) ou de uma variedade dela (SARDINHA, 2004).

A LC, portanto, é o estudo da língua em uso sempre em grande escala, com apoio informatizado e tratamento estatístico. Objetiva compreender o funcionamento da língua e descrever seus usos a partir de uma concepção probabilística e combinatória para analisar a colocabilidade em torno de uma palavra para sua descrição em meio ao sistema da língua (FINATTO, LOPES; CIULLA, 2015). Busca revelar respostas para fenômenos linguísticos como uma abordagem metodológica teórica e metateórica a partir de **observações estatísticas e identificação de padrões** de uso de uma **coleção de amostras digitais** (SARDINHA, 2004). A Programação da Linguagem Natural (PLN) é uma área da Computação que busca investigar um corpus linguístico, situando-se como uma subárea da AM (FINATTO; LOPES; CIULLA, 2015).


Conforme Rosa (2011), a PLN é definida como a habilidade de um computador em processar a linguagem natural (usualmente empregada pelos seres humanos) utilizada no dia a dia. O argumento para este processo é a necessidade de entender a pluralidade da linguagem em um mundo globalizado que representa desafios na esfera de negócios, política e ciência. Com o advento da AM, a expectativa era que o computador conseguisse raciocinar e tomar decisões, como metáfora do cérebro humano, não realizando apenas cálculos aritméticos, mas também simulando comportamentos humanos (contexto filosófico) (FINATTO; LOPES;

CIULLA, 2015). Entretanto, existe a demanda por avanços teóricos e práticos no que diz respeito à complexidade de realização de tarefas simultâneas e a rapidez dos softwares. O problema reside no fato de que a máquina funciona apenas para um estado de coisas predefinido, principal desafio a ser superado. A busca por soluções inteligentes volta-se para o desenvolvimento de ferramentas de auxílio ao ser humano em análise e tomada de decisão.

Esse contexto associado a Linguística pode ser repensado e empregado sobre o processo de compilação de produtos cartográficos, em que a linguagem é formalizada com a utilização de dados geoespaciais. Tanto aqueles produzidos por usuários comuns (blogs, postagens na web, mapeamento colaborativo), quanto os tradicionais compilados por agências e profissionais de Cartografia empregando sensores específicos para o mapeamento. A PLN, portanto, pode ser aplicada no contexto geoespacial para a formalização algorítmica de processamento e compilação de produtos cartográficos em diferentes domínios de aplicações.

Essa afirmação parte do pressuposto que dados geoespaciais fazem parte da LN. Tradicionalmente, a LC relaciona-se com uma amostra linguística (corpus), analisada para identificar a dinâmica e os significados das palavras em um determinado contexto específico. No âmbito geoespacial, um conjunto de geodados (Corpora geoespaciais) é processado e interpretado para significar ambientes geoespacializados (FIGURA 17).

FIGURA 17 - CORPUS LINGUÍSTICO *VERSUS* CORPUS GEOESPACIAL



FONTE: O autor (2022).

Segundo Sardinha (2000), no contexto da Linguística, um corpus é um conjunto de dados linguísticos (oral ou escrito), sistematizados segundo critérios, suficientemente extensos em amplitude, de maneira que sejam representativos da totalidade do uso linguístico ou de

algum de seus âmbitos, dispostos de modo que possam ser processados por computador, objetivando resultados úteis para descrição e análise.

Em ambos os casos, computacionalmente, busca-se segmentar e extrair informações para gerar conhecimento automático sobre os aspectos analisados condicionados à tecnologia, que permite aprimorar o armazenamento de corpora e sua exploração. Döllner (2020) explora a teoria da LC e afirma que dados geoespaciais se encaixam no conceito de um corpus linguístico. No contexto geoespacial, dados autênticos adquiridos por sensores diversos que fazem parte de um BDG com um propósito de representar o mundo real e extrair conhecimento específico e georreferenciado sobre um determinado local e/ou aspecto produz um corpus geoespacial. Estes dados quando processados e combinados é possível extrair conhecimento formalizado por meio da definição de regras específicas para explorar as características geoespaciais que se deseja.

Essa afirmação se relaciona com a utilização de dados geoespaciais. Normalmente, o mapeamento envolve grandes conjuntos de dados geoespaciais coletados de fontes diversas e armazenados em formatos variados incluindo informações como dados de censo, imagens, nuvens de pontos LiDAR e dados de mídia social. São úteis, principalmente, quando descobertos, compartilhados, analisados e empregados para a extração de conhecimento formalizado e/ou compilação de representações que descrevam objetos, eventos ou outros recursos a partir da combinação de dados caracterizados pela localização e algum tipo de atributo.


É interessante notar, neste aspecto, a semelhança entre Linguística e Cartografia. Na primeira, a principal finalidade do Corpus linguístico é de ser o instrumento de investigação da estrutura da linguagem a partir de evidências extraídas por meio de computador para revelar fatos a respeito de uma linguagem (SARDINHA, 2004), sendo o corpus considerado por Leech (1992) como uma abordagem filosófica para extração de conhecimento. No contexto cartográfico, os dados geoespaciais remontam esta concepção, em que formam o conjunto comunicativo essencial, que quando organizado e explorado permitem a extração de conhecimento e comunicação. Dessa forma, a utilização de um corpus geoespacial permite verificar teorias, descobertas de padrões e variações servindo como fonte quantitativa de informação.

A exploração desses fatores está condicionada a definição de abordagens de investigação que são baseadas nas teorias da PLN com aspectos associados a AM, então, podem ser aplicadas para a definição de padrões e descrição de dados geoespaciais de entrada por meio de vetores característicos n dimensionais cujos componentes numéricos descrevem aspectos

selecionados de um fenômeno a ser observado para processar e visualizar espaços e recursos com eficiência. A principal vantagem de se considerar um conjunto de dados geoespaciais como corpora é aplicabilidade geral das estratégias AM e exploração das características geométricas e estatísticas do conjunto, modelando fenômenos de difícil descrição, como o caso das nuvens de pontos LiDAR.

Segundo Döllner (2020), devido à irregularidade, áreas de oclusões e ambiguidade as nuvens de pontos LiDAR são dados difíceis para a programação processual e algorítmica. Suas características, no entanto, permitem aplicar estratégias computacionais para sua exploração efetiva. As características que permitem essa atividade são ilustradas na FIGURA 18.

FIGURA 18 - CARACTERÍSTICAS ESSENCIAIS DAS NUVENS DE PONTOS



FONTE: O autor (2022).

Essas propriedades são exploradas em domínios específicos e aplicativos de computador, normalmente por processos de minimização de redundância, definição da semântica do conjunto de pontos e extração de contextos específicos em um processo de agregação de pontos vizinhos. Algoritmos processuais, heurísticos ou empíricos podem ser aplicados para explorar os corpora 3D formado por uma nuvem de pontos LiDAR. No entanto, aplicações AM, geralmente, têm complexidade de implementação inferior devido a possibilidade de customizar as estruturas AM previamente implementadas em decorrência do estabelecimento de dados de treinamento e testes apropriados (POUX, 2019).

Essas tarefas são calcadas nas características estatística e geométrica das nuvens de pontos LiDAR, baseando-se na Hipótese da Naturalidade (HN).

3.2 HIPÓTESE DA NATURALIDADE CENTRADA EM NUVENS DE PONTOS

Os campos da LC e o PLN contam com comunidades científicas e correntes filosóficas com abordagens e aspectos prático-teóricos distintos. No entanto, no âmbito digital (especificamente no campo da Engenharia de Software - ES), pesquisadores propuseram a

Hipótese da Naturalidade (HN) (HINDLE et al., 2016) que argumenta que a programação e as linguagens podem ser compreendidas e manipuladas com as mesmas abordagens aplicadas naquelas definidas como naturais. Inspira pesquisas e soluções baseadas na interseção da ES e linguagens de programação para explorar aspectos distintos em decorrência da área do conhecimento de aplicação.

Estas afirmações são corroboradas pela onipresença de softwares na sociedade moderna. Quase todos os aspectos da vida, incluindo as Geociências, dependem de operações computacionais confiáveis. Todavia, o desenvolvimento de soluções tecnológicas por meio de computador é uma tarefa complexa e os desenvolvedores necessitam lidar com as complexidades inerentes ao software e ao seu contexto no mundo real, que em certa medida é generalizado para que seja viável de implementação. Há, portanto, uma demanda contínua por inovações.

As pesquisas nessa área têm sido dominadas pela abordagem formal lógico-dedutiva, sendo o software construído em linguagens de programação puramente formais para definição, abstração e dedução. As propriedades das ferramentas assim construídas são comprovadas usando técnicas rigorosas e priorizam a teoria computacional apoiadas em contextos matemáticos para avaliar ferramentas de software, mensurando formalmente se os resultados são favoráveis, na prática. Ultimamente, no entanto, devido à grande disponibilização de dados de forma colaborativa e o desenvolvimento de linguagens de programação e sistemas de software de código livre (Linux, MySQL, Django, etc.) permite uma enorme escala de disponibilidade de dados que sugere uma nova abordagem para desenvolvimentos de ferramentas computacionais em que se explora as propriedades estatísticas de distribuição, estimadas em corpora representativos que influenciam no desenho do desenvolvimento (ALLAMANIS et al., 2019).

Esses aspectos estão relacionados diretamente ao desenvolvimento de algoritmos e não necessariamente com a ordem lexical dos métodos. Os principais elementos são as propriedades estatísticas do conjunto de dados que formam um corpus específico. Nesse aspecto, inclui-se o conceito HN que insere que a programação é uma forma de comunicação humana. A HN sustenta que os algoritmos que materializam um software remontam um corpus com propriedades estatísticas similares a LN possibilitando sua exploração para a construção de ferramentas computacionais (HINDLE et al., 2016).

A HN, então, inspira abordagens de AM para criar códigos e soluções probabilísticas que aprendam como os desenvolvedores escrevem e usam naturalmente uma linguagem de programação (ALLAMANIS et al., 2019). Os métodos estatísticos permitem que um sistema

faça hipóteses, juntamente com valores de confiança probabilísticos sobre propriedades formais, fornecendo, assim, formas naturais de aprendizado. Esses aspectos, apesar de serem levantados e abordados em ES apresentam ampla aplicação em áreas distintas do conhecimento. Principalmente devido à capacidade de técnicas de AM de lidar com incertezas e aprender mesmo na presença de ruídos.

Döllner (2020) buscou adaptar a HN para o contexto geoespacial 3D e menciona que as nuvens de pontos LiDAR formam corpora específicos, mas semelhantes em estruturas probabilísticas. Segundo o autor, as nuvens de pontos LiDAR apresentam limitações que dificultam sua interpretação (dados puramente geométricos), contudo, devido apresentar características da LN, podem ser analisadas e processadas estatisticamente. Baseado em Allamanis et al. (2018) no contexto da LN e a partir dos argumentos levantados por Hindle et al. (2016) em ES, Döllner (2020) desenvolveu a HN centrada em nuvem de pontos LiDAR, em que propõe a seguinte afirmativa: *"as nuvens de pontos LiDAR no domínio geoespacial são menos complexas e apresentam repetibilidade. Suas propriedades estatísticas são previsíveis e podem ser interpretadas a partir de métodos estatísticos e linguagem de programação, podendo ser aplicadas em processos de análise geoespacial."*

As abordagens levantadas por Döllner (2020) apresentam aspectos importantes no processamento e interpretação de uma nuvem de pontos LiDAR e existem motivações para incorporar a HN centrada em nuvem de pontos LiDAR no fluxo de processamento desse conjunto de dados. Primeiramente, as nuvens de pontos LiDAR são adquiridas rapidamente por sensores e quando armazenadas computacionalmente apresentam algumas características de um *Big Data* (POUX, 2019) permitindo a obtenção de uma amostra suficientemente extensa para estimar propriedades matemáticas. Uma segunda motivação se relaciona com a possibilidade de incorporar uma modelagem probabilística em métodos de AM para extrair informações métricas e semânticas consistentes. As nuvens de pontos LiDAR são estritamente geométricas, redundantes e ruidosas (FIGURA 18). Métodos probabilísticos oferecem ferramentas para lidar com incertezas e de fundir múltiplas fontes de informação, que na maioria dos perfilamentos apresentam um aspecto ambíguo de difícil interpretação manual.

Ademais, modelos probabilísticos fornecem uma estrutura natural para conectar o conhecimento prévio extraído do próprio conjunto, que permite a determinação de um *framework* de propriedades estatísticas de corpora 3D. Ao prever as propriedades estatísticas da nuvem de pontos LiDAR, fornece-se requisitos básicos para manutenção da solidez das propriedades em padrões estatísticos de forma a quantificar a confiança do método em suas previsões. Esse processo está relacionado com a tarefa de prever um conjunto de variáveis

interdependentes, dado um vetor característico de entrada. Essencialmente, a previsão determina padrões para múltiplas variáveis de saída e pode ser explorada para atingir diferentes soluções, como discutido na Subseção 3.4.1.

3.2.1 Aplicação da HN centrada em nuvem de pontos LiDAR

Independente da aplicação, a teoria da HN pode ser explorada para extrair geoinformação 3D de nuvem de pontos LiDAR e, além disso, pode se acoplar ao conceito de *Smart Point Cloud* (SPC), levantado por Poux (2019), relacionando-se com o fluxo básico de processamento para definir semântica em um conjunto de pontos em decorrência de um LoD para uma determinada finalidade (FIGURA 19).

FIGURA 19 - AUTOMAÇÃO DE TAREFAS NA ESTRUTURAÇÃO DE NUVENS DE PONTOS LIDAR



FONTE: Adaptado Poux (2019).

Poux (2019) menciona que para extrair todo o conhecimento formalizado em uma nuvem de pontos LiDAR é necessário a aplicação de processos de mineração de informação que permitem criar novos conhecimentos a partir de dados estruturados (ou não estruturados) para um determinado domínio. No entanto, a extração de conhecimento é apenas um passo em um contexto global na criação de espaços interativos para a tomada de decisão autônoma e representação do mundo de uma forma que o computador possa usar para raciocinar. Porém, definir uma estrutura modular para dados brutos que permita integração, estruturação e raciocínio é desafiador, especialmente quando se trata de grandes conjuntos de dados de fontes heterogêneas.

A HN centrada em nuvem de pontos LiDAR, portanto, é empregada principalmente no contexto do ordenamento do conhecimento tridimensional em que a partir dos aspectos estatísticos é possível extrair e integrar o conhecimento 3D na construção de modelos geométricos de ambientes. Dados 3D são empregados em um número amplo de aplicações (CECCHINI et al., 2019); que variam de escopo, escala, elaboração e representatividade. Por exemplo, no SIG 3D, modela-se o próprio mundo, com informações em rede, condutividade e

consideração de aspectos topológicos que permitem a análise espacial, realizada em grandes coleções de instâncias 3D armazenadas com coordenadas expressas em um sistema de referência. Já no CAD 3D empregam técnicas paramétricas de modelagem em escala visual descrevendo um objeto complexo em um sistema de coordenadas local. Enquanto o SIG 3D é baseado em um BDG 3D, o CAD 3D é relacionado a desenhos individuais. O BIM apresenta muitas características associadas ao CAD 3D, entretanto, com maior integração semântica (POUX, 2019).

No contexto da SPC, a HN centrada em nuvem de pontos LiDAR é utilizável no pré-processamento dos conjuntos, tal como a sua simplificação e minimização de redundância. Além disso, generalizações estatísticas podem ser computadas, como a definição de um esqueleto topológico baseado em adjacência ou distribuição dos pontos, decomposição espacial, análise de componentes principais para estimação de *features* – definidas nesse trabalho como métricas perspectivas de autossimilaridade (Seção 3.5) - como planaridade, rugosidade, curvatura de nuvem de pontos LiDAR e etc. Isso é relevante na determinação de relações topológicas ou de estimativa de importância no contexto da generalização 3D para a manutenção de características essenciais ao conjunto de dados na modelagem estatística e geométrica de uma superfície ou objeto para posteriormente inseri-lo em sistema.

Essas tarefas permitem estruturar a informação (geometria 3D e semântica) a fim de inserir semântica a uma nuvem de pontos LiDAR minimizando redundância e custo computacional de processamento e armazenamento em acessos de ferramentas de apoio a estruturação de modelos geométricos 3D e raciocínio computacional para determinação de observações estatísticas e identificação de padrões. Métodos de generalização cartográfica 3D fazem parte desse fluxo de processamento inteligente.

3.3 GENERALIZAÇÃO 3D DE NUVENS DE PONTOS LIDAR

Como discutido no Capítulo 2, o procedimento de generalização 3D está diretamente relacionado com a minimização do custo computacional e de armazenamento do corpus analisado. Todavia, quando se analisa as nuvens de pontos LiDAR um limiar deve ser estabelecido para não ser demasiadamente generalizada, perdendo suas características geométricas e estatísticas essenciais. Isso é importante para a manutenção da comunicação entre dados 3D e algoritmos computacionais responsáveis por transformar dados não estruturados em abstrações 3D alimentadas com valor semântico. Entretanto, processos formalizados de generalização 3D ainda não estão completamente disponibilizados.

No contexto 2D, o modelo de McMaster; Shea (1992) é fortemente aceito e pode ser expandido para aplicações 3D. Para generalizar, segundo o modelo conceitual proposto pelos autores, deve-se responder às questões motivadoras (Por quê (questões filosóficas)? Quando? E como?). A principal motivação das questões filosóficas é a necessidade de reduzir a complexidade das representações, respeitando o projeto cartográfico e requisitos dos usuários, mantendo acuracidade e o significado dos atributos. Na análise de quando generalizar são realizados processos cartométricos, identificando condições geométricas que demandam generalização. E por último, a definição dos operadores de generalização que deverão ser aplicados para se chegar ao resultado esperado.

No âmbito 3D, considerando as nuvens de pontos LiDAR como dados de entrada, pode-se aplicar as mesmas condições apresentadas por McMaster; Shea (1992), no entanto, com algumas adaptações. No caso 3D, a generalização é centralizada no fluxo computacional conforme LoD original da nuvem de pontos LiDAR e o exigido por uma determinada aplicação. A preocupação principal é a manutenção das características geométricas essenciais de um ponto e sua vizinhança imediata.

Para exemplificar esse contexto, pode-se observar o QUADRO 4, os aspectos tradicionais da generalização com aqueles definidos para novos paradigmas no mapeamento. Convencionalmente, a generalização é aplicada a partir da análise de elementos teóricos analisando elementos objetivos como a escala e requisitos gráficos (condições geométricas) associado a aspectos subjetivos como características e importância das feições geométricas, definidas pelo analista (medidas espaciais). Esses aspectos são inseridos em processos de generalização cartográfica para obtenção de transformações geométricas e de atributos.

Considerando a generalização cartográfica para o caso 3D a definição das condições de generalização é baseada em aspectos objetivos, em que se analisa os requisitos gráficos para alcançar um LoD pré-definido computacionalmente, visando basicamente a redução do volume de dados e custo de armazenamento, visualização e processamento. No caso das nuvens de pontos LiDAR, operadores de generalização devem ser aplicados. No entanto, a HN deverá ser mantida em LoD inferiores após aplicação de transformação geométricas e de atributos.

Todo o processo está relacionado com a configuração e distribuição de pontos que compõem uma nuvem de pontos LiDAR que deve ser analisada a partir de medidas espaciais que possibilitam interpretar a inter-relação do conjunto (XUE et al., 2020). Esses princípios são aplicados na identificação de características perceptíveis de uma nuvem de pontos LiDAR por meio de relações estruturais entre padrões de distribuição e estatística de vizinhança semelhante. A partir de leis matemáticas baseadas na HN centrada em nuvem de pontos LiDAR

é possível inferir aspectos de proximidade, conectividade e simetria em sistemas computacionais para generalizar objetos de interesse e encontrar transformações de atributos (segmentação e classificação) e geométrica (redução do volume) adequadas para a aplicação pretendida.

QUADRO 4 - ESTRUTURA CONCEITUAL DO PROCESSO DE GENERALIZAÇÃO






Cartografia Digital (McMaster e Shea, 1992)		
Por que generalizar?	Quando generalizar?	Como generalizar?
<u>Elementos teóricos:</u> objetivos (escala e requisitos gráficos) e subjetivos (características e importância das feições)	<u>Condições geométricas:</u> operações de generalização devem ser realizadas reduzindo volume de dados e mantendo a características e feições importantes.	<u>Transformações geométricas:</u> operações de generalização geométrica adequadas para a obtenção de uma representação em uma nova escala.
<u>Propósito:</u> requisitos do usuário.	<u>Medidas espaciais:</u> identificação da necessidade de generalizar, obtendo o inter-relacionamento entre as feições.	<u>Transformações de atributos:</u> operações de generalização conceitual para a obtenção de representações em uma nova escala.
<u>Computacional:</u> custo de armazenamento e computacional.	<u>Controle:</u> seleção de operadores, algoritmos e parâmetros de generalização.	
Nuvens de pontos LiDAR		
Por que generalizar?	Quando generalizar?	Como generalizar?
<u>Elementos teóricos:</u> objetivos (LoD e requisitos gráficos). Interpretação computacional.	<u>Condições geométricas:</u> operações de generalização devem ser realizadas reduzindo volume de dados e mantendo a HN centrada em nuvens de pontos LiDAR.	<u>Transformações geométricas:</u> operações de generalização geométrica adequadas para a redução do volume de dados para obter um LoD adequado.
<u>Propósito:</u> requisitos da aplicação.	<u>Medidas espaciais:</u> identificação da necessidade de generalizar, obtendo o inter-relacionamento entre um ponto e sua vizinhança imediata.	<u>Transformações atributos:</u> operações de generalização para a segmentação e classificação de nuvem de pontos LiDAR.
<u>Computacional:</u> armazenamento e custo computacional.	<u>Controle:</u> seleção de operadores, algoritmos e parâmetros de generalização, conforme necessidade da aplicação.	

FONTE: O autor (2022).

A essas características perceptíveis, neste trabalho, denomina-se de métricas perspectivas de autossimilaridade que permitem a identificação de recursos matemáticos adicionando camadas de detalhe ao conjunto de pontos. Isso é importante devido às características das nuvens de pontos LiDAR que contém grande volume de informação, mas, a menos que sejam previamente processadas, não podem ser efetivamente empregadas ou compreendidas satisfatoriamente. Aplicar as métricas perspectivas implica no primeiro passo para aproveitar uma nuvem de pontos LiDAR de forma eficaz.

A extração e estimativa destas métricas baseia-se na HN e na estimativa matemática dos detalhes das superfícies perfiladas. Fundamentalmente, as métricas permitem a interpretação do espaço físico e é a chave para potencializar a utilização de sensores de mapeamento 3D, com aplicação de uma gama de atividades e aplicações. Para ambientes internos é especialmente interessante a sua aplicação direta, pois permite a interpretação da distribuição espacial de cada ponto associado ao processo de reconhecimento estrutural de edificações. Elementos essenciais ao processo de modelagem geométrica para a construção de um modelo BIM ou um mapa 3D para navegação interna. Logo, analisando as métricas perspectivas é possível determinar níveis de relacionamentos e extrair conhecimento formalizado de uma nuvem de pontos LiDAR, reduzindo redundância e retrabalhos. O QUADRO 5 ilustra algumas métricas empregadas com frequência em perfisamentos de edificações.

QUADRO 5 - EXEMPLOS DE MÉTRICAS PERSPECTIVAS DE AUTOSSIMILARIDADE

Métricas	nuvem de ponto	Representação Gráfica/Numérica	Formalização
Curvatura			$\frac{\lambda_2}{\lambda_0 + \lambda_1 + \lambda_2}$
Planaridade			$\frac{(\lambda_1 - \lambda_2)}{\lambda_0}$
Linearidade			$\frac{(\lambda_0 - \lambda_1)}{\lambda_0}$
Soma dos autovalores			$\lambda_0 + \lambda_1 + \lambda_2$

FONTE: O autor (2022).

As métricas perspectivas materializam as mudanças decorrentes do mapeamento do ambiente e a maioria tem base no cálculo da covariância, derivada de autovalores normalizados ($\lambda_0, \lambda_1, \lambda_2$) (POUX, 2019). Além disso, métricas perspectivas podem ser baseadas em vetores normais calculados localmente em um ponto usando sua vizinhança imediata. O vetor normal n_i estimado é baseado na solução por Mínimos Quadrados (MMQ) em relação à superfície analisada. A verticalidade, por exemplo, é uma métrica perspectiva importante baseada na estimativa de vetores normais, considerando a formação de planos por um conjunto de pontos vizinhos.

Essas métricas (QUADRO 5) são exemplos que materializam de forma específica a HN centrada em nuvem de pontos LiDAR e permitem a obtenção de relações matemáticas e informações relacionadas a cada parte da estrutura de uma edificação. A escolha de qual métrica ou a combinação entre elas a ser empregada dependerá da complexidade da superfície analisada, bem como os interesses do analista. Processos automatizados podem ser aplicados para auxiliarem na estimativa de relacionamentos gerais entre pontos vizinhos para extrair LoDs ideais para uma determinada aplicação.

Na generalização 3D de nuvem de pontos LiDAR o objetivo é extrair, quantificar e formalizar o conhecimento 3D embutido em um LoD adequado a partir de sistemas de generalização abrangente, que ainda não estão complementarmente disponibilizados para o caso 3D, que deverá conter um conjunto de regras de operações de generalização associadas a uma sequência de aplicação e restrições relacionadas aos requisitos de cada aplicação computacional, com qualidade geométrica e semântica definidas a partir de métricas perspectivas pré-estabelecidas.

3.4 CONCLUSÕES DO CAPÍTULO

No domínio geoespacial, as características dos dados são adequadas para implementação de abordagens algorítmicas heurísticas ou estratégias baseadas em AM devido aos seus aspectos estatísticos que permitem encaixá-los no conceito de linguística de corpus. Em relação às nuvens de pontos LiDAR, as métricas perspectivas são aplicadas como recursos de base que permitem derivar semânticas específicas de aplicativos, domínios e tarefas. No âmbito da generalização cartográfica 3D, aspectos da HN devem ser empregados para transcender a modelagem geoespacial e superar a complexidade do conjunto de dados e da geometria de objetos e ambientes.

Nesses aspectos, partindo-se do pressuposto que as nuvens de pontos LiDAR são estatisticamente interpretáveis, é possível materializar operadores de generalização para simplificar e acelerar fluxos de trabalho para o processamento desses geodados. Para concretizar essa atividade, além da necessidade de análise do próprio conjunto de dados, é necessário analisar os objetos e ambientes a serem mapeados e representados em modelos geométricos 3D, conforme realizados nos Capítulos que seguem. No caso deste trabalho, a implementação e sugestão de aplicação de operadores de generalização são baseadas em aspectos construtivos de ambientes internos, considerando que para modelá-lo as principais informações estão relacionadas a aspectos estruturais, considerando que o significado do todo é composto pelo significado das partes, definido por subespaços compostos por partes estruturais específicas.

As estratégias de generalização de nuvem de pontos LiDAR discutidas neste trabalho são apresentadas nos capítulos 4, 5, 6 e 7.

CAPÍTULO 4 - SIMPLIFICAÇÃO POR SIMILARIDADE

O avanço tecnológico e a concepção de novos sensores de aquisição de dados geoespaciais 3D tornaram possível a renderização de estruturas tridimensionais (3D) virtuais (NIKOOHEMAT et al., 2020). Essas tecnologias permitem a concepção de modelos 3D de cidades no contexto de Smart Cities (BILJECK et al., 2016; NEUVILLE et al., 2018) e Digital Twins (LEHNER & DORFFNER, 2020; DÖLLNER, 2020), para representação de ambientes internos (NIKOOHEMAT et al., 2020) e/ou externos a edificações (BILJECK et al., 2016). Dentre as várias alternativas de representação de conteúdo na realidade virtual, a nuvem de pontos LiDAR ganha popularidade devido à eficiência na captura de dados in loco e sua codificação em estruturas 3D renderizáveis em ambientes computacionais.

No entanto, a compilação de modelos geométricos 3D esbarra em um problema recorrente: as características intrínsecas às nuvens de pontos LiDAR. Quando densas, podem retratar tridimensionalmente um ambiente, entretanto constituem dados massivos, puramente geométricos e aleatoriedade na distribuição dos pontos (DÖLLNER, 2020). O problema central consiste na redundância de uma nuvem de pontos bruta que, dependendo do tamanho da área perfilada e a frequência de perfilamento do sensor empregado, a exigência de memória e armazenamento em disco pode impossibilitar processamentos adicionais sem a aplicação de métodos de generalização cartográfica 3D, que ainda não estão completamente disponíveis (SESTER, 2020).

A aplicação de um operador de simplificação de nuvem de pontos LiDAR representa uma alternativa para diminuir este problema, consistindo basicamente no processo de minimizar o conjunto de pontos, mantendo as características matemáticas e estatísticas conforme conjunto original, ou seja, a autossimilaridade entre o conjunto original e os seus derivados. Tecnicamente, isso significa que o processo de simplificação deve apresentar invariância na sua forma à medida que o Nível de Detalhamento (*Level of Detail* – LOD) é alterado, mantendo-se a sua estrutura idêntica à original, recaindo sobre o contexto de uma estrutura fractal (MANDELBROI, 1975).

O termo fractal aplica-se, em geral, a construções diversas, tanto nas ditas formas abstratas como as inerentes à natureza, e são objetos de estudo nos ramos da Matemática e Física, enquanto leis de formação e de escala. No contexto de uma nuvem de pontos LiDAR, o conjunto de pontos que a define geometricamente deve apresentar autossimilaridade matemática conforme uma estrutura fractal determinística (MANDELBROI, 1975), ou seja, as características matemáticas devem ser independentes da densidade de pontos de uma nuvem de

pontos LiDAR. Portanto, a configuração espacial de distribuição de pontos deve apresentar autossimilaridade exata, ou seja, as configurações geométricas relacionadas ao conjunto original devem se repetir nas sucessivas configurações simplificadas. O grande desafio está na definição de um limiar entre a perda das características geométricas e a minimização da redundância de uma nuvem de pontos.

Assim, essa pesquisa partiu do princípio de que uma nuvem de pontos LiDAR, independentemente do ambiente perfilado, é caracterizada por autossimilaridade, conforme as normatizações matemáticas da geometria fractal. Portanto, a partir do particionamento de uma nuvem de pontos LiDAR um operador de simplificação da generalização cartográfica 3D pode ser visto como uma réplica do todo, em um LoD inferior calculado em um procedimento recursivo, ou seja, composto por sub procedimentos que permitam calcular uma dimensão fractal que representa o grau de ocupação e autossimilaridade que uma estrutura no espaço possa conter.

Para tanto, esse Capítulo apresenta uma proposta de simplificação de nuvem de pontos LiDAR considerando os aspectos construtivos de edificações e ambientes internos. As discussões são apresentadas em 5 Seções. Primeiramente a Seção 4.1 são apresentados os trabalhos relacionados e o potencial de contribuição da estratégia proposta. Na Seção 4.2 é ilustrado o fluxo metodológico proposto, seguido pela Seção 4.3, que apresenta os resultados e discussões acerca do processo desenvolvido. Por fim, conclusões e recomendações são discriminadas na Seção 4.5.

4.1 TRABALHOS RELACIONADOS

O recente avanço nas tecnologias de aquisição de dados 3D, por exemplo os Sensores *Light Detection and Ranging* (LiDAR) Terrestres (SLT), possibilitam a aquisição de nuvem de pontos LiDAR com alta densidade por metro quadrado (m^2). Todavia, o incremento de detalhes usualmente insere custos computacionais em termos de processamento e visualização de operações. Métodos de simplificação 3D permitem reduzir a complexidade dos dados mantendo a descrição de estruturas relevantes. Isso permite minimizar problemas no processamento de nuvem de pontos LiDAR que pode se tornar impraticável em um *dataset* em larga escala. Diversos procedimentos de seleção e simplificação de nuvens de pontos LiDAR foram desenvolvidos nos últimos anos. Particularmente, existem três vias para a simplificação: A) Baseado em malhas; B) Baseado em otimização direta e; C) Baseado em amostragem, conforme descritos nos subtópicos que seguem:

A) Métodos baseados em malhas: as estratégias baseadas em malhas consistem no ajuste preliminar de uma nuvem de pontos LiDAR a uma superfície (malha), a qual passa por sucessivos processos de simplificação (GARLAND; HECKBERT, 1997). São métodos iterativos e apresentam ineficiência em perfilamentos de grandes porções e podem ser divididos em dois grupos: baseados em dizimação (GARLAND; HECKBERT, 1997; ASGHARIAN; EBRAHIMNEZHAD, 2020) ou em colapso (HOPPE et al., 1993; HINDERINK; MANDAD; CAMPEN, 2022). O primeiro remove vértices iterativamente e na sequência realiza um processo de re-triangulação, enquanto o segundo emprega abordagens baseadas na mescla das bordas existentes para estimar uma posição ótima para um vértice (ASGHARIAN; EBRAHIMNEZHAD, 2020). Independente da vertente, os métodos baseados em malhas atribuem um peso relacionado à importância de cada ponto na representação de uma superfície S com base em atributos estatísticos, como vetores normais (HINDERINK; MANDAD; CAMPEN, 2022) ou a curvatura da nuvem de pontos LiDAR (ASGHARIAN; EBRAHIMNEZHAD, 2020). Além disso, comumente se utiliza a determinação de uma função energia para extrair pontos de borda (HINDERINK; MANDAD; CAMPEN, 2022).

B) Métodos baseados em otimização direta: nesta família de algoritmos, os pontos de uma nuvem de pontos LiDAR são selecionados e simplificados consonante com suas propriedades matemáticas locais (XUAN et al., 2018; ZOU et al., 2021). O processo de simplificação baseado neste processo avalia a importância de cada ponto em uma nuvem de pontos LiDAR. Vetores normais são frequentemente aplicados e considerados a informação de base para obtenção da descrição das características geométricas locais de uma vizinhança de pontos a partir de estratégias iterativas. Contudo, embora eficientes, os algoritmos apresentam alto custo computacional quando aplicados em escalas de perfilamento maiores.

C) Métodos baseados em amostragem: consistem em um esquema de seleção de pontos cujo foco é manter a estrutura geral do objeto, e não a sua estrutura geométrica baseada na importância de representação da superfície analisada. Métodos como o *Farthest Point Sampling Histogram* (RUSU; COUSINS, 2011), *SampleNet* (LANG; MANOR; AVIDAN, 2020) e *S-net* (DOVRAT et al., 2019) podem ser classificados como métodos baseados em amostragem. O principal impasse está relacionado a não preservação dos detalhes geométricos importantes de uma nuvem de pontos LiDAR, o que pode acarretar problemas de interpretação e geração de um modelo 3D.

Independente da família de métodos empregados, a simplificação de nuvem de pontos LiDAR introduz distorções e erros na renderização de modelos 3D. O problema está na

necessidade de desenvolvimento de algoritmos que interpretem a distribuição da nuvem de pontos de forma coerente, imitando um processo de cognição humana em uma linguagem computacional. Para alcançar este objetivo, busca-se selecionar variáveis e atributos geométricos que permitam a interpretação computacional do conjunto de pontos e minimização de sua redundância. A aplicação de elementos matemáticos e estatísticos, como o cálculo de vetores normais e a curvatura dos pontos pertencentes a uma nuvem de pontos LiDAR permite a análise da autossimilaridade de um conjunto P , as quais são denominadas nesta pesquisa como métricas perceptivas.

Motivado pela necessidade de desenvolvimento de operadores de generalização 3D e pelos estudos mencionados, buscou-se o desenvolvimento de um processo híbrido para a simplificação de uma nuvem de pontos LiDAR, baseado nos aspectos da geometria fractal e métricas perceptivas de autossimilaridade. Logo, partindo-se do pressuposto de que uma nuvem de pontos LiDAR apresenta características matemáticas e estatísticas (DÖLLNER, 2020) e forma uma estrutura fractal e determinística, para alcançar uma condição de densidade de pontos mínima, uma nuvem de pontos LiDAR composta por um conjunto de pontos $P = (p_1, p_2, p_{n_1-1} \dots p_{n_1})$ que passa por um processo de simplificação isotrópico (com a mesma intensidade em todas as direções), baseado na distribuição geométrica e estatística de uma nuvem de ponto LiDAR é minimizado e transformado ao conjunto $P' = (p'_1, p'_2, p'_{n_2-1} \dots p'_{n_2})$, em que $n_2 < n_1$. Por consequência, o conjunto P é autossimilar ao conjunto simplificado P' , se P' resultar invariante após a referida transformação, será assumido como conjunto principal para modelar uma superfície S .


Neste contexto, as principais contribuições que este Capítulo busca fornecer são: 1) Emprego da autossimilaridade de uma estrutura fractal para especificar o número amostral de pontos suficientes para reconstruir uma superfície S sem necessidade de iterações; 2) Amostragem adaptativa de pontos de borda baseado no cálculo da rugosidade de pontos pertencentes a uma nuvem de pontos LiDAR em um processo isotrópico e 3) Preservação da qualidade visual e geométrica do conjunto de dados em um LoD inferior sem perda significativa de precisão.

4.2 PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO

Foram empregados dois conjuntos de dados experimentais adquiridos com um SLT no modo estático em ambientes internos, conforme ilustrado na FIGURA 20. Partiu-se do pressuposto de que uma nuvem de pontos LiDAR apresenta características matemáticas e

estatísticas (DÖLLNER, 2020) e forma uma estrutura fractal e determinística, para alcançar uma condição de densidade de pontos mínima. Assim, uma nuvem de pontos LiDAR composta por um conjunto de pontos $P = (p_1, p_2, p_{n1-1} \dots p_{n1})$ que passa por um processo de simplificação isotrópico baseado na distribuição geométrica e estatística de uma nuvem de ponto LiDAR é minimizado e transformado ao conjunto $P' = (p'_1, p'_2, p'_{n2-1} \dots p'_{n2})$, em que $n_2 < n_1$. Nesta pesquisa, consideraram-se apenas as características geométricas para a minimização dos dados e não condições topológicas.

FIGURA 20 - CONJUNTO EXPERIMENTAIS (a) CONJUNTO I (b) CONJUNTO II




FONTE: O autor (2022).

Neste processo, considera-se que um operador de simplificação de uma nuvem de pontos LiDAR pode ser obtido a partir do particionamento do conjunto original em subconjuntos com o estabelecimento de restrições e análise da autossimilaridade da vizinhança de pontos. O objetivo é a redução de ruídos e a redundância da nuvem de pontos LiDAR preservando características de borda e uniformidade da densidade total do conjunto. A estratégia empregada busca otimizar algoritmos em um *framework* para o desenvolvimento de uma estratégia de simplificação de nuvens de pontos LiDAR no contexto da generalização cartográfica 3D, baseado na autossimilaridade estatística dos dados e cálculo da importância de cada ponto pertencente a nuvem como métrica de simplificação.

O fluxo metodológico empregado (FIGURA 21) é subdividido em quatro tarefas. A primeira consiste no processo de amostragem e estruturação de uma nuvem de pontos LiDAR para solucionar o primeiro problema: a distribuição aleatória. Para isto, aplicou-se uma estrutura octree (RUSU; COUSINS, 2011) que fornece efetivamente uma representação e estruturação para dados 3D. Optou-se por empregar uma octree como estrutura de dados de base devido a

sua eficiência na serialização. Posteriormente, aplica-se o processo de estimativa da curvatura dos pontos e da rugosidade de uma vizinhança para a extração de pontos de borda pela análise da autossimilaridade (Subseção 4.2.1) (PAULY; GROSS; KOBELT, 2002) e então o algoritmo desenvolvido por Rusu e Cousins (2011), *Statistical Outliers Remove* (SOR), é aplicado para a eliminação de pontos espúrios nos conjuntos gerados. Posteriormente na tarefa 3, o processo de voxelização, baseado em Lv, Lin e Zhao (2021) uniforme é empregado (Subseção 4.2.2), para simplificação dos pontos classificados como intermediários

FIGURA 21 - FLUXOGRAMA DE APLICAÇÃO



FONTE: O autor (2022).

Por fim, o algoritmo *Iterative Closest Point* (ICP) (BESL; MCKAY; 1992) é aplicado para registrar os conjuntos gerados em um mesmo sistema de coordenadas local.

4.2.1 Extração de pontos de borda a partir de métrica perceptiva de rugosidade

A extração e simplificação de bordas pertencentes às estruturas perfiladas foi baseada em métricas matemáticas locais de autossimilaridade, a partir da análise da curvatura dos pontos pertencentes à nuvem de pontos LiDAR, conforme proposto por Pauly, Gross e Kobbelt (2002). Segundo Hoppe et al. (1993), uma matriz de variância e covariância é um método intuitivo para a determinação da curvatura e de vetores normais de uma nuvem de pontos LiDAR. Logo, considerando uma vizinhança N_i em torno de um ponto $p_i \in R^3$, pode-se definir a matriz de covariância apresentada na EQUAÇÃO 9.


$$C = [p_{i1} - p_1 \ p_{i2} - p_1 \ : \ p_{ik} - p_1]^T \cdot [p_{i1} - p_1 \ p_{i2} - p_1 \ : \ p_{ik} - p_1] \in R^{|N_i| \times |N_i|} \quad (9)$$

A partir da autodecomposição de C , pode-se derivar os autovalores $(\lambda_0, \lambda_1, \lambda_2)$ correspondentes por componentes principais para definição de uma referência ortogonal no ponto p_i . Conforme Hoppe et al. (1993), os autovalores com maior valor abrangem um plano tangente no ponto p_i , enquanto aqueles de menor valor são empregados para aproximar a superfície normal n_i . Logo, dado o menor autovalor relacionado a p_i de uma superfície, pode-se estimar os valores de curvatura (k) de p_i (PAULY et al., 2002), conforme EQUAÇÃO 10.

$$k(p_i) = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2} \quad \lambda_0 < \lambda_1 < \lambda_2 \quad (10)$$

Assumindo que $\lambda_0 < \lambda_1 < \lambda_2$ são os autovalores de uma vizinhança local de p_i e v_0, v_1, v_2 correspondem aos vetores normais que definem um plano $T(x) = (x - p_i)v_0 = 0$, prioriza-se a soma das distâncias quadradas para os vizinhos de p_i , conforme FIGURA 22.

FIGURA 22 - DETERMINAÇÃO DA CURVATURA DE UM PONTO



FONTE: O autor (2022).

A estimação da curvatura local de p_i é a variável matemática ideal para analisar a autossimilaridade geométrica e minimização da redundância de um conjunto de pontos. Portanto, empregando a estimativa inicial da curvatura de um ponto p_i , é possível estimar a média ponderada gaussiana das curvaturas ao redor de uma vizinhança (EQUAÇÃO 11) (AN et al., 2021).


$$\hat{k}(p_i) = \frac{\sum_{j \in N_i} k(p_j) \exp\left(-\frac{\|p_j - p_i\|^2}{h}\right)}{\sum_{j \in N_i} \exp\left(-\frac{\|p_j - p_i\|^2}{h}\right)} \quad (11)$$

Em que h é o raio de busca de uma vizinhança de p_i . A estimativa de rugosidade de uma nuvem de pontos LiDAR, pode ser definida como a diferença entre a curvatura (k) e a curvatura média ($\hat{k}$) no ponto p_i (RODRÍGUEZ-CUENCA et al., 2015). A rugosidade de cada ponto é representada por um operador simples calculado pela variação da superfície perfilada. Entretanto, para fins de simplificação, o resultado de saída (segmentação de pontos em borda e intermediários) ainda não é completamente uniforme e contém ruídos que podem ser minimizados. A solução é reamostrar os dados empregando um operador de simplificação e remoção de ruídos, conforme apresentado na Subseção que segue.

4.2.2 Simplificação baseada em voxelização

Após a extração dos pontos que permitem a identificação de bordas dos objetos perfilados, a nuvem de pontos LiDAR original é subdividida em pontos de borda e pontos intermediários. Observa-se que empregar apenas os pontos pertencentes às bordas pode inserir erros nos processos de definição de representações 3D. Portanto, os pontos classificados como intermediários devem ser associados e empregados ao conjunto anteriormente mencionado. Entretanto, é necessário simplificá-lo uniformemente sobre a superfície S . Para este processo, adaptou-se o método desenvolvido por Lv, Lin e Zhao (2021). A estratégia desta etapa é subdividir a nuvem de pontos LiDAR em estruturas de voxels, conforme ilustrado na FIGURA 23.

FIGURA 23 – VOXELIZAÇÃO (a) ORIGINAL (b) GRADE 3D (VOXEL)



FONTE: O autor (2022).

Um voxel é uma geometria no espaço 3D e corresponde aos pixels no contexto 2D. Do ponto de vista conceitual, um voxel possui geometria cúbica, composta por seis faces, oito vértices e doze arestas, apesar disso, a representação não é feita conforme um cubo poliédrico, mas a partir de um ponto central ou pelos pontos que representam seus vértices (XU; TONG; STILLA, 2021). Logo, no contexto da simplificação, um voxel é considerado uma unidade

básica, representando uma posição em uma grade cúbica regular. Nesta perspectiva, a nuvem de pontos LiDAR classificada como intermediária é subdividida por voxel.


O algoritmo implementado é executado em três etapas: 1) Cálculo de um retângulo envolvente para a nuvem de pontos LiDAR que define o espaço a ser segmentado; 2) O espaço definido na primeira etapa é subdividido em cuboides 3D regularmente espaçados e com tamanho pré-determinado (geralmente definidos pelo executor), que se tornam as células da estrutura do voxel e; 3) A nuvem de pontos LiDAR é segmentada em pequenas porções a partir dos cuboides, e finalmente o conjunto de pontos subdividido é representado por voxels, em que a posição e as características destes pontos são calculadas em decorrência da análise do conjunto extraído em cada parcela. Então, a partir de um conjunto de pontos $P = (p_1, p_2, p_{n1-1} \dots p_{n1})$ em que n são o número de pontos dentro de um voxel V_k , e k o índice do voxel no espaço voxelizado $V = \{V_1, V_2, \dots V_m\}$, sendo m o número de todos os voxels gerados.

A partir desta tarefa, os pontos de borda e a nuvem de pontos LiDAR intermediária são registradas empregando o algoritmo *ICP* para a formação de uma nuvem generalizada e pronta para servir de base para a construção de modelos 3D.

4.3 RESULTADOS E DISCUSSÕES

Para avaliar a eficácia e o desempenho da abordagem proposta, foram utilizados dois experimentos de validação a partir de dados adquiridos com o SLT de ambientes internos. A plataforma de processamento de dados foi um computador Laptop, Windows 10 com processador de 1,8 GHz e 8 GB de memória RAM. A linguagem de programação Python 3.0 e bibliotecas como a *open3D Library* (ZHOU; PARK; KOLTUN, 2018) e *Point Cloud Library* (PCL) (RUSU; COUSINS, 2011) foram empregadas. Como primeiro passo, optou-se pela organização dos conjuntos de dados em forma de octree (FIGURA 24).

FIGURA 24 – ESTRUTURAÇÃO OCTREE (a) CONJUNTO I (b) CONJUNTO II




Fonte: O autor (2022).

A estrutura Octree é uma forma eficiente de organização de dados, em que uma nuvem de pontos LiDAR é subdividida em nós (representado por um cubo). Cada nó inclui oito nós secundários (exceto o nó folha, primário). O espaço total é dividido em $2^n \times 2^n \times 2^n$ (RUSU; COUSINS, 2011), neste caso a nuvem é decomposta recursivamente (um nó em outros oito subnós). Esta estratégia é aplicada principalmente para estruturação da nuvem de pontos LiDAR e minimização de custo computacional para as futuras etapas de processamento. Com os conjuntos experimentais estruturados, iniciou-se o processo de determinação da rugosidade dos pontos que formam a nuvem de pontos LiDAR. A partir desta componente geométrica, iniciou-se o processo de análise de autossimilaridade da rugosidade relacionada aos pontos que compõem um conjunto amostral, conforme Subseção que segue:

4.3.1 Determinação de pontos de borda e intermediários

A extração de pontos pertencentes a bordas das edificações foi realizada a partir da análise da rugosidade dos pontos. A FIGURA 25 ilustra a quantidade de pontos em ambos os conjuntos experimentais aos valores de rugosidade correspondentes. Nesta pesquisa, o limiar relacionado ao valor de rugosidade foi de 0,01. Este valor foi definido a partir de testes de plotagem, sendo o valor coerente encontrado para bordas de edificações.




FONTE: O autor (2022).

Os pontos com rugosidade $> 0,01$ foram classificados como pontos de borda (coloração verde –). Já aqueles com valores $< 0,01$ foram categorizados como intermediários (coloração azul – FIGURA 26). A análise da autossimilaridade do parâmetro geométrico de rugosidade demonstrou ser eficiente, e permitiu extrair pontos de borda. Entretanto, ambos os conjuntos gerados, tanto o de pontos de bordas quanto os intermediários, apresentaram pontos

espúrios que inserem erros no processo de modelagem geométrica de uma superfície. Para eliminá-los e reduzir a redundância das nuvens de pontos LiDAR de teste, aplicou-se o algoritmo SRO. Este algoritmo, permite eliminar dados ruidosos que compõem a amostra, eliminando elementos que não contribuem efetivamente no processo de construção de um modelo 3D.


FIGURA 26 – VALORES DE RUGOSIDADE (a) CONJUNTO I (b) CONJUNTO II



FONTE: O autor (2022).

O perfilamento de ambientes internos apresentou alta complexidade devido à presença de superfícies reflexivas, translúcidas (como os vidros) e áreas oclusas. Neste contexto, na concepção de construção de um modelo 3D, a etapa de remoção de pontos espúrios é relevante para a minimização de erros no processo de interpretação semântica e geométrica de uma nuvem de pontos LiDAR. Na FIGURA 27 é ilustrado o resultado encontrado no processo. Os pontos em vermelho foram classificados como espúrios e eliminados da amostra, enquanto os demais foram considerados como remanescentes, minimizando o número de pontos em 10%.

FIGURA 27– VALORES DE RUGOSIDADE (a) CONJUNTO I (b) CONJUNTO II




FONTE: O autor (2022).

4.3.2 Simplificação baseada em voxel

O processo de simplificação baseado na voxelização da nuvem de pontos LiDAR foi aplicado apenas nos pontos classificados como intermediários, uma vez que apresentam o maior número de pontos que compunham a amostra e são importantes no contexto da modelagem 3D de ambientes construídos. Um dos principais problemas da aplicação de processos de simplificação de nuvem de pontos LiDAR é a definição de um limiar específico para a redução do número de pontos que minimize o custo computacional e mantenha as propriedades geométricas mínimas (representação explícita da posição e a topologia de uma vizinhança de pontos) armazenadas em estruturas 3D abstratas contendo posições e atributos pré-definidos para que algoritmos de modelagem possam ser explorados de forma adequada (XU; TONG; STILLA, 2021).

Devido a este fato, optou-se pela realização de três testes específicos para os conjuntos amostrais, considerando tamanhos de voxels de 0,01, 0,02 e 0,05 m. Os resultados são apresentados na FIGURA 28. Observa-se que quanto maior o valor do voxel associado, menor o número de pontos remanescentes. Não obstante, a minimização demasiada acarreta erros. Entretanto, as representações baseadas em voxel são vantajosas e eficientes no processo de compactação de dados.



FONTE: O autor (2022).


O objetivo com a variação dos voxels é encontrar um valor ótimo de sugestão para aplicação na simplificação considerando a integração do conjunto voxelizado com pontos categorizados como bordas na etapa anterior (TABELA 1).

TABELA 1 - NÚMERO DE PONTOS REMANESCENTE NO CONJUNTO INTERMEDIÁRIO

Experimentos	Número de pontos			
	Original (Intermediários)	Voxel 0,01 m	Voxel 0,03 m	Voxel 0,05 m
Conjunto I	4.305.738	1.214.465	192.063	76.504
Conjunto II	2.891.867	1.033.032	135.193	53.588

FONTE: O autor (2022).

Segundo Xu; Tong; Stilla (2021), as técnicas de voxels tem alto potencial de sucesso para minimizar custo computacional e devido a sua estruturação 3D sua aplicação é ideal para tarefas de monitoramento, planejamento e navegação em ambientes construídos. Ademais, interessantes de aplicação na reconstrução de modelos 3D, em particular para análise estrutural e simulações no contexto do *CityGML* (BILJECK et al., 2016) e do BIM (NIKOOHEMAT et al., 2020). Para a composição da nuvem de pontos LiDAR final, realizou-se o processo de registro com o emprego de uma variação do algoritmo ICP entre os pontos de borda e os intermediários voxelizados, conforme FIGURA 29.



FONTE: O autor (2022).

As nuvens de pontos LiDAR geradas foram caracterizadas por pontos concentrados nas bordas das edificações, enquanto em superfícies planas (não rugosas) os pontos ficaram esparsos, conforme o tamanho do voxel empregado. Os números de pontos remanescentes são

apresentados na TABELA 2. O conjunto original consiste na nuvem de pontos LiDAR após aplicação do processo de estruturação *octree*.


TABELA 2 - NÚMERO DE PONTOS – NUENS FINAIS

Experimentos	Número de pontos			
	Original	Voxel 0,01 m	Voxel 0,03 m	Voxel 0,05 m
Conjunto I	6.068.202	1.224.175	221.773	106.224
Conjunto II	4.982.096	1.083.476	186.359	104.032


FONTE: O autor (2022).

A comparação gráfica é apresentada na FIGURA 30. O acréscimo dos pontos de borda no conjunto de dados voxelizados ocasionou em média um acréscimo de 23% no número de pontos, considerando as três configurações testadas. Apesar do acréscimo de 23%, observa-se que em ambos os experimentos houve uma redução de 80, 96 e 98%, respectivamente, para voxels com dimensões de 0,01, 0,03 e 0,05 m.

FIGURA 30 – PROCESSO DE SIMPLIFICAÇÃO (a) NP INTERMEDIÁRIA (b) NP FINAL



(a)



(b)

FONTE: O autor (2022).

Neste caso, para a simplificação de uma nuvem de pontos LiDAR proveniente de perfilamento de construções verificou-se a partir dos experimentos que a adoção do voxel 0,01 m apresenta as taxas de simplificação adequadas, uma vez que uma simplificação em torno de 80% é suficiente para permitir um processamento com menor custo computacional e de armazenamento, permitindo que 20% dos pontos da nuvem original permaneçam para as etapas futuras (considerando a aplicação do fluxo metodológico proposto).

Com os dados empregados nos experimentos, os voxels com dimensões de 0,03 e 0,05 m simplificaram expressivamente os conjuntos originais, remanescendo menos de 5%. Isso pode acarretar erros de interpretação por algoritmos computacionais em etapas de concepção de modelos 3D. Para testar a eficiência da proposta, realizou-se a comparação com outros dois métodos empregados frequentemente para simplificar nuvem de pontos LiDAR.

4.3.3 Método Proposto *Versus* Outros Métodos De Simplificação

Para analisar os experimentos, comparou-se os resultados obtidos com a metodologia proposta com 2 métodos empregados para simplificar e minimizar a quantidade de pontos pertencentes a uma nuvem. A abordagem proposta busca armazenar uma saída comprimida com base na análise de valores de rugosidade dos pontos pertencentes a uma nuvem de pontos LiDAR, mantendo aspectos de borda como característica essencial ao processo, ou seja, armazena-se um conjunto de pontos que representa coerentemente as mudanças de perspectivas de um ambiente minimizando o número de pontos e em consequência o custo computacional de processamento.

Neste caso, comparou-se apenas os resultados obtidos com o voxel considerado ideal (dimensão de 0,01 m) com algoritmos regularmente utilizados. Empregaram-se os métodos *Poisson Sample Disk* (PSD) e o denominado de *Random Sample* (RS), ambos implementados, respectivamente, no MeshLab e no CloudCompare. A vantagem do método proposto é a manutenção dos pontos de borda de forma automática. Enquanto os demais processos minimizam a nuvem de pontos LiDAR sem a consideração que as mudanças de angulações e perspectivas podem inserir erros de estimativas e de representações na confecção de modelos 3D.

O teste de comparação de métodos de simplificação indicou que para ambos os conjuntos experimentais, o tamanho do arquivo armazenado e gerado foi maior que os demais produzidos pela aplicação dos algoritmos testados. Além disso, a qualidade geométrica de representação 3D da nuvem de pontos LiDAR gerada com o método proposto foi superior.

Dentre os algoritmos testados, o RS apresentou limitações acentuadas, pois não permitem realizar uma análise para a definição de pontos remanescentes. O processo é baseado somente na análise das distâncias entre os pontos, permanecendo somente um ponto em decorrência de uma distância previamente estabelecida pelo analista.

Matematicamente, os resultados foram comparados com a partir da definição da razão de simplificação ε . Neste caso, $\varepsilon = \frac{P-P'}{P} * 100\%$, em que P são o número de pontos da nuvem de ponto original e P' dos conjuntos simplificados, conforme listado na TABELA 3.

O método PSD permite a amostragem de pontos baseada no princípio da proximidade a partir da definição do raio do disco de Poisson (parâmetro de entrada definido pelo usuário), definido como a meia distância entre duas amostras mais próximas. Em comparação com o algoritmo RS, o PSD apresenta uma distribuição mais uniforme sobre o domínio de amostragem (HOU et al., 2013), entretanto não apresenta a análise de pontos característicos como os de borda. A estratégia RS permite a minimização do conjunto de pontos de forma aleatória. Ou seja, a partir da nuvem de pontos LiDAR original o algoritmo minimiza o conjunto para uma quantidade de pontos pré-estabelecida. A posição de cada ponto não segue regras específicas, mas aspectos aleatórios de distribuição. Para superfícies planas e com pouca variabilidade geométrica o método pode ser aplicado e será eficiente. Entretanto, os pontos considerados como importantes no processo de modelagem poderão ser excluídos do conjunto amostral.

TABELA 3 - RAZÃO DE SIMPLIFICAÇÃO

Experimentos	Razão de simplificação		
	Proposta (Voxel 0,01 m)	PSD	RS
Conjunto I	78%	98%	96%
Conjunto II	80%	99%	95%

FONTE: O autor (2022).

O método proposto é eficaz na preservação de parâmetros geométricos essenciais, enquanto os demais processos possibilitam a simplificação de forma não uniforme e há a inserção de regiões com pontos ausentes, o que insere erros em estimativas futuras. Em perfilamentos de ambientes reais, o método mantém as principais características de borda, essenciais para o processo de definição de geometrias automaticamente.

Apesar da razão de simplificação ser em média de 18% menor que os algoritmos comparados para ambos os conjuntos experimentais, houve uma taxa de simplificação que permite garantir que o conjunto P' derivado apresente autossimilaridade geométrica adequada ao conjunto original P . Destaca-se que os testes foram realizados com configurações padrões

dos softwares e parâmetros podem ser modificados para encontrar uma taxa de simplificação menor, porém pontos característicos, como os de bordas, não serão preservados.

Embora o processo de voxelização exija uma parametrização manual do tamanho mínimo do voxel, integrar pontos de borda a nuvem de pontos voxelizada permite obter informações geométricas das estruturas perfiladas, o que insere vantagens em comparação com as demais abordagens testadas. A princípio, a principal limitação da aplicação do voxel como estratégia de simplificação é a inserção manual de seu tamanho, que pode ocasionar uma perda significativa de informações geométricas importantes para processos de modelagem geométrica de nuvens de pontos LiDAR. A associação da nuvem voxelizada e pontos de borda permite minimizar esta problemática.

A vantagem do procedimento é a consideração da autossimilaridade dos valores de rugosidade dos pontos pertencentes a uma nuvem de pontos LiDAR, pois permite determinar a importância dos pontos para representar uma determinada estrutura. Conforme Ji et al. (2019), normalmente os métodos de simplificação sacrificam a precisão do conjunto de dados para aprimorar a velocidade de processamento. Um equilíbrio adequado entre velocidade e precisão deve ser mantido para minimizar erros em etapas futuras. Estes fatores levantados por Ji et al. (2019) corroboram os pressupostos defendidos nesta pesquisa, uma vez que a partir da determinação das características estatísticas do conjunto de pontos tem-se a formação de uma estrutura fractal determinística e autossimilaridade estatística de distribuição de pontos, a qual permite alcançar uma condição de densidade mínima em um processo de simplificação isotrópico (voxelização) para gerar um subconjunto simplificado que mantenha as características geométricas essenciais do conjunto original.

4.2 CONCLUSÕES DO CAPÍTULO

O emprego do processo de *voxelização* apresentou resultados satisfatórios, mas devido à determinação do tamanho do voxel ser definido de forma manual a nuvem de pontos LiDAR pode ser simplificada de forma demasiada e perder características essenciais. A análise primária dos pontos de borda permitiu minimizar este problema, proporcionando um conjunto menos ruidoso, uniforme e auto similar ao conjunto original. Logo, a partir das análises realizadas pressupõem que para alcançar uma densidade mínima de pontos para modelar tridimensionalmente um ambiente, deve-se analisar características de autossimilaridade geométrica de uma nuvem de pontos LiDAR para produzir um conjunto simplificado autosemelhante ao original, considerando as premissas da geometria fractal. Apesar de

apresentar resultados satisfatórios operadores de generalização 3D baseados em AM e princípio da HN minimizam a subjetividade do processo, conforme discutido no Capítulo 5.

CAPÍTULO 5 – SIMPLIFICAÇÃO BASEADO NA HN

Como mencionado nos Capítulos anteriores uma nuvem de pontos LiDAR bruta é o principal elo entre o mundo real e o virtual (POUX, 2019; DÖLLNER, 2020) e forma um BDG primário que será empregado como base geométrica para a compilação de representações 3D, usualmente empregadas em aplicações como o SIG 3D (BILJECKI; et al., 2016), BIM (NIKOOHEMAT et al., 2020) e na construção de *Digital Twins* (DÖLLNER, 2020; XUE et al., 2020).

Apesar de uma nuvem de pontos LiDAR formar um conjunto de dados de base para o contexto 3D, o seu processamento apresenta desafios que ainda devem ser superados (POUX, 2019; XU; STILLA, 2020; DÖLLNER, 2020). Uma nuvem de pontos LiDAR é um conjunto simples e não ordenado de pontos dotados de coordenadas 3D (x, y, z) associadas a atributos (a depender do sensor empregado), que não apresentam aspectos de conectividade, topologia ou semântica e são dados massivos que consomem memória de processamento e armazenamento computacional (POUX, 2019; DÖLLNER, 2020). Essas características inserem dificuldades no fluxo básico de processamento, que compõem as tarefas necessárias para transformar dados puramente geométricos em modelos estruturados com informações topológicas e semânticas (XU; STILLA, 2020).

Como discutido no Capítulo 4, as estratégias de generalização comumente empregadas sobre as nuvens de pontos LiDAR são caracterizadas como um processo de simplificação (*simplification*, também denominado de *downsampling*) em que se busca a minimização da densidade de pontos com o foco na detecção, descrição estatística, vetorização e visualização de recursos do espaço analisado, reduzindo consumo de memória computacional e armazenamento físico a partir da eliminação de dados redundantes. As estratégias podem ser subdivididas em 3 grupos: baseada em malhas (HINDERINK; MANDAD; CAMPEN, 2022), em otimização direta (XUAN et al., 2018; ZOU et al., 2021) e em amostragem (DOVRAT, et al., 2019; LANG; MANOR; AVIDAN, 2020).

A generalização 3D baseada em malhas se apresenta como uma estratégia multiescala. Tecnicamente, os requisitos para essa família de métodos são: um banco de dados com representações múltiplas e funcionalidades para selecionar um LoD para uma aplicação em específico (UYAR; ULUGTEKIN, 2017). A maioria das estratégias, neste caso, concentram-se sobre processos de simplificação geométrica (HINDERINK; MANDAD; CAMPEN, 2022) em edificações simples e isoladas (KADA, 2011). São métodos iterativos e apresentam ineficiência em perfilamentos de grandes porções. As técnicas de amostragem constituem-se na

minimização do número de pontos sem considerar aspectos geométricos específicos da estrutura perfilada, fatores que podem desconfigurar geometricamente o conjunto de dados.

As estratégias baseadas em otimização direta abrangem basicamente aspectos estatísticos e matemáticos extraídos diretamente de uma nuvem de pontos LiDAR (XUAN et al., 2018; ERVAN; TEMELTAŞ, 2019; ZOU et al., 2021). Frequentemente é empregado processo de decomposição do conjunto de dados a partir de sua estruturação, como a aplicação de *Kd-trees* (HUBO et al., 2006) e *octrees* que possibilita o particionamento da nuvem de pontos LiDAR por subdivisões recursivas (HUANG et al., 2020). Outros processos, baseiam-se na adoção dos voxels, elementos de volume com representação tridimensional. Ambas as possibilidades empregam uma representação de dados hierárquica, entretanto, discretizar uma nuvem de pontos LiDAR de uma grande área perfilada incorre no aumento do custo computacional. Nestes casos, podem ser empregados estruturas denominadas de *Octomaps*, reduzindo requisitos de memória (HORNUNG et al., 2013).

O problema central nestas estratégias é a necessidade da aplicação de métodos que permitam selecionar feições, classificá-las e, na sequência, definir suas relações espaciais simplificando-as quando possível para a minimização de custo computacional e de armazenamento, recaindo sobre um processo de generalização cartográfica 3D de nuvem de pontos LiDAR. O ideal é desenvolver um método que seja capaz de lidar com os obstáculos relacionados a uma nuvem de pontos LiDAR, como presença de ruídos, áreas oclusas e a massividade do conjunto de dados. Ademais, métodos de simplificação frequentemente empregados dependem da adoção de parâmetros por parte do operador humano, o que gera erros relacionados a subjetividade do processo (XUAN et al., 2018; ERVAN; TEMELTAŞ, 2019).

Estas problemáticas podem ser minimizadas a partir das afirmativas levantadas por Döllner (2020) que considera que um conjunto de pontos 3D forma um corpus (conceito proveniente da LN) geoespacial 3D e apresenta repetibilidade estatística e geométrica, o que possibilita significar ambientes geoespacializados a partir da segmentação e extração de informações para gerar conhecimento automatizado. Logo, se uma nuvem de pontos LiDAR apresenta repetibilidade estatística e matemática, então, este conjunto de dados pode ser explorado por algoritmos computacionais que consigam analisá-lo para aprender e interpretar automaticamente o conjunto de dados, encaixando-se nos requisitos para aplicações de técnicas de AM.

Nos últimos anos, métodos baseados em AM (BELLO et al., 2020) foram propostos para processamento de nuvem de pontos LiDAR inspirados em aplicações pioneiras como o

PointNet (QI et al., 2017a) e o PointNet++ (QI; YI; et al., 2017b). No contexto da simplificação, algoritmos AM são técnicas interessantes para a minimização da redundância do conjunto de pontos e, em consequência, aprimorar o desempenho de processamento do conjunto. A principal vantagem está associada a HN, em que se analisa variáveis perceptivas matemáticas (parâmetros estatísticos e geométricos de distribuição de pontos pertencentes ao conjunto) sem a necessidade de inserção de parâmetros manuais e ainda resguardando características geométricas essenciais da geometria perfilada. Nesta perspectiva, objetiva-se neste Capítulo apresentar uma variação DL para produzir nuvem de pontos LiDAR uniformes e esparsas, minimizando custo de armazenamento e processamento para etapas futuras, entretanto, mantendo a autossimilaridade de uma nuvem simplificada com a estrutura originalmente mapeada.


As discussões são apresentadas em 4 Seções. Na Seção 5.1, descreve-se o fluxo metodológico e conjunto de dados empregados. Na Seção 5.2, apresenta-se os resultados e discussões. Na Seção 5.3, compara-se os resultados obtidos com a implementação proposta e métodos de simplificação usualmente empregados. Na Seção 5.4, são descritas as conclusões e recomendações futuras.

5.1 PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO

Para testar o processo proposto neste Capítulo foram empregados seis conjuntos de dados do repositório *Stanford Large-Scale 3D Indoor Dataset* (ARMENI et al., 2016). Compreendem nuvem de pontos LiDAR adquiridas em ambientes internos de uma edificação escolar, compostas por estruturas construtivas e mobiliário (FIGURA 31). O algoritmo foi desenvolvido em linguagem de programação Python 3.0, empregando bibliotecas computacionais *open-source* (Open3D, TensorFlow e Pythorch3D) e o ambiente de desenvolvimento *Google Colaboratory*.

Na generalização cartográfica 3D de nuvem de pontos LiDAR o primeiro passo consiste na definição dos operadores de generalização que dependerão do espaço a ser mapeado (domínio da aplicação). Independentemente do domínio, é necessário selecionar pontos relevantes (eliminação de pontos espúrios e ruídos) e posteriormente aplicar operadores de simplificação, minimizando redundância. A principal tarefa neste processo é equilibrar duas questões: 1) Preservar as características geométricas e estatísticas de uma nuvem de pontos LiDAR conforme dado original e; 2) Otimizar tarefas subsequentes com menor densidade de pontos.


FIGURA 31 – CONJUNTOS EXPERIMENTAIS



FONTE: O autor (2022)

Para isto, baseou-se em Wang et al. (2021) e Choy et al. (2019) a partir da adoção de uma estrutura AM para simplificar uma nuvem de pontos LiDAR de forma eficiente. Introduz-se, então, um processo multiescala de representação hierárquica por meio de reamostragem aprendida a partir da aplicação de uma Rede Neural Convolutucional (RNC) do tipo *autoencoder* baseada em convolução esparsa (FIGURA 32).

FIGURA 32 – FLUXO DEEP LEARNING DE SIMPLIFICAÇÃO



FONTE: O autor (2022).

A ideia é produzir a partir de uma RNC na camada de saída uma nuvem de pontos LiDAR simplificada com as mesmas características geométricas do conjunto de dados que alimenta a rede (entrada), no entanto, inserem-se restrições nas camadas intermediárias para que a saída não seja simplesmente uma cópia dos valores de entrada. A restrição mais comum

é limitar o número de unidades nas camadas ocultas intermediárias, criando um ponto de conexão denominado de gargalo, no qual dois blocos de camadas são conectados, um denominado de *encoder* (codificação) e o outro decoder (decodificação) em uma estrutura denominada de *autenconder*.

Essa estrutura, baseada em voxels, permite que o algoritmo interprete as características geométricas de uma nuvem de pontos LiDAR. Logo, a partir de um conjunto de coordenadas tridimensionais e seus atributos matemáticos F (vetores normais e distância entre os pontos), indica-se a ocupação de cada camada pertencente à rede. Assim, ao inserir uma nuvem de ponto C em um tensor esperso $\{C_x, F_x\}$, em que F_x indica a ocupação da camada baseadas em *voxels*, realiza-se progressivamente a simplificação de C em múltiplas escalas ($C_x', C_x'' \dots C_x'''$) - *Downscale* - para implicitamente a RNC aprender e incorporar estruturas locais de F .

O processo de decomposição consiste em um espelho das camadas da codificação para gerar e reconstruir um conjunto de pontos em escalas progressivas a partir de um processo denominado de convolução transposta (CHOY et al., 2019) para minimizar hierarquicamente a quantidade de pontos pertencente a uma nuvem de pontos LiDAR. Especificamente, a reconstrução de uma escala inferior será progressivamente aumentada ($\hat{C}_x''', \hat{C}_x'' \dots \hat{C}_x'$) a partir de atributos decodificados que permitam o refinamento da geometria analisada. A aplicação de camadas de convolução esparsas permitem estimar a probabilidade de um *voxel* ser ocupado após consecutivas convoluções a partir de uma função de perda L , conforme EQUAÇÃO 12 (WANG et al., 2021).

$$L = \frac{1}{N} \sum_i^N -(x_i \log(p_i) + (1 + x_i) \log(1 - p_i)) \quad (12)$$

Em que x_i são os voxels ocupados por pelo menos um ponto (igual a 1) ou vazio (igual a 0) e p_i a probabilidade de existência de um voxel ocupado por pelo menos um ponto, ativada por uma função sigmoide. Neste processo são extraídos os voxels com maior probabilidade de ocupação e então a densidade da nuvem de pontos LiDAR é ajustada e reconstruída conforme aprendizado da RNC. A partir da aprendizagem, a informação interna é compactada e contém informações suficientes para posteriormente restauração dos dados com um mínimo de perda possível (decodificação), uma tarefa atribuída ao decoder (*upscale*). Para cada ponto (c_i, f_i) pertencente a C em I camadas intermediárias o algoritmo encontra K novos pontos que compõem uma vizinhança $\{(c_i^k, f_i^k), k \in \{0, \dots, I - 1\}\}$ dentro de um raio r .


Sabendo-se que $c_i^k = c_i + r \cdot \Delta_k(f_i)$ e $f_i^k = \phi_k(f_i)$, em que Δ_k indica um bloco de multicamadas ocultas de ativação responsáveis por definir filtros de aprendizado de um conjunto de pontos. A função $\phi_k: R^{entrada} \rightarrow R^{saída}$ é responsável por estimar novas classificações com base nos resultados de saída da estrutura enconder, esta tarefa consiste no aumento da densidade dos pontos a partir da análise de I .

A RNC aplicada é pré-treinada a partir do Dataset ShapeNet (<https://shapenet.org/>) que contém um conjunto de dados com cerca de 51.300 modelos 3D reamostrados e processados para a geração de nuvem de pontos LiDAR de treinamento.

5.2 RESULTADOS E DISCUSSÕES

A partir da aplicação da estratégia de simplificação, produziram-se novos conjuntos de dados que preservam as características gerais dos objetos originalmente perfilados. Observa-se, na FIGURA 33, que o objetivo deste Capítulo foi alcançado, transformando uma nuvem de pontos LiDAR densa e esparsa, preservando recursos e características geométricas importantes. A partir disto, minimiza-se o custo computacional de etapas subsequentes do processamento, como por exemplo, a atribuição de semântica de um agrupamento. Entretanto, caso a nuvem de pontos LiDAR seja demasiadamente simplificada, processos automáticos posteriores poderão ser prejudicados.

FIGURA 33 – EXPERIMENTOS: DADOS SIMPLIFICADOS



FONTE: O autor (2022).

Em ambientes complexos, como o interior de edificações, este processo é crítico devido à existência de áreas oclusas e objetos de diferentes dimensões que poderão ser simplificados de forma errônea, sendo necessário a adoção de critérios para manutenção de pontos importantes em todas as estruturas presentes na cena perfilada. Estes fatores não foram abordados neste trabalho, sendo adequado apenas quando aplicado em contextos que se visa minimizar o número de pontos que compõem uma nuvem de pontos LiDAR para modelar subespaços internos (espaços limitados horizontal e verticalmente por elementos estruturais).

A discussão da qualidade dos resultados encontrados é discutida na Subseção 5.3.

5.3 MÉTODO PROPOSTO *VERSUS* OUTROS MÉTODOS DE SIMPLIFICAÇÃO

A TABELA 4 lista as taxas de simplificação dos três algoritmos de simplificação aplicados sobre os conjuntos de dados experimentais. Tanto o processo testado, quando os algoritmos tradicionais alcançam altas taxas de simplificação, no entanto, nenhum deles apresenta a manutenção de pontos característico para a representação da geometria original dos dados em LoD inferiores. Essa característica é a principal desvantagem do método proposto.

TABELA 4 - Nº DE PONTOS REMANESCENTES

Experimentos	Número de pontos			
	Original	Método	PSD	Octree
Conjunto I	1.535.040	39.702	31.006	19.273
Conjunto II	592.832	15.672	26.951	17.958
Conjunto III	1.266.990	20.413	26.918	14.757
Conjunto IV	1.049.844	27.331	25.869	8.796
Conjunto V	1.507.439	38.833	30.988	17.249
Conjunto V	307.058	7.926	22.112	9.854


FONTE: O autor (2022)

Nos seis experimentos, comparou-se a performance da estratégia AM com métodos tradicionais implementados em softwares gratuitos. A proposta apresentou uma razão de simplificação de 97%, armazenando uma saída codificada a partir da análise de vetores normais do conjunto de pontos original, com densidade mínima. O método PSD e baseado na estrutura Octree obtiveram, respectivamente, razão de simplificação média de 96% e 98%. Em ambos, a simplificação ocorreu de forma empírica devido à inserção de parâmetros iniciais sem uma prévia análise, uma vez que o emprego de valores idênticos produziu resultados diversos em decorrência das características dos dados originais.

Na FIGURA 34 é ilustrada a taxa de simplificação de cada método em relação ao conjunto de dados experimental. Nos conjuntos I, III e V a estratégia AM teve uma taxa de simplificação menor que os demais métodos analisados. Este padrão era esperado, uma vez que estes conjuntos apresentam grande quantidade de mobiliário em seu interior, enquanto os demais apresentam aspectos estruturais. A justificativa está relacionada com o processo de análise da metodologia empregada neste trabalho, baseada na definição de pontos remanescentes em decorrência da mudança de orientação de vetores normais.

Apesar do algoritmo apresentar taxa de simplificação média equivalente aos métodos tradicionais, os resultados são promissores devido o processo ocorrer sem a necessidade de inserção de parâmetros iniciais pré-definidos pelo usuário. A taxa de simplificação alcançada é interessante para o contexto da representação de subespaços internos, uma vez que a razão de simplificação de 97% permite que o processo de modelagem 3D de estruturas internas simples seja modelado adequadamente. Para objetos ou edificações complexas é necessário analisar se esta razão de simplificação permite identificar as principais variáveis geométricas para analisar a estrutura tridimensionalmente.

FIGURA 34 – TAXA DE SIMPLIFICAÇÃO



FONTE: O autor (2022).

A principal limitação está relacionada com a ausência de um processo que permita analisar a importância dos pontos pertencentes a nuvem de pontos LiDAR, sendo recomendável, futuramente, a adoção de estratégias complementares para analisar a importância de cada ponto em detrimento às características geométricas dos objetos perfilados.

A estratégia apresentada na Capítulo 4, de análise da rugosidade da nuvem de pontos LiDAR pode complementar a estratégia apresentada quando o objetivo é modelar geometricamente um subespaço interno.

5.4 CONCLUSÕES DO CAPÍTULO


Nesse Capítulo, apresentou-se um método para a simplificação de nuvem de pontos LiDAR baseado em uma estratégia AM para minimizar o número de pontos que compõem o conjunto de dados e em consequência sua complexidade de processamento. A abordagem empregada foi eficiência na tarefa de simplificação a partir da análise da HN centrada em nuvem de pontos LiDAR reduzindo a redundância do conjunto de dados. A proposta oferece uma alternativa aos métodos tradicionais, com a vantagem de não exigir a inserção de parâmetros iniciais de forma manual. Para o aprimoramento do método é recomendado o desenvolvimento de uma estratégia para analisar a importância dos pontos em relação à geometria dos objetos perfilados, mantendo pontos característicos de minimizem erros em processos posteriores ao de simplificação, como por exemplo, a criação de modelos 3D. Este processo pode ser aprimorado a partir da análise da curvatura e rugosidade de nuvem de pontos LiDAR.

CAPÍTULO 6 - AGREGAÇÃO DE SUPERFÍCIES PLANAS BASEADA NA HN

Como discutido nos Capítulos 4 e 5, o primeiro operador de generalização cartográfica 3D a ser aplicado em uma nuvem de ponto é a simplificação. Este operador é importante como uma etapa inicial, pois, permite a minimização de redundância do conjunto de dados e em consequência, demandas computacionais em etapas subsequentes. O resultado da aplicação desta tarefa é um conjunto de pontos em menor quantidade que o conjunto de origem, mas que apresente as mesmas características geométricas e matemáticas do original. A manutenção das propriedades geométricas é importante para que a nuvem de pontos LiDAR seja processada e interpretada de forma eficiente. Tratando-se de ambientes internos é interessante manter bordas e aspectos construtivos que tenham uma mudança de orientação ou posicionamento em específico para que em etapas de modelagem geométrica seja possível a construção de modelos 3D consistentes.

Uma vez que essa generalização estatística seja computada, é importante a inferência da relação topológica entre um ponto e sua vizinhança imediata para raciocínio e cálculos adicionais. Esse processo consiste na análise das propriedades geométricas e de similaridade da distribuição espacial de um ponto, e, em consequência, a definição de agregados pontuais em decorrência de características geométricas semelhantes, como ilustrado na FIGURA 35.

FIGURA 35 – CARACTERÍSTICA GEOMÉTRICAS (a) VETORES NORMAIS (b) AGREGAÇÃO



FONTE: O autor (2022).

Na FIGURA 35a são representados vetores normais computados sobre uma nuvem de pontos LiDAR. Esses vetores são calculados localmente e usados para definir características semelhantes entre os pontos que compõem o conjunto a partir da dedução de sua orientação, direção etc. A definição de características como os vetores normais é a chave para a agregação de pontos e extração de semântica por processos computacionais automatizados. A FIGURA 35b ilustra esse fato, uma vez que a partir da análise da direção dos vetores normais foi possível

a segmentação dos pontos em relação a cada alvo mapeado. Todavia, a segmentação, nesse caso, ocorre sem a inserção de semântica. Definir estratégias computacionais para agregação 3D associada a inserção de semântica é uma tarefa desafiadora. Métodos baseados em AM são alternativas possíveis para agregar conjuntos de pontos, fornecendo níveis de generalização de nuvem de pontos relacionando-as aos objetos e/ou estruturas construtivas perfiladas (FIGURA 6, Capítulo 2).

Partindo-se deste princípio, esse Capítulo descreve uma metodologia baseada em AM e HN que permite a agregação de nuvem de pontos considerando suas características geométricas em superfícies planas. Para isso, primeiramente, determinam-se vetores normais, inseridos em uma RNC baseada em voxels. Em sequência, após o treinamento da RNC, insere-se os dados de teste para a confecção de novos grupos de pontos agregados explorando a sinergia entre *clusters* relevantes e características de ambientes internos de edificações (elementos estruturais e objetos). Por fim, um conjunto de pontos pertencentes a elementos construtivos da edificação analisada são agregados conforme feições planas a partir da análise de vetores normais. Em suma, este Capítulo busca inserir duas contribuições: 1) Definir uma estratégia de agregação de pontos considerando aspectos construtivos de ambientes internos a edificações e; 2) Decompor uma nuvem de pontos LiDAR em elementos conectados e agregados em decorrência da análise de descritores locais. Robusto a ruídos, variação de resolução, desordem e oclusões.

6.1 TRABALHOS RELACIONADOS

A automação no processamento de nuvem de pontos LiDAR é uma questão central para a extração de conhecimento 3D formalizado. A definição de características relevantes é a chave para a agregação e classificação, sendo um dos principais desafios associados ao fluxo de trabalho relacionado às nuvens de pontos LiDAR. A necessidade de desenvolvimentos sobre essas questões está relacionada na criação de *frameworks* mais rápidos e confiáveis para extração de informações sobre um domínio de aplicativo específico. No entanto, as abordagens ainda não satisfazem eficientemente todos os domínios, pois os conceitos semânticos ligados a objetos e localização variam com seu uso específico.

Entretanto, agregar pontos em decorrência de suas características é uma tarefa não trivial que exige raciocínio interoperável e flexível para lidar com relacionamentos geométricos e semânticos em decorrência do espaço perfilado (POUX, 2019). Apesar das dificuldades, segundo Xue et al. (2020), ambientes urbanos e as construções no geral apresentam autossimilaridade geométrica, ou seja, seções invariáveis seguindo princípios da Gestalt,

descrita por Max Wertheimer, incluindo proximidade, conectividade, simetria e similaridade. Logo, para agregar um conjunto de pontos pode-se partir do pressuposto inserido pela Gestalt: o todo é maior que a soma de suas partes, e que as relações entre as partes podem produzir novas propriedades/ recursos.

Embora, naturalmente, o sistema cognitivo visual humano permita o entendimento desses princípios, é difícil traduzi-los e formalizá-los seguindo uma linguagem de programação. Entretanto, com o avanço computacional, técnicas de AM são promissoras e permitem a formalização de princípios da Gestalt computacionalmente. A principal vantagem, relaciona-se com a possibilidade de extração de informação de um conjunto de dados de treinamento sem um modelo matemático específico. Busca-se, nesse contexto, padrões relacionados a dados de entrada e saída, permitindo utilizá-lo para realizar previsões acerca de uma amostra.

Nisso, busca-se, nessa Seção, cobrir o contexto da aplicação de métodos para a definição de agrupamentos de nuvem de pontos (diretamente relacionados a operadores de agregação, pois permitem a inserção de semântica e sua posterior agregação em decorrência dos objetos e estruturas perfiladas) a partir de uma discussão de referências teóricas e abordagens práticas recentes (2016+), Subseção 6.1.1.

6.1.1 Principais abordagens

Considerando a perspectiva da AM, os métodos de processamento de nuvem de pontos LiDAR podem ser classificados em quatro classes: 1) Não aprendizado; 2) Aprendizado supervisionado; 3) Aprendizado por reforço e 4) Aprendizado não supervisionado (XUE, et al., 2020).

A primeira classe, definida como não aprendizado, emprega o modelo de correlação baseado em regras sobre primitivas geométricas e suas articulações. No caso de ambientes internos a edificações, as primitivas geométricas relacionam-se com a estimativa de vetores normais (XU et al., 2021; HUANG et al., 2019) e extração de feições planas, como, por exemplo, o algoritmo RANSAC para estimativa de pisos, tetos e paredes (LI et al., 2017; EBRAHIMI; CZARNUCH, 2021). Ao utilizar estas abordagens, relacionam-se informações semânticas aproximadas a partir da análise da geometria em relação a uma vizinhança em um contexto local. Nestes casos, a escala e a forma do objeto variam, logo, a vizinhança selecionada deve ser capaz de descrever informações geométricas em várias escalas e intervalos (XU, STILLA, 2020). Entretanto, apresentam limitações em cenas complexas e em conjuntos de dados com presença de ruídos.

Métodos baseados em aprendizado supervisionado emprega um processo de treinamento a partir de amostras pré-estabelecidas, correlacionadas com rótulos previamente determinados. O primeiro desafio é obter grupos de pontos que possam descrever a organização dos dados e definição de um agrupamento relevante. As abordagens supervisionadas também são caracterizadas como SS (XU; STILLA, 2020) e cresceram com o advento da tecnologia AM, ferramentas poderosas para a interpretação de nuvem de pontos LiDAR. Nesses casos, diferentemente de técnicas tradicionais, um algoritmo implementado em uma única rede, normalmente, combina a extração de recursos geométricos locais com processos de classificação. A SS, subdivide-se em 3 subclasses: baseado em imagens (ROBERT et al.; 2020), em voxel (POUX, 2019) e em pontos (QI; YI et al., 2017a; QI; YI et al., 2017b).

A SS baseada em imagens permite a criação de um conjunto de imagens a partir das nuvens de pontos LiDAR, sobre as quais aplicam-se convoluções para a determinação de agregados pontuais em paralelo com sua semântica. As metodologias baseadas em voxel fazem um processo de rasterização em voxels (pixels 3D), mantendo propriedades contínuas e a terceira dimensão. Já nas estratégias baseadas em pontos, busca-se determinar características diretamente nos dados brutos, dispensando etapas específicas de pré-processamento.

Apesar das abordagens apresentarem resultados satisfatórios, observa-se que em ambientes urbanos sofisticados, as estratégias podem tornar-se complexas e a precisão dos resultados de aprendizagem pode ser problemática, uma vez que há um grande desvio entre o modelo de classificação e reconhecimento da semântica estrutural. Um dos métodos pioneiros, como mencionado previamente neste trabalho, é o algoritmo PointNet (QI; YI et al., 2017a), uma RNC capaz de aprender por conta própria os recursos geométricos para classificação e agregação de subpartes de uma nuvem de pontos LiDAR. O algoritmo explora as feições pontuais definindo propriedades geométricas globais a partir de uma função simétrica (*maxpooling*), obtendo invariância de permutação de entrada. Finalmente, o algoritmo agrega os valores para previsão e classificação de rótulos. O PointNet++ (QI; YI et al., 2017b) foi uma melhoria do PointNet, obtendo além de informações globais à exploração de características locais (relações entre pontos vizinhos) aprimorando a acurácia dos métodos propostos.

Baseado nessas iniciativas precursoras, outras variações foram impostas e empregadas para agregação de nuvem de pontos LiDAR em decorrências às suas características semânticas e geométricas (XIA et al.; 2022; LUO et al.; 2021). Apesar dos métodos apresentarem resultados satisfatórios, geralmente são aplicados em pequenas escalas, ou seja, para classificação de objetos isolados e não considerando uma cena completa.

A terceira classe de métodos, estratégias baseadas em aprendizado por reforço, definem a correlação de agregação gradualmente após iterações e baseiam-se na extração de descritores locais da vizinhança 3D. Consiste em um processo de tentativa e erro para maximizar as recompensas e minimização do erro médio quadrático da estimativa. São aplicados com frequência nas etapas de registro de nuvem de pontos LiDAR, como o algoritmo ICP (BESL; MCKAY; 1992). Outros exemplos, nessa categoria, incluem: Pavan e Santos (2017); Santos, Freiman e Pavan (2018) e Xue et al. (2019). Em comparação com o aprendizado supervisionado, o esforço depende de uma função de otimização em vez de rótulos de treinamento, maximizando os resultados a partir da minimização do erro médio quadrático das estimativas.

Por fim, o aprendizado não supervisionado não requer exemplos de treinamento ou funções de recompensa. Em comparação com os demais é altamente automatizado em termos de aplicação e determinação de agrupamentos. Nesse caso, os algoritmos entendem que objetos do mesmo grupo são mais semelhantes considerando algumas características geométricas específicas do que aqueles de grupos diferentes. Exemplos são: crescimento por regiões, k-médias de direções normais, e baseado em proximidade (XU; STILLA, 2021), além das técnicas de AM implementadas recentemente (POUX, 2019). A principal vantagem desses métodos é a minimização da interação homem-máquina, quando comparado com o supervisionado, entretanto, podem apresentar sensibilidade à presença de *outliers*.

No Quadro 6 são listadas as características dos métodos descritos neste Capítulo.

QUADRO 6 – CARACTERÍSTICAS DOS MÉTODOS DE PROCESSAMENTO DE NUVENS DE PONTOS

	Não aprendido	Supervisionado	Reforço	Não Supervisionado
Pré-requisitos	Conhecimento da estrutura perfilada.	Conjunto amostral.	Função de otimização.	Características aprendidas.
Principais usos	Agregação de objetos.	Rotulação e agregação.	Reconhecimento de pontos-chave. Registro de NPs.	Agregação de objetos. Estratégias de pré-processamento.
Vantagens	Baixo custo computacional e adaptável.	Adaptabilidade a diferentes domínios. Possibilidade de aplicação do Big Data.	Resultados otimizados e ajustados.	Baixo custo computacional. Precisão crescente.
Desvantagens	Tem uma aplicação limitada em cenas complexas.	Alto custo computacional e precisão insatisfatória quando a amostra não for efetiva.	Necessidade de muitas iterações e alto custo computacional.	Aplicação a pequenos conjuntos e sensível a ruídos.

FONTE: O autor (2022).

Nessa revisão, foram elencadas 4 abordagens pertinentes de interpretação e processamento de nuvem de pontos LiDAR e correlacionam-se com as direções que conduziram os processos metodológicos deste Capítulo (Seção 6.2). Em primeiro lugar, é importante identificar pontos-chave em uma nuvem de pontos que podem reter uma conotação relevante para objetos relacionados a um certo domínio. Em segundo lugar, nota-se que ambientes internos apresentam homogeneidade. Ademais, os aspectos construídos retêm alta proporção de superfícies planas, como pisos, tetos e paredes. Portanto, detectá-los constitui o primeiro passo em uma estrutura metodológica, considerando aspectos computacionais, flexibilidade de aplicação e possibilidade de escalonamento. Por estes fatos, foi aplicado um método baseado em AM (Rede Neural Convolucional - RNC) para agregar pontos em decorrência de suas características geométricas semelhantes a partir de uma abordagem supervisionada.

6.2 PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO

Neste trabalho, aplicou-se seis conjuntos de dados presentes no repositório *Satanford Large-Scale 3D Indoor Dataset* (ARMENI et al., 2016). Compreendem nuvem de pontos LiDAR adquiridas em ambientes internos de uma edificação escolar, compostas por pontos pertencentes às estruturas construtivas e mobiliário (FIGURA 31, Capítulo 5). Todos os conjuntos estão devidamente registrados em um sistema de coordenadas global. Para a confecção do método, empregou-se a linguagem de programação Python 3.0 e bibliotecas computacionais *open-source*. Os testes foram executados no ambiente *Google Colaboratory*. O método empregado é descrito na Subseção 6.2.1


6.2.1 Método

As estratégias de generalização de nuvem de pontos LiDAR incluem, em maioria, operações de simplificação, descritas como a eliminação de pontos redundantes que não inserem informações relevantes ao processo e aumentam o custo computacional. Posterior a simplificação, ainda é necessário interpretá-la. No contexto do mapeamento 3D de ambientes internos a principal interpretação geométrica é a identificação de subespaços que compõem o ambiente. Neste aspecto, um processo de agregação pode auxiliar, reduzindo a densidade de pontos, no entanto, mantendo o padrão de distribuição representativo do grupo de recursos original.

No caso 2D, a agregação é aplicada para minimizar a distribuição representativa mantendo a estrutura espacial de visualização do grupo original. No contexto 3D, é necessário agregar um conjunto de entidades semelhantes para formar uma única. Embora a agregação 2D tenha sido amplamente estudada para agregar feições cartográficas, o procedimento em objetos 3D não atraiu uma quantidade considerável de desenvolvimentos. Portanto, aqui, o foco é propor um processo de agregação 3D de pontos em subespaços (conforme descrito no Capítulo 2).

Considerando o domínio *indoor*, restrições adicionais devem ser inseridas devido à terceira dimensão. A principal tarefa, então, é considerar um ambiente interno como um conjunto de primitivas geométricas relativas às estruturas que compõem um subespaço (paredes, pisos, janelas, como exemplos). A RNC projetada para esta tarefa visa correlacionar um conjunto de pontos com objetos ou partes construtivas de uma edificação, como ilustrado na FIGURA 36.

FIGURA 36 – ARQUITETURA RNC APLICADA NO PROCESSO DE AGREGAÇÃO



FONTE: O autor (2022).

Primeiramente é dada uma nuvem de pontos LiDAR de entrada que será estruturada a partir de *voxels* e então, segmentada em subespaços e interpretada pela RNC, determinando sua correspondência em relação a um objeto O para prever as propriedades geométricas. A RNC é treinada usando uma função de custo que minimiza a discrepância entre um conjunto de pontos e sua forma básica correspondente, conforme descrito na Subseção 6.2.1. A agregação ocorre quando um conjunto de pontos é agrupado de acordo com as características geométricas de um determinado alvo, associando-os a um rótulo semântico.

6.2.1.1 Otimização RNC

Antes de iniciar o processo de otimização pela aplicação da RNC empregada neste trabalho, operações de pré-processamento foram aplicadas e consistem nas atividades

discutidas no Capítulo 5, simplificação de nuvem de pontos LiDAR. A simplificação é uma operação importante para minimização e exclusão de pontos redundantes presentes em cada cena perfilada. Com base nas nuvens de pontos LiDAR simplificadas foi necessário a exploração da HN para estimar características geométricas relevantes de cada conjunto, como, por exemplo, a estimativa dos vetores normais, denominadas neste trabalho como primitivas perspectivas locais, ou seja, descritores baseados no cálculo dos autovalores (Capítulo 3). As normais foram estimadas empregando o software *Cloud Compared*.

Esses experimentos são baseados na implementação fornecida por Choy, Gwalk e Savarese (2019). Tal implementação emprega k-vizinhos mais próximos para individualizar os k pontos mais próximos de um ponto a ser agregado e classificado, definido assim uma vizinhança. As propriedades de borda são calculadas a partir de uma região vizinha e fornecidas como entrada para a camada seguinte da rede (FIGURA 36). Dá-se como entrada um bloco de cena, composta por feições aleatórias que geralmente estão presentes em um ambiente interno, tendo cada ponto: coordenadas X_i, Y_i e Z_i e os parâmetros dos vetores normais. Com base no processo de otimização da rede, as características geométricas de cada ponto são atualizadas e interpretadas a partir de análises de similaridade, e, então, os pontos são agregados e separados em classes temáticas.

Segundo Choy, Gwalk e Savarese (2019) a convolução da RNC proposta é representada por uma extensão N-dimensional de uma matriz esparsa. A convolução é realizada a partir de um conjunto de coordenadas armazenadas em uma matriz $C_i = \{(X_i, Y_i \text{ e } Z_i)\}_i$ e um conjunto de características geométricas associadas $F = \{f_i\}_i$. Após definidas, as convoluções são generalizadas para formas de kernel arbitrárias. Logo, se $x_u^{in} \in R^{N^{in}}$, sendo N^{in} um vetor de características geométricas no espaço D -dimensional (coordenadas 3D) em que $u \in R^D$ e os pesos sinápticos das convoluções estimados por $W \in R^{K^D * N^{out} * N^{in}}$. Os pesos W_i são decompostos em matrizes de dimensionalidade $N^{out} * N^{in}$ por $|\{i\}_i| = K^D$. Então, a convolução na dimensão D é dada pela Equação 13:

$$x_u^{out} = \sum_{i \in v^D(K)} W_i x_{u+i}^{in} \text{ em que } u \in \mathbb{Z}^D \quad (13)$$

Especificamente, a convolução emprega um conjunto de coordenadas genéricas de entrada e saída e para formas de kernel arbitrárias, em que $v^D(K)$ é uma lista de deslocamento dimensional que define o kernel. Neste caso, a primeira etapa da RNC é o processamento de

dados de entrada para gerar uma saída esparsa, que converte uma entrada em coordenadas exclusivas, recursos associados e, opcionalmente, rótulos previamente estabelecidos para rotular cada conjunto de pontos em relação ao objeto de origem. Então, gera-se coordenadas de saída (C_{out}) a partir do conjunto empregado como dados de entrada (C_{in}).

Em seguida, para convoluir uma entrada com um kernel é necessário mapear quais delas afetam determinadas saídas, definidos como pares de listas de índices de entrada e de saída, $M = \{(I_i, O_i)\}_i$ para $i \in n^D$, em que n^D é o intervalo dimensional que define a forma do kernel, enquanto I e O são, respectivamente, vetores que representam parâmetros geométricos característicos (vetores normais) de entrada e saída. Finalmente, dadas C_{in} e C_{out} , o mapa de kernel e os pesos W_i podem ser estimados.

Neste caso, o algoritmo permite a extração de recursos iniciais da nuvem de pontos LiDAR, ou seja, categorias semânticas são agregadas em um mesmo grupo, enquanto aqueles classificados como diferentes são separados. Integra-se, assim, as informações aos recursos de cada instância com reconhecimento semântico e vice-versa. Todo o processo foi baseado na Biblioteca Minkowski Engine 0.5.3, empregando uma RNC estruturada em voxelização. No geral, o algoritmo encontra voxels exclusivos e cria rótulos associados a eles. Nesse caso, foi empregada uma rede treinada, ou seja, os pesos sinápticos previamente estabelecidos a qual é ajustada individualmente em cada cena devido à existência de estruturas internas complexas.

Resumidamente, o processo consiste a partir de um conjunto de coordenadas $C \in \mathbb{Z}^{N \times N}$ associado a parâmetros geométricos $F \in \mathbb{R}^{N \times N \times F}$, em que N é um número não nulo (ou seja, não vazios), D a dimensão analisada (3D) e NF o número de camadas da RNC. Nesse caso, a cada camada da RNC é necessário o mapeamento para determinar qual pontos coordenados de entrada (I) é mapeado na camada de saída (O).

A camada de saída fornece a primeira estimativa da representatividade de um conjunto de pontos agregados a partir da definição de sal semântica, aplicado apenas para reconhecimento de estruturas internas a edificações e a objetos que comumente estão presentes nesses ambientes. A agregação de pontos pertencentes a uma nuvem de pontos LiDAR é o primeiro passo para possibilitar a agregação de Subespaços, como discutido no Capítulo 7, deste trabalho.

A implementação é realizada a partir de uma Rede Neural Residual (ResNet – *Residual Neural Network*). O conjunto ScanNet⁷ foi empregado para treinar a rede. Após a definição da


⁷ SCANET. Disponível em: https://kaldir.vc.in.tum.de/scannet_benchmark/documentation. Acesso em: 15 nov. 2022

semântica e agregação pontual conforme alvos perfilados, realizou-se o processo de estimativa e definição de planos para que os elementos estruturais sejam agregados com base em elementos geométricos, como descrito na Subseção 6.2.2.

6.2.1.2 Estimativa e agregação de pontos em superfícies planas

No contexto da representação de edificações, após a determinação de agregados pontuais é necessário a compilação da agregação completa em relação aos elementos estruturais da cena. Nesse caso, as paredes são elementos perpendiculares ao piso. Além disso, a partir da coordenada Z, é possível projetar paredes verticais. A ilustração do processo é apresentada na FIGURA 37.

FIGURA 37 – AGREGAÇÃO DE PONTOS EM SUPERFÍCIES PLANAS



FONTE: O autor (2022).

A FIGURA 37 mostra que a partir dos resultados adquiridos com a aplicação do processo descrito na Subseção 6.2.2 são adquiridos agregados pontuais relacionados aos elementos estruturais da edificação, paredes, piso e teto. Nesse passo, já existe um processo de agregação, minimizando o conjunto de elementos necessários para modelagem de subespaços. Entretanto, ainda é necessário e possível agregá-los conforme elementos geométricos completos. No caso de construções, por apresentarem em maioria elementos estruturais regulares considerou-se a agregação de cada conjunto de pontos pertencentes a um elemento estrutural em planos (conforme LoD1 e LoD2, DA CityGML). A sua estimativa, primeiramente, foi realizada com o emprego do algoritmo *RANdom Sample Consensus* (RANSAC) (FISCHLER; BOLLES, 1981) implementado na biblioteca open3D.

O algoritmo RANSAC seleciona aleatoriamente um conjunto mínimo de pontos (n) pertencentes a um determinado conjunto, a partir do qual inicia o processo de geração de parâmetros matemáticos para a geometria plana em específico. Nesse caso, para estimar estes valores de planos e torná-los superfícies contínuas, realizaram-se as seguintes etapas:


- a) A partir dos elementos pontuais agregados em elementos estruturais verticais e horizontais, na etapa descrita na Subseção 6.2.1 o algoritmo seleciona aleatoriamente um conjunto mínimo de pontos (que nesse caso, por tratar-se de elementos de grandes dimensões, consideraram-se planos mínimos que contivessem ao menos 5.000 pontos) para a geração de soluções candidatas e estimação dos parâmetros do plano, sendo que a nuvem de pontos contém um número maior do que 5.000 pontos;
- b) A partir da geração de planos candidatos, inicia-se a estimação dos parâmetros do modelo matemático ($ax + by + cz + \rho = 0$, em que (a, b, c) são parâmetros do vetor normal ao plano e ρ a distância entre a origem do plano e a origem do sistema de coordenadas da nuvem de ponto) para as observações selecionadas em (a);
- c) Analisa os demais pontos do conjunto de dados. Nesse processo, verifica-se a direção do vetor normal de cada ponto que pertence ao conjunto, sendo permitido um desvio máximo de 45° (valor inserido manualmente);
- d) A partir disto, o algoritmo analisa os demais pontos do conjunto, determinando quais deles pertencem a um específico, selecionados com limiares definidos pelo operador (erro tolerável ($e = 0,02$) e número de iterações ($k = 1000$));
- e) Iterativamente, testa um novo conjunto de pontos no modelo parametrizado para o plano em (b), substitui-se o conjunto consenso por esse novo grupo de observações. Caso não seja a última iteração do processo, retorna-se a etapa (a);
- f) Na última iteração, os parâmetros do modelo matemático são ajustados, empregando o Método dos Mínimos Quadrados (MMQ)

Após a aplicação do algoritmo RANSAC, um conjunto de pontos são especificados como pertencentes a um mesmo plano que apresenta uma configuração específica – verticais (paredes) e horizontais (pisos e tetos) –. A partir disso, estima-se uma forma plana ajustada a esses conjuntos, substituindo-se em uma única superfície agregada conforme planos regulares (FIGURA 37). Os resultados e as discussões são apresentados na Subseção 6.3 que segue.

6.3 RESULTADOS E DISCUSSÕES

Após a aplicação da RNC, realizou o processo de agregação baseado na estimativa de características geométricas locais das nuvens de pontos LiDAR de treinamento para posteriormente classificar e agrupar um conjunto de pontos. Neste estudo, como considera-se ambientes internos a edificações, os pontos foram agregados em estruturas construtivas e objetos (mobiliário) (FIGURA 38).

FIGURA 38 – RESULTADOS GERAIS DO PROCESSO DE AGREGAÇÃO DE PONTOS



FONTE: O autor (2022).

Para avaliar os resultados, empregou as métricas apresentadas na Subseção 6.3.1.

6.3.1. Métricas de avaliação

O processo de avaliação consistiu na definição de métricas para avaliar os dados agregados a partir da metodologia apresentada na Seção 6.2. No caso da generalização cartográfica 3D, foram definidas métricas e correspondências entre a cena real perfilada e os resultados obtidos com a aplicação do algoritmo. Os aspectos analisados são associados ao espaço de armazenamento e custo computacional de processamento, mensurando aspectos de performance, um fator importante quando se trabalha com aspectos de AM. Além disso, métricas de precisão foram empregadas para denotar a qualidade das estimativas obtidas com a aplicação da metodologia.

Nesse caso, foram determinados o grau de correspondência que o modelo pode diagnosticar entre previsões e uma referência. As métricas empregadas para avaliar permitem analisar a Acurácia geral (Ag) do método, que associa predições positivas (TP) e predições negativas (FP) em relação ao número n de classes a serem analisadas, conforme EQUAÇÃO 14 (POUX, 2019).


$$A = \frac{\sum_{i=1}^n TP_i / (FP_i + TP_i)}{n} \quad (14)$$

A precisão geral é uma medida que permite analisar o desempenho do algoritmo, ou seja, sua capacidade de agregar pontos em um mesmo conjunto corretamente. A precisão do processo (P) é obtida a partir da análise do valor de predições positivas (TP), negativas (FP), em que $P = \frac{TP}{TP+FP}$.

6.3.2 Avaliação dos resultados

No tocante a avaliação dos resultados, realizaram-se análises quantificas e qualitativas. As primeiras estão relacionadas com as estimativas descritas na Subseção 6.3.1, enquanto, as segundas, com análises visuais de completude dos elementos que compõem a cena. A análise é importante, pois sua qualidade influenciará no processo aplicado no Capítulo 7, em que busca a formação de subespaços completos. Na FIGURA 39, ilustram-se os principais elementos classificados a partir da agregação de pontos.

FIGURA 39 – ELEMENTOS ESTRUTURAIS AGRUPADOS (HORIZONTAIS E VERTICAIS)



ZFONTE: O autor (2022).

As estruturas verticais (FIGURA 39) representam feições planas com aspectos de verticalidade bem definidos (pontos em azul), estimadas a partir da análise de vetores normais de cada ponto pertencente ao grupo em específico. Tratando-se do perfilamento de edificações é um dos principais elementos a serem determinados, uma vez que representam as paredes que delimitam um subespaço específico (FIGURA 40). As feições horizontais representam pisos e tetos (pontos em verde – FIGURA 39).


FIGURA 40 – DELIMITAÇÃO DE SUBESPAÇOS POR FEIÇÕES VERTICAIS



FONTE: O autor (2022).

Os resultados alcançados foram satisfatórios para o reconhecimento de elementos estruturais em cinco dos seis conjuntos de dados empregados neste Capítulo, no entanto, os elementos verticais e horizontais que compõem o subespaço que forma o conjunto VI foi classificado erroneamente, como ilustrado na FIGURA 41(a). Esse erro ocorreu devido ao espaço ser quadrado, sem nenhum detalhamento em específico. Isso insere dificuldades na tarefa de reconhecimento automático de estruturas e elementos presentes na cena, uma vez que as geometrias formadas pela distribuição dos pontos apresentam alta similaridade. Essa problemática ainda deverá ser aprimorada a partir de novas adaptações e treinos na RNC empregada.

FIGURA 41 – ERROS PREDITIVOS (a) ESTRUTURAIS (b) PORTAS E JANELAS (c) MOBÍLIA



FONTE: O autor (2022).

As janelas e portas também são elementos construtivos essenciais em processos de modelagem 3D de edificações e representam aspectos de conectividade de um subespaço para outro. O algoritmo empregado teve uma taxa de acertos (precisão) de 30% para estes elementos, não sendo uma taxa satisfatória. Erros de agrupamentos foram verificados em todos os conjuntos que continham portas ou janelas. Na FIGURA 41(b) é ilustrado um dos erros ocasionados. O algoritmo apresentou desempenho satisfatório no reconhecimento de portas

abertas, aquelas que permaneceram fechadas no interior das edificações não foram reconhecidas pelo algoritmo. Para feições planas verticais (paredes) e horizontais (teto e piso) apresentou acurácia geral de 84% (TABELA 5). O processo de identificação de portas e janelas, devido o valor da acurácia ser baixo, ainda deve ser aprimorado. Entretanto, aspectos relativos a feições planas verticais e horizontais apresentaram taxas de precisão e acurácias satisfatórios e são os elementos de entrada para a análise da modelagem de superfícies geométricas por meio da parcimônia da descrição, discutido no Capítulo 7.

TABELA 5 – PRECISÃO DE PREDIÇÃO DO ALGORITMO (ESTRUTURAS)

Experimentos	Planas Verticais	Planas horizontais	Janelas	Portas
	<i>P</i>	<i>P</i>	<i>P</i>	<i>P</i>
Conjunto I	95%	76%	0%	50%
Conjunto II	63%	85%	-	0%
Conjunto III	81%	97%	15%	90%
Conjunto IV	90%	98%	10%	45%
Conjunto V	86%	93%	75%	0%
Conjunto VI	70%	72%	-	-


FONTE: O autor (2022)

Os erros de estimativa são esperados em ambientes internos devido a sua heterogeneidade e presença de oclusões. As estimativas encontradas necessitam de um refinamento, entretanto, permitem minimizar a interação homem máquina e em consequência, processos manuais tediosos, que em termos de qualidade, quando aplicado em ambientes de grandes dimensões, podem inviabilizar o processo.

Além de elementos estruturais, o algoritmo também consegue agrupar pontos pertencentes a um objeto como cadeiras, mesas, escrivaninhas, sofás e armários. As estimativas para estes objetos foram satisfatórias, todavia, devido à variabilidade de feições em ambientes internos, alguns equívocos foram ocasionados - FIGURA 41(c) -, em que pontos relativos a uma tela de computador são agrupados com aqueles relacionados a mesas e escrivaninhas.

Os resultados relacionados a esses processos são ilustrados na FIGURA 42. Nos conjuntos II e III não estavam disponibilizados armários no momento do perfilamento. O subespaço número IV, é relativo a um sanitário, logo, não foram reconhecidos elementos como cadeiras e mesas. Os elementos construtivos dos sanitários também não foram reconhecidos de forma satisfatória pelo algoritmo. O conjunto VI foi um perfilamento de um saguão, completamente vazio. Por este fato, sem identificação de objetos na cena perfilada. O elemento ilustrado na FIGURA 42 para o conjunto VI diz respeito aos detalhamentos arquitetônicos.

FIGURA 42 – OBJETOS GERAIS AGREGADOS (CADEIRAS, MESAS, ARMÁRIOS, etc.)



FONTE: O autor (2022).

A acurácia e precisão geral para o agrupamento de objetos foram, respectivamente, 80% e 76%. Considerados valores satisfatórios para o processo. Embora o mobiliário não seja ponto focal deste trabalho, as determinações relativas a eles são importantes para outras etapas, como, por exemplo, aspectos relacionados à confecção de representações 3D, de simbolização e reconhecimento de elementos estruturais para o cálculo de rotas de emergência em ambientes internos. Logo, a aplicação desse algoritmo pode ser considerado o ponto inicial de diferentes aplicações que busquem a representação e/ou estimativas espaciais considerando a terceira

dimensão. Os valores de acurácia e precisão para o agrupamento de objetos internos para cada experimento são listados na TABELA 6.


TABELA 6 – ACURÁCIA E PRECISÃO DE PREDIÇÃO DO ALGORITMO (OBJETOS)

Experimentos	Mesas	Cadeiras	Armários
	<i>P</i>	<i>P</i>	<i>P</i>
Conjunto I	99%	74%	70%
Conjunto II	95%	91%	20%
Conjunto III	78%	86%	12%
Conjunto IV	-	-	-
Conjunto V	85%	87%	25%
Conjunto VI	-	-	-

FONTE: O autor (2022).

No gráfico da FIGURA 43 são ilustrados o valor de precisão para cada elemento discutido nessa Seção (6.3.2).

FIGURA 43 – REPRESENTAÇÃO DA PRECISÃO DE AGREGAÇÃO PONTUAL E ROTULAÇÃO



FONTE: O autor (2022).


Os resultados também foram confrontados com processos tradicionais de extração de geometrias e semantização de uma nuvem de pontos LiDAR, conforme Subseção 6.3.2.1.

6.3.2.1 Comparação com métodos tradicionais

O processo de agregação pontual executada na Seção 6.3.2 apresentou resultados satisfatórios, considerando o conjunto S3DIS empregado, composto por cenas complexas com

presenças de ruídos, escadas, mobiliário e áreas de oclusões que dificultam as estimativas corretas. É um conjunto de dados robusto para obtenção de indicadores de qualidade para os resultados das etapas de rotulação. Etapa crucial para automatizar processos de identificação e agregação de pontos em superfícies, que reduzirão o custo computacional para renderizar e armazenar uma nuvem de pontos LiDAR para possibilitar uma representação semântica efetiva das estruturas de uma edificação e, em consequência, seus subespaços. Nesse aspecto, estruturas AM permitem obtenção de resultados satisfatórios que ainda poderão ser aprimoradas com a inserção de novos dados de treinamento. Em comparação com algoritmo tradicional (*Connected componente*, implementado no software Cloud Compared) empregados para estimar agregados pontuais em nuvem de pontos LiDAR, o processamento por AM apresenta resultados superiores, como demonstrado na FIGURA 44.

FIGURA 44 – AGREGAÇÃO PONTUAL (a) ALGORITMO CONNECTED COMPONENT (b) DL



FONTE: O autor (2022).

Em relação a qualidade das estimativas, observa-se que o algoritmo *Connected Component* alcançou acurácia média de 57%. Além disso, não foi capaz de separar em nenhum dos conjuntos feições planas horizontais (piso ou teto) e verticais (paredes). As principais vantagens de estratégias AM é a possibilidade de rotulação de agregados pontuais, além de dispensar parâmetros de entrada definidos manualmente pelos usuários.

6.3.2.2 Transformação de agregados pontuais em superfícies planas

Após o processo de determinação de agregados pontuais adquiridos com o processo de definição de semântica para a cena perfilada, iniciou-se o processo de agregação de feições planas empregando o algoritmo RANSAC e o software *CloudCompared* para estimativa das superfícies finais. Observa-se que a estrutura metodológica proposta contém parâmetros de entrada para a detecção do plano, que – com a configuração proposta na Subseção 6.2.2 – foi invariável a mudança de cenas. Os parâmetros de entrada são listados no QUADRO 7.


QUADRO 7 – PARÂMETROS EMPREGADOS NO MÉTODO PROPOSTO

Parâmetros (valores)	Descrição
Distância ponto-plano ($e = 0,03$ m)	Distância máxima de um ponto que será agregado em um mesmo plano ajustado ao conjunto de agregados pontuais.
Derivação máxima das direções de vetores normais ($e = 45^\circ$)	Variação do ângulo entre as direções dos vetores normais relativos aos pontos que pertencem a um mesmo plano ajustado
Nº mínimo de pontos ($n = 5000$)	Os planos identificados devem ser compostos por agregados de pelo menos 5000 pontos. Este item é variável com a densidade da nuvem de pontos. Entretanto, para ambientes relacionados a edificações foi o valor que melhor estimou planos completos.
Probabilidade de existência de um plano ($p = 0,001$)	Valor mínimo calculado na estimativa do plano para afirmar a existência de um plano. Caso o parâmetro não seja atendido, o plano em questão não é criado.
Nº de iterações: ($i = 1000$)	Número de iterações para estimação dos resultados agregados.

FONTE: O autor (2022).

Neste caso, as primitivas planas (previamente classificadas como elementos estruturais verticais e horizontais) foram estimadas e ajustadas a partir do RANSAC, aplicado devido a sua robustez a presença de ruídos. Os resultados são apresentados na FIGURA 45.

FIGURA 45 – ESTIMATIVAS DE PLANOS ALGORITMO RANSAC (a) CONJUNTO I (b) CONJUNTO II (a) CONJUNTO III (d) CONJUNTO IV (e) CONJUNTO V (f) CONJUNTO VI




FONTE: O autor (2022).

Dentre os parâmetros empregados, como se busca um processo de agregação de agregados pontuais em superfícies planas é o valor que representa o menor número de pontos que participa na composição de um plano. Quanto menor o seu valor, maior o número de planos encontrados pelo algoritmo e em consequência a inserção de estimativas equivocadas. Nestes experimentos, definiu-se 5000 como número mínimo para a obtenção de planos verticais e

horizontais. O segundo parâmetro representa a distância máxima entre um ponto e um plano (0,03 m). Nos experimentos, empregou-se como parâmetro de similaridade a direção de vetores normais, os resultados são aceitáveis quando a variação máxima da direção varia em torno de 0° a 45° . Os resultados dessa etapa foram satisfatórios, no entanto, erros de completude da geometria foram observados, devido à presença de ruídos e buracos ocasionados por oclusões na cena perfilada.

O terceiro parâmetro reflete a probabilidade da existência de planos (0,001). Define-se, então, o desvio padrão máximo dos pontos pertencentes a um plano, buscando sua minimização, assim é possível estimar geometrias de forma mais confiável. Os planos estimados são apresentados na FIGURA 46.

FIGURA 46 – TRANSFORMAÇÃO DE PONTOS PARA AGREGADOS PONTUAIS (a) ELEMENTOS VERTICIAS (b) ELEMENTOS HORIZONTAIS



FONTE: O autor (2022).

Na Subseção 6.3.3 são apresentados os detalhes de performance.

6.3.3 Implementação e detalhes de performance

Como mencionado, o processo de agregação de elementos pontuais foi desenvolvido em *Python 3* empregando bibliotecas computacionais essenciais ao funcionamento do algoritmo e sua replicação para aquisição de resultados satisfatórios no *Google Colab*. No contexto da aplicação de técnicas de AM uma questão importante é o tempo de processamento que a RNC demandará para obter resultados satisfatórios. Como o processo foi obtido a partir de uma rede com ponderações previamente definidas, minimiza-se de forma eficiente o tempo para que o algoritmo possa obter respostas satisfatórias.

No conjunto de dados simplificados e aplicados neste Capítulo o tempo de execução não ultrapassou 20 segundos, considerando o contexto de processamento do *Google Colaboratory*. Para nuvem de pontos LiDAR maiores é necessário a aquisição de um plano pago na plataforma empregada, pois o disponibilizado gratuitamente não é suficiente para a demanda computacional do processo. Para processamentos locais é recomendado a utilização de equipamentos que disponham de processadores potentes, pelos menos 16 GB de RAM e GPU Nvidia. O sistema operacional Linux Ubuntu pode facilitar a instalação de bibliotecas e demais ferramentas computacionais.

Após definidos os agregados pontuais, a segunda etapa consistiu na estimativa de planos ajustados formados por um conjunto de pontos, determinados por similaridade de vetores normais, estimados a partir do software *CloudCompare*. O algoritmo empregado, RANSAC, não apresentou dificuldades ou alto custo computacional para estimar os parâmetros dos planos, considerando um número de iterações igual a 1000 e computados em Sistema Desktop, Ubuntu 20.4 e processador Core i5, sétima geração. Para processos que apliquem mais iterações, o custo computacional deve ser avaliado.

6.3.4 Discussões


A partir dos resultados apresentados na Subseção 6.3.1, foram realizadas discussões gerais acerca da qualidade do processo, suas vantagens e melhorias que deverão ser implementadas. Em primeiro lugar, o método, por empregar uma biblioteca computacional que traz funções complexas previamente definidas, é relativamente simples de implementar quando comparada com algoritmos tradicionais que necessitam de definição matemáticas e lógicas específicas. Uma plataforma cliente-servidor estruturada pode ser aplicada para o processamento o que minimiza a necessidade de aquisição de hardwares específicos que demandam um investimento monetário elevado.

A segunda vantagem se relaciona com a estrutura empregada, adaptável para aplicações diversas a partir da inserção de novos conjuntos de dados de entrada para o treinamento da rede em específico, sendo possível, então, ampliar o seu poder de reconhecimento estrutural com pouca ou nenhuma interação manual. Em terceiro lugar, a abordagem resulta em uma resolução aceitável para diversas aplicações que requerem a determinação de elementos estruturais de objetos que comumente estão presentes em uma cena interna, sendo aplicada para a extração e determinação de agregados pontuais de superfícies como paredes, tetos e pisos para a configuração de subespaços 3D em ambientes virtuais. Ou

seja, é a base para extrair subespaços organizados quanto à sua função. Pode ser empregado para fornecer plantas baixas, criação de cortes e modelagem 3D de ambientes internos considerando preceitos da IndoorGML ou IFC, quando considerando aspectos BIM. Em relação ao tempo, para ambientes isolados fornece desempenho adequado.

Para analisar o processo aplicado em uma nuvem de pontos LiDAR de um ambiente completo, foi realizado um experimento extra (conjunto também aplicado no Capítulo 4). Para processá-lo completamente expendeu-se 5 minutos. Os resultados são ilustrados na FIGURA 47.

FIGURA 47 – AGREGADOS PONTUAIS (a) VISTA SUPERIOR (b) SUPERIOR INTERNA (2º ANDAR) (c) SUPERIOR INTERNA (1º ANDAR) (d) PAREDES (e) PISO E TETO (f) VISTA LATERAL




FONTE: O autor (2022).

Esse conjunto consiste no perfilamento de um ambiente completo, contendo diferentes salas, distribuídas em dois pavimentos. Na FIGURA 47(a), é apresentado o resultado geral do

processo, em que todas as partes segmentadas compõem o ambiente completo, ou seja, a representação do todo é obtida pela soma de elementos estruturais e objetos instalados no interior das edificações, os quais são disponibilizados com a sua destinação de uso. Na FIGURA 47(b), observa-se a agregação de pontos relacionados a paredes e em seu interior a configuração do mobiliário, previamente agregados para o 2º pavimento da edificação. A configuração interna do primeiro pavimento é ilustrada na FIGURA 47(c).

As taxas de acurácia e precisão seguiram os mesmos preceitos descritos nos experimentos anteriores (83% e 65%, respectivamente), não tendo boa adequação para a formação de agregados pontuais relacionados a objetos como as janelas, porém, observa-se na FIGURA 47(f) que apesar dos erros de formação de um agregado pontual relacionados a essas partes estruturais, os principais aspectos de conexão entre subespaços foram definidos, mas necessitam de refinamento. Todavia, os resultados alcançados demonstram efetiva aplicação na modelagem geométrica de ambientes internos, uma vez que os elementos essenciais estruturais são bem definidos - FIGURA 47(d) e FIGURA 47(e) -, principalmente estruturas planas com o algoritmo RANSAC (FIGURA 48).


FIGURA 48 – ESTIMATIVA DE PLANOS HORIZONTAIS E VERTICAIS (a) 2º PAVIMENTO) (b) 1º PAVIMENTO



FONTE: O autor (2022).

Ao analisar um ambiente completo é possível gerar e identificar, mesmo que as formas geométricas não estejam completamente modeladas, dos subespaços pertencentes ao primeiro e segundo pavimento da edificação analisada. Superfícies planas são bem definidas pelo processo, entretanto, refinamentos devem ser aplicados, pois alguns planos não se adequaram bem à realidade, principalmente em regiões de difícil reconhecimento automático, como nas áreas de escadas que apresentam dados espúrios, regiões transparentes com presença de vidros e áreas que não são completamente curvas. Algumas dessas limitações são apresentadas na FIGURA 49.

FIGURA 49 – ESTIMATIVA DE PLANOS HORIZONTAIS E VERTICAIS (a) 2º PAVIMENTO (b) 1º PAVIMENTO



FONTE: O autor (2022).

Na FIGURA 49(a) são ilustrados exemplos de erros na estimativa de planos horizontais nas áreas de escada. Isso se dá devido a formação de um plano para cada degrau, além de pontos espúrios remanescentes de áreas com vidraças, que neste caso, no momento da varredura existe a aquisição de dados exteriores à edificação. Na FIGURA 49(b) é ilustrada uma feição curva, não sendo possível modelá-la conforme um plano, a possibilidade é adaptar o algoritmo RANSAC para o reconhecimento de superfícies curvas (círculo com borda vermelha), como cilindros. Na FIGURA 49(c) é ilustrado um erro de estimativa de um plano (elipse com borda vermelha). Devido a existência de ruídos na cena o algoritmo entende todos os pontos como um plano completo, diferenciando da orientação e configuração original da edificação.

Os erros demonstrados estão diretamente relacionados ao processo de reconhecimento e semantização das estruturas verticais, horizontais e mobiliário presente na cena que permitem a permanência de pontos que não pertencem às estruturas de interesse, modificando a interpretação do algoritmo acerca da configuração espacial dos subespaços de uma edificação. Esse é um problema recorrente devido à complexidade e variabilidade de configuração espacial

de ambientes internos. Logo, pequenas correções manuais são necessárias para a modelagem correta de subespaços.

Em relação às limitações, nota-se uma necessidade de aprimoramento nas estimativas da estrutura proposta, inserindo novas análises geométricas e conjuntos de treinamento na RNC para aprimorar a acurácia e precisão, apesar dos resultados serem considerados adequados ao processo. O desenvolvimento em questão, baseia-se em um conhecimento básico de elementos planos. Nesse ponto, é útil adaptar o algoritmo para reconhecer estruturas curvas, aprimorar a agregação de elementos de conexão (janelas e portas), além do processo para estimar a conectividade de subespaços.

6.4 CONCLUSÕES E RECOMENDAÇÕES DO CAPÍTULO


Neste Capítulo, um processo de agregação pontual baseado em AM foi aplicado para determinar agregados pontuais rotulados, ou seja, agregação com definição de semântica a um conjunto de pontos que representa alguns elementos presentes em ambientes internos. O algoritmo permite agrupar pontos pertencentes a partes estruturais da edificação, como paredes, piso, teto, janelas e portas. Além de agregar conjunto de pontos, uma primeira organização estrutural da nuvem de pontos LiDAR a partir da estimativa de semântica, superando dois dos principais desafios elencados no Capítulo 1: distribuição aleatória e ausência de semântica. O algoritmo é baseado na biblioteca computacional Python 3, MikowskiEngine, executado em uma estrutura ResNet, em que se analisa a similaridade do conjunto de treinamento, considerando a estimativa de vetores normais, e os compara com o conjunto que se deseja agregar, com assinaturas geométricas específicas. No contexto desse trabalho, como se interessa na representação 3D do espaço, a agregação completa consiste na estimativa de planos empregando o algoritmo RANSAC.

Observa-se que o método apresenta bom desempenho para estimativas de feições planas (pisos, tetos e paredes), além de móveis como cadeiras, mesas e armários. É necessário o seu aprimoramento em pesquisas futuras para que possibilite a identificação de outros itens, além de adaptá-lo para prever estruturas construtivas que não tenham padrão plano. Os elementos de mobiliário das nuvens de pontos LiDAR também podem ser aplicados em trabalhos futuros, como por exemplo na estimativa de simbolização 3D para objetos em ambientes internos.

CAPÍTULO 7 - AGREGAÇÃO DE NUVEM DE PONTOS LIDAR EM SUBESPAÇOS

As estratégias de generalização de nuvem de pontos incluem, em maioria, operações de simplificação. Posteriormente, ainda é necessário interpretar efetivamente o conjunto, representando-o geometricamente. No contexto do mapeamento 3D de ambientes internos a principal tarefa é a determinação de subespaços que componham um ambiente completo (FIGURA 50). A nuvem de pontos LiDAR é empregada como elemento geométrico e a partir de sua interpretação efetiva, realiza-se a definição de subespaços que definem um ambiente interno.

FIGURA 50 – IDENTIFICAÇÃO DE SUBESPAÇOS



FONTE: O autor (2022).

Neste aspecto, como apresentado no Capítulo 6, uma estratégia de agregação pode auxiliar, no entanto, mantendo o padrão de distribuição representativo do grupo de recursos original. No caso 2D, a agregação é aplicada para minimizar a distribuição representativa mantendo a estrutura espacial de visualização (SESTER, et al. 2018). No contexto 3D, é necessário agrupar um conjunto de entidades semelhantes para formar uma única. Portanto, aqui, o foco é aplicar um processo de agregação 3D de pontos em subespaços, considerando o domínio *indoor*.

Ao agregar um conjunto de pontos em um subespaço algumas questões devem ser consideradas e, além das restrições impostas ao 2D, necessita-se de restrições adicionais devido a terceira dimensão. A principal tarefa, então, é considerar um ambiente interno como um conjunto de primitivas geométricas (primitivas planas) que formam uma geometria completa. A estratégia aplicada neste Capítulo foi baseada na visão de Paul Cézanne (pintor francês pós-impressionista) que introduziu em suas obras distorções formais e alterações de perspectiva em benefício da composição.

Cézanne buscava simplificar as feições em suas formas geométricas essenciais, em suas palavras isto era possível porque *“a natureza segundo suas formas fundamentais pode ser interpretada por meio de cilindros, esferas, cones, tudo colocado em uma perspectiva adequada”*, denominado este processo como método de modulação, que pode ser interpretado como uma operação geométrica aplicada sobre dados que produz um sinal apropriado para transmissão. Esta percepção inserida por Cézanne vem aplicada na computação gráfica (CG) em que um objeto pode ser concebido ou estimado a partir de um conjunto de primitivas geométricas volumétricas.

Uma das motivações é o que se denomina de **parcimônia de descrição** (TULSIANI et al., 2018), ou seja, um objeto pode ser descrito por formas geométricas generalizadas, que requerem poucos parâmetros. No contexto de ambientes internos a edificações, isto consiste em modelar dados de entrada a partir de operações que produzam subespaços agregados para a representação de um determinado espaço completo. Nesse processo, a partir da inserção de uma nuvem de pontos LiDAR simplificada e ausência de ruídos, busca-se estimar as formas geométricas de subespaços para formalizar computacionalmente a definição de um espaço interno: um conjunto de subespaços, limitados verticalmente e que apresentam aspectos de adjacência e conectividade.

A teoria desenvolvida por Cézanne é aplicada no contexto cognitivo humano, que a partir de experiências e concepções de geometria é possível associar intuitivamente uma figura geométrica com um elemento natural do mundo real. No entanto, quando se trabalha no âmbito computacional este processo apresenta limitações, devido aos computadores, mesmo com o desenvolvimento tecnológico, não possuem a mesma eficiência cognitiva humana. A principal característica do sistema é permitir que um algoritmo computacional identifique as primitivas que compõem um subespaço, permitindo-lhe decidir se ele corresponderá a uma determinada superfície. Com isso, a configuração de uma primitiva geométrica é inferida, estimando sua adequação a um subespaço correspondente de destino.

Com base na parcimônia da descrição o foco deste Capítulo é propor uma abordagem para agregar um conjunto de pontos rotulados para geração de subespaços internos a partir de um processo orientado a dados que empregam primitivas geométricas extraídas a partir da aplicação da HN centrada em nuvem de pontos LiDAR. Nesse caso, busca-se responder os seguintes questionamentos: como a parcimônia da descrição relacionam-se com a HN centrada em nuvem de pontos LiDAR e podem ser empregadas na agregação de subespaços? Os seguintes aspectos são introduzidos nesse Capítulo: 1) Um fluxo metodológico baseado na HN centrada em nuvem de pontos LiDAR para geração de um subespaço e; 2) A aplicação de um

operado de generalização 3D de nuvem de pontos LiDAR para ambientes internos baseado na parcimônia da descrição.

7.1 PROCESSOS METODOLÓGICOS E IMPLEMENTAÇÃO

O processo metodológico refere-se a uma continuação dos resultados obtidos no Capítulo 6. Ou seja, a partir de uma nuvem de pontos simplificada, agregada em agrupamentos pontuais vide rótulos pré-estabelecidos, separação de elementos estruturais e estimativas de feições planares verticais e horizontais, busca-se implementar uma solução de parametrização de um subespaço completo baseado na parcimônia da descrição. Foi empregada a linguagem de programação C++ e bibliotecas computacionais *open-source*, principal foi a *Computational Geometry Algorithms Library* (CGAL). Os testes foram executados no ambiente *Google Colaboratory*.

7.1.1 MÉTODO


A determinação de subespaços a partir de uma nuvem de pontos equivale a gerar uma superfície completa e plausível que se aproxima do conjunto de pontos de entrada. Quando, previamente não interpretada e ajustada, muitas superfícies são passíveis de definição, gerando inconsistências e retrabalhos. Uma gama de abordagens tem sido proposta para resolver esses problemas. Geralmente são aplicadas no mapeamento de pequenos objetos, que apesar de apresentarem complexidade geométrica são menos complexos que ambientes internos reais (presença de ruídos e oclusões causadas pelo mobiliário e configuração espacial dos subespaços). Nesse âmbito, a partir da consideração de uma nuvem de pontos LiDAR previamente interpretada e agrupada conforme feições planares (Capítulo 6), aplica-se um método computacional de interpretação geométrica que possibilita definir formas e aspectos topológicos de adjacência e conectividade entre os elementos construtivos que compõem um subespaço completo.

7.1.1.1 Definição do algoritmo

O presente algoritmo é uma coleção de métodos para a formação de polígonos consistentes a partir de um conjunto de pontos previamente ajustados. Para a execução dessa tarefa o fluxo metodológico apresentado na FIGURA 51 foi proposto. Esse Capítulo é a finalização da análise da HN centrada em nuvem de pontos LiDAR. Primeiramente, insere-se

uma nuvem de pontos LiDAR bruta do ambiente perfilado que será interpretado -FIGURA 51(a) -. Posteriormente, aspectos relacionados a redundância devem ser analisados (Capítulo 4 e Capítulo 5), FIGURA 51(b).

FIGURA 51 – FLUXO (a) NUVEM DE PONTOS LiDAR BRUTA (b) PROCESSO DE SIMPLIFICAÇÃO (c) DETERMINAÇÃO DE AGREGADOS PONTUAIS CONFORME RÓTULOS (d) ESTIMATIVA DE PLANOS (e) CORREÇÕES (f) OTIMIZAÇÃO



FONTE: O autor (2022).

A partir disto é possível a aplicação de estratégias de interpretação da nuvem de pontos LiDAR para posteriormente determinar agregados pontuais - FIGURA 51(c)-. No caso de representação 3D de ambientes internos, considerando a estimativa de subespaços, é necessário identificar e agregar um conjunto de pontos em relação a planos horizontais e verticais - FIGURA 51(d) -. Agora em diante (estratégias descritas nesse Capítulo), emprega-se critérios para minimização de erros remanescentes, como eliminação de pontos espúrios - pontos em vermelho FIGURA 51(e) - e correção de buracos devido a existência de oclusões. Em seguida, um processo de otimização é aplicado para estimar superfícies parametrizadas (7.1.1.2), aspectos topológicos de adjacência (7.1.1.3) e de continuidade, como descrito na Subseção 7.1.1.4 - FIGURA 51(f) -. O processo metodológico empregado nesse Capítulo é baseado em Liangliang e Wonka (2017), algoritmo PolyFit.

7.1.1.2 Remoção de pontos espúrios e minimização de oclusões

A definição de subespaços, para o LoD1 e LoD2, recai sobre um problema de processamento geométrico, ou seja, a partir de uma nuvem de pontos LiDAR e algoritmos computacionais que explorem a HN centrada em nuvem de pontos LiDAR se define modelos geometricamente consistidos. Nesse caso, como já mencionado no Capítulo 3, o algoritmo pode ser considerado como a formalização da representação 3D em ambientes computacionais. Logo, o algoritmo representa a ação e a definição da geometria do objeto de estudo. Considerando esses aspectos, a partir de um processo de formalização algorítmica, objetivou-se a

representação de subespaços por meio da definição de representações paramétricas, obtidas e definidas por funções de parametrização implícitas (ou volumétricas). As superfícies parametrizadas (S), então, são estimadas como um valor escalar igual a 0 baseado na função $F: R^3 \rightarrow R$, i.e., $S = x \in R^3 | F(x) = 0$. Nesse processo, considerou-se que cada plano estimado pelo algoritmo RANSAC pode ser representado por faces (modelos 3D) planas que podem ser definidas como um conjunto de triângulos orientados unidos por arestas em comum.

Logo, uma superfície S seja modelada de forma consistente é importante a análise de aspectos topológicos. Para isso, considera-se que os segmentos planares detectados pelo algoritmo RANSAC podem conter elementos indesejáveis como pontos espúrios e áreas oclusas. Neste caso, foi necessário analisar a distribuição dos pontos para eliminar dados ruidosos que não refletem os objetos de interesse para a representação. Este processo é relevante devido as edificações apresentarem regiões reflexivas (metais, espelhos) e transparentes (vidros), as quais, devido às suas características físicas, não refletem adequadamente ao perfilamento, fator que insere leituras errôneas ao conjunto de dados. Para a remoção de dados ruidosos, aplicou-se o algoritmo desenvolvido por Rusu; Cousins (2011), *Statistical Outliers Remove* (SOR), em cada plano agregado e rotulado como uma estrutura vertical e ou horizontal.

Considera-se como um subespaço, uma geometria que contém planos verticais e horizontais que apresentam aspectos de adjacência sem a presença de buracos. Nesse caso, após a remoção de pontos espúrios, determinou-se uma caixa delimitadora ampliada sobre a nuvem de pontos LiDAR, e então estima-se as interseções no encontro entre planos verticais e horizontais para determinação de faces de objetos (FIGURA 52, linha em preto).

FIGURA 52 – RELACIONAMENTO TOPOLÓGICO (a) NUVEM DE PONTOS LiDAR (b) PLANOS ADJACENTES



FONTE: O autor (2022).

Esse processo é formulado com base em um problema de programação linear, como apresentado na Subseção 7.1.1.3.

7.1.1.3 Definição de fases e superfícies paramétricas

Para a confecção de um subespaço qualquer considera que os seus elementos de base (planos verticais e horizontais) formam faces, ou seja, superfícies completamente fechadas e modeladas geometricamente. Logo, dado uma nuvem de pontos LiDAR inicial é possível estimar N faces candidatas $F = \{f_i | 1 \leq i \leq N\}$, que a partir da aplicação de uma função energia é possível otimizar uma variável x_i para codificar uma face candidata f_i ($x_i = 1$) ou eliminá-la do processo ($x_i = 0$). Para definir essa face, primeiramente, avalia-se o intervalo de confiança de pontos que contribuem efetivamente para a reconstrução 3D, a partir da EQUAÇÃO 15 (LIANGLIANG; WONKA, 2017).

$$E = \frac{1}{|P|} - \sum_{i=1}^N x_i \cdot support(f_i) \quad (15)$$

Em que $|P|$ é o número total de pontos em um conjunto de planos horizontais e verticais e $support(f_i)$ representa a confiança da contribuição efetiva de um ponto para a estimativa de uma superfície plana em relação a sua vizinhança local, conforme EQUAÇÃO 16.


$$support(f) = \sum_{p, f | dist(p, f) < \varepsilon} \left(1 - \frac{dist(p, f)}{\varepsilon} \right) \cdot conf(p), \quad (16)$$

Em que $dist(p, f)$ é a medida da distância euclidiana entre um ponto p e uma face (plano geometricamente consistido) f . Considera-se para cada ponto um limiar ε entre o ponto e a face candidata, isto é, $dist(p, f) < \varepsilon$. O termo $conf(p)$ mede a qualidade local da nuvem de pontos LiDAR em um ponto específico a partir do cálculo de uma matriz de covariância local definida em p , empregando os autovalores ($\lambda_1 \leq \lambda_2 \leq \lambda_3$). Esse processo de ajuste favorece a escolha de geometrias próximas aos pontos amostrais de entrada. Nesse caso, um conjunto de pontos com ausências de ruídos recebe um valor igual a 1, sendo considerado uma boa amostra para estimar planos que comporá o subespaço.

Considerando que um conjunto de pontos que formam elementos estruturais horizontais e verticais apresentam áreas oclusas (buracos – FIGURA 53) é necessário a

compilação de um método que permita a minimização de erros. Introduce-se, então, uma função de complexidade.

FIGURA 53 – ÁREAS OCLUSAS (a) VISÃO FRONTAL (b) VISÃO LATERAL



FONTE: O autor (2022).

Logo, as lacunas existentes resultam em arestas adicionais, calculadas conforme EQUAÇÃO 17 que representa um modelo matemático de complexidade $E(m)$ (LIANGLIANG; WONKA, 2017). Em que $|E|$ representa o número total de interações para a determinação de um plano candidato e a função $.aresta(a_i)$ é um indicador cujo valor é determinado pela configuração de pelo menos duas geometrias conectadas em uma determinada aresta. Para gerar um subespaço completo considera-se aspectos topológicos de adjacência e interseção entre planos vizinhos, classificados em planares ou ponto de borda, sobre os quais se contém feições planas coplanares.

$$E(m) = \frac{1}{|E|} - \sum_{i=1}^{|E|} aresta(a_i) \quad (17)$$

Para lidar com dados ausentes causados pelas oclusões, as regiões não cobertas por pontos devem ser as menores possíveis. Para a realização dessa medida em uma determinada geometria, projeta-se todos os pontos pertencentes a um plano em relação a f_i , em seguida, extrai-se uma malha M , construindo uma forma α 2D a partir dos pontos projetados. Nesse caso, busca-se que quaisquer três pontos com raio circunscrito $rc \leq \sqrt{\alpha}$ sejam percorridos por uma geometria triangular. Assim, a função de energia Ec que define uma geometria plana em decorrência de um agregado de pontos é dada pela EQUAÇÃO 18.

$$Ec = \frac{1}{area(M)} - \sum_{i=1}^N x_i \cdot (area(f_i) - area(M_i^\alpha)), \quad (18)$$

Em que, $area(M)$, $area(f_i)$ e $area(M_i^\alpha)$ denotam as áreas da superfície final, a geometria candidata f_i e do modelo geométrico M_i^α de f_i , respectivamente. A partir disto é possível definir uma função energia de otimização, conforme Subseção 7.1.1.4.

7.1.1.4 Otimização

A partir do conjunto de faces obtidos em 7.1.1.3, o conjunto de geometrias ótimo para modelar um subespaço pode ser obtido minimizando a soma ponderada desses termos sobre certas restrições, conforme EQUAÇÃO 19.


$$\begin{aligned} \min & \lambda_f \cdot E_f + \lambda_m \cdot E_m + \lambda_c \cdot E_c \\ \text{s.t.} & \begin{cases} \sum_{j \in N(e_i)} x_j = 2 \text{ ou } 0 & 1 \leq i \leq |E| \\ x_i \in \{0,1\}, & 1 \leq i \leq N \end{cases} \end{aligned} \quad (19)$$

Em que $\sum_{j \in N(e_i)} x_j$ contém o número de faces conectadas por uma aresta e_i . Esse valor é forçado a ser igual a 0 ou 2, significando que nenhuma ou pelo menos duas geometrias planas coplanares são selecionadas. Essa restrição garante que o subespaço gerado seja completamente fechado (compatível com o LoD2). O problema da EQUAÇÃO 18 é um problema de programação linear binário, resolvido por Liangliang e Wonka (2017). Os resultados e discussões são apresentados na Subseção 7.2.

7.2 RESULTADOS E DISCUSSÕES

A partir do fluxo metodológico descrito se buscou alcançar o último objetivo específico listado neste trabalho, a compilação de subespaços completos. Observa-se na FIGURA 54, que o processo de construção de um subespaço no LoD2 inicia-se na estimativa de feições planas verticais e horizontais, as quais são dados de entrada para a compilação das funções energias descritas na Subseção 7.1.1.3 e determinação de geometrias planas candidatas. A principal vantagem do processo é a minimização da influência de áreas oclusas em cada subespaço perfilado.


FIGURA 54 – ELEMENTOS ESTRUTURAIS AGREGADOS (HORIZONTIAS E VERTICAIS) E DEFINIÇÃO DE PLANOS CANDIADOS



FONTE: O autor (2022).

Os conjuntos II e III, por exemplo, são subespaços problemáticos, devido às grandes áreas de oclusões (ocasionado pela presença de mobiliário), entretanto, o algoritmo conseguiu estimar uma caixa delimitadora de forma eficiente e estimar geometrias candidatas de forma correta. Isso se dá devido à possibilidade de exploração da HN centrada em nuvem de pontos LiDAR, uma vez que todos os parâmetros geométricos são determinados com base em aspectos matemáticos e geométricos da distribuição de um ponto e sua vizinhança imediata. Após a determinação das geometrias planas candidatas e sua otimização, alcançaram-se os resultados apresentados na FIGURA 55.


FIGURA 55 – DEFINIÇÃO DE SUBESPAÇOS (a) CONJUNTO I (b) CONJUNTO II (c) CONJUNTO III (d) CONJUNTO IV (e) CONJUNTO V (f) CONJUNTO VI



FONTE: O autor (2022).

Todos os subespaços foram gerados de forma satisfatória. Sendo representados com rigidez geométrica. Na FIGURA 55(a) e FIGURA 55(f), os subespaços foram generalizados conforme cuboides simples, sendo que detalhes arquitetônicos fossem negligenciados. Entretanto, nos demais subespaços (FIGURA 55(b), 56(c), 56(d) e 56(e)) as características geométricas foram completamente modeladas, inclusive áreas de oclusões. As nuvens de pontos LiDAR interpretadas e preliminarmente processadas, a partir da aplicação do algoritmo de compilação de subespaços, foi possível agregar planos formados por conjuntos de pontos em superfícies, todavia, preservando a HN centrada em nuvem de pontos LiDAR. Esse fato pode ser observado na FIGURA 56.

FIGURA 56– HN CENTRADA EM NUVEM DE PONTOS LiDAR E COMPILAÇÃO DE SUBESPAÇOS (a) CONFIGURAÇÃO VETORES NORMAIS (b) SUBESPAÇO




FONTE: O autor (2022).

Na FIGURA 56(a) ilustra a manutenção da direção e orientação de vetores normais. As linhas em azul representam a direção do vetor normal relacionado a cada plano identificado e que forma uma superfície plana completa. Aqui, retorna-se ao conceito original da geometria fractal (Capítulo 4) e similaridade (Capítulo 6), respectivamente: 1) Uma superfície pode ser vista como uma réplica do todo e são autos similares e; 2) o todo é maior que a soma de suas partes. Nas arestas, pontos de encontro entre as superfícies planas estimadas, observa-se vetores normais em direções opostas (linhas em vermelho) que permitem a identificação da ligação entre os componentes para formar um subespaço completo (FIGURA 56b).

Nesse caso, alcança-se uma composição de um subespaço. A partir de uma nuvem de pontos LiDAR simplificada e semantizada foram obtidas feições geométricas essenciais interpretadas como planos verticais e horizontais em um processo de modelagem apropriado para transmitir o entendimento do espaço físico para o meio computacional. A partir da agregação de planos é possível a gerar uma superfície completa, estimando subespaços que componham uma edificação a partir da parcimônia da descrição, conforme Tulsiani et al. (2018), ou seja, um subespaço pode ser modelado por formas geométricas generalizadas, que requerem poucos parâmetros. Nesse caso, foi possível modular dados de entrada a partir de operações baseadas na HN centrada em nuvem de pontos LiDAR para produzir subespaços agregados que podem ser combinados para representar um ambiente interno completo.

Apesar dos resultados serem satisfatórios, o processo considera basicamente superfícies planas. Construções complexas que apresentam aspectos arredondados ou cúpulas não foram empregadas. Por tanto, a principal limitação do processo é a consideração de apenas elementos planos. Melhorias nessas questões devem ser implementadas, entretanto, o processo apresenta resultados significativas quando comparado com métodos tradicionais Poisson (KAZHADAN; BOLITHO; HOPPE, 2006) e baseado em triangulação (SÉBASTIN et al., 2022) (FIGURA 57).


FIGURA 57 – CONSTRUÇÃO DE SUBESPAÇOS (a) METODOLOGIA (b) POISSON (c) TRIANGULAÇÃO



FONTE: O autor (2022).

Nos três processos comparados, a metodologia aplicada para a construção de subespaços apresentou resultados superiores, uma vez que permite a definição de superfícies com ausência de buracos e modelagem correta das dimensões do espaço perfilado, apesar de inserir níveis de generalização na forma. Todavia é o subespaço que permite estimar grandezas métricas com confiabilidade, por modelar os encontros de cada subparte de um subespaço de forma satisfatória. Os demais processos apresentam limitações em decorrência da existência de oclusões, conforme destacado na FIGURA 58.

FIGURA 58 – INFLUÊNCIA DE ÁREAS E OCLUSÕES (a) METODOLOGIA (b) POISSON (c) TRIANGULAÇÃO



FONTE: O autor (2022).

Para analisar os resultados quantitativamente, seria necessário a obtenção de medidas em campo e posteriormente confrontá-las com aquelas realizadas em ambiente computacional. Entretanto, essas informações não estão disponíveis para o conjunto de dados aplicado nesse trabalho. Para processos futuros, recomenda-se a aquisição de informações métricas sobre o ambiente perfilado e posteriormente análise quantitativa dos resultados.

7.2.1 Discussões


A partir dos resultados apresentados nessa seção, foram realizadas discussões gerais acerca da qualidade do processo, suas vantagens e melhorias que deverão ser implementadas. Em primeiro lugar, o método, por empregar uma biblioteca computacional que traz funções complexas previamente definidas, é de implementação relativamente simples quando comparado com algoritmos tradicionais que necessitam de definição matemáticas e lógicas específicas. Uma plataforma cliente-servidor estruturada pode ser aplicada para o processamento o que minimiza a necessidade de aquisição de hardware e software específicos que demandam um investimento monetário elevado.

A segunda vantagem está relacionada com a possibilidade de adaptação do algoritmo e emprego em diversas edificações com formatos variados. Em terceiro lugar, a abordagem resulta em resultados aceitáveis para aplicações que requerem estimar elementos estruturais e apresentam aspectos importantes de construções, sendo um processo de entrada para representar tridimensionalmente edificações considerando preceitos da IndoorGML ou IFC, quando considerando aspectos BIM. Em relação ao tempo, para ambientes isolados fornece desempenho adequado. Após a modelagem do ambiente, observa-se que a partir da HN centrada em nuvem de pontos LiDAR alcança-se, a partir de operadores de generalização 3D, a minimização do custo de armazenamento e processamento, definição de semântica para um conjunto específico de pontos e estruturação do conjunto, passando de um contexto de distribuição aleatório e não ordenado para superfícies auto similares às reais.

A principal desvantagem do procedimento é a adoção de apenas superfícies planares. Geometrias mais complexas ainda deverão ser implementadas para aprimorar os operadores de generalização e resultados de subespaços agregados. O ideal é que cada processo implementado e descrito nos Capítulos anteriores, seja empregado como ferramentas encadeadas, como processos de generalização cartográfica e otimização para a construção de representações 3D de edificações. Processos de aprimoramento na representação e definição de conectividade entre subespaços podem ser implementados para permitir o cálculo e rotas ou execução de análises espaciais robustas.

Para analisar o processo aplicado em uma nuvem de pontos LiDAR de um ambiente completo, realizou um experimento extra (conjunto também aplicado no Capítulo 4 e 6), obtendo-se os resultados ilustrados na FIGURA 59.

FIGURA 59 –EDIFICAÇÃO (a) AGREGADOS PONTUAIS (b) SUBESPAÇO TÉRREO (c) SUBESPAÇO 1º ANDAR




FONTE: O autor (2022).

Pode-se observar que o objetivo geral do trabalho é alcançado, onde uma nuvem de pontos LiDAR bruta - FIGURA 59(a) - é transformada em subespaços agrupados. Esse conjunto

de dados em particular é complexo, pois, além de apresentar dois pavimentos o conjunto possuía muitas áreas de oclusões o que dificulta a modelagem completa. Na FIGURA 59(c), ilustra-se os subespaços que formam o ambiente completo. Nesse caso, cada subespaço deve ser segmentado anteriormente a aplicação do algoritmo de agregação. Caso contrário, o algoritmo formará um único sólido que compreenderá os limites da edificação e não suas subpartes, conforme ilustra-se para o pavimento térreo, FIGURA 59(b).

No software MeshLab foi possível verificar o detalhamento dos subespaços gerados. Na FIGURA 60(a), verifica-se externamente o detalhamento do encontro entre os subespaços (superfícies paramétricas).

FIGURA 60 –FORMAÇÃO DE SUBESPAÇOS (a) VISÃO EXTERNA (b) VISÃO INTERNA



FONTE: O autor (2022).

A partir da manipulação dessas formas é possível identificar internamente a relação de conectividade entre os subespaços adjacentes - FIGURA 60(b) -. As linhas em verde representam a adjacência de cada parte do subespaço com o seu vizinho. Para aprimorar o processo, a automatização de identificação de subespaços que compõem uma edificação completa e a estimativa de conectividade entre espaços vizinhos deverá ser implementada. Além disso, relacionar os procedimentos com o contexto de armazenamento em BDG 3D devem ser investigados. Os principais aspectos relacionados ao processo descrito neste Capítulo são apresentados no QUADRO 8.

QUADRO 8 – CARACTERÍSTICAS DOS MÉTODOS DE PROCESSAMENTO DE NUVENS DE PONTOS LiDAR


Parâmetros	Descrição
Seleção	O parâmetro crucial para o sucesso da definição de subespaços é a detecção de planos verticais e horizontais, logo, a precisão da estimativa dos subespaços estão diretamente relacionados com a acurácia e precisão dos processos implementados e descritos no Capítulo 6. A principal vantagem da aplicação de um método baseado em AM é a separação e dados estruturais daqueles que representam mobiliários e objetos que permanecem no interior das edificações. O que define a qualidade desse processo é o treinamento da rede, quanto mais o treino e variedade de objetos que a rede reconhece, melhor serão as estimativas e separação de objetos não estruturais. Destaca-se que após a agregação pontual, conforme rótulos, é necessário a aplicação de processos de ajustes, como a eliminação de pontos espúrios e aplicação do algoritmo RANSAC para separar efetivamente os pontos que contribuem para estimar uma superfície. Para o conjunto amostral empregado neste trabalho, os parâmetros de entrada do algoritmo RANSAC empregado foram satisfatórios. Todavia, devem ser revisados em superfícies que apresentam detalhamentos arquitetônicos superiores.
Robustez	Qualidade e robustez da geração de subespaços é dependente da etapa de definição de agregados pontuais rotulados (Capítulo 6). A estimativa de superfícies completas depende da qualidade de estimativas de planos verticais e horizontais e é um processo influenciado pela presença de ruídos, densidade, precisão da etapa de registro de nuvem de pontos LiDAR. Pontos espúrios ou planos estimados de forma equivocada provocam o deslocamento dos elementos construtivos, o que gera uma geometria que não equivale a construção real. Esse problema ocorreu nos experimentos realizados (FIGURA 61). Nesse caso, observa-se que devido a presença de um plano oblíquo que corresponde a posição da escada houve um erro de estimativa de um dos subespaços, tendo uma geometria não equivalente ao real. Oclusões interferem nos resultados, entretanto, o processo apresenta resultados satisfatórios na presença desses problemas.
Limitações	Caso o subespaço não seja completamente modelado por paredes, teto e piso, o processo de agregação de subespaços não ocorrerá de forma adequada. Logo, o processo pode ser aplicado em ambientes indoor. Espaços intermediários deverão ser aprimorados. Além disso, aspectos relacionados ao formato da construção, como elementos curvos não são modelados pelo sistema, considera-se, nesse caso, apenas a formação de cuboides. Ademais, apesar de ser possível determiná-la em softwares específicos, a determinação de conectividade entre subespaços de forma automática é um elemento importante.

FONTE: O autor (2022).

A principal característica da abordagem é que ela permite entender as propriedades e relações dos elementos estruturais de uma construção. Fatores importantes para construir, manter e estudar temáticas como o BIM ou o mapeamento 3D. Isso permite desenvolver uma gama de tarefas de processamento e análises em softwares específicos. Permite uma

prototipagem rápida de grupos de elementos de construções semanticamente conhecidas. Além disso, as informações disponíveis também permitem consultas complexas para um subconjunto de elementos estruturais.

FIGURA 61 –PROBLEMAS (a) ERRO DE ESTIMATIVA (b) PLANO OBLÍQUO (ESCADA)



FONTE: O autor (2022).

As conclusões e recomendações do Capítulo são apresentadas na Seção 7.3 que segue.

7.3 CONCLUSÕES E RECOMENDAÇÕES DO CAPÍTULO

Neste Capítulo, apresentou-se um procedimento metodológico para definir subespaços de forma eficiente de forma a identificar e formar subespaços como superfícies paramétricas a partir de uma nuvem de pontos LiDAR. A viabilidade da abordagem é demonstrada em uma variedade de conjuntos de dados complexos do mundo real que devem ser processados, simplificados e interpretados para generalizar-se uma nuvem de pontos LiDAR de um ambiente interno de forma consistente. Observa-se que a composicionalidade de ambientes internos foi alcançada, a partir da análise de subpartes de elementos estruturais formar uma superfície paramétrica completa que representa um espaço real completo (parcimônia da descrição). No futuro, aspectos topológicos (relações de conectividade e adjacência entre subespaços) devem ser implementados. Ademais, superfícies complexas devem ser estudadas. É recomendado a adoção de procedimentos matemáticos que considerem superfícies quadráticas (esferas, cuboides, triângulos, toros, etc.) para possibilitar uma modelagem completa e eficiente de superfícies variadas.

No Capítulo 8 são apresentadas as conclusões e perspectivas futuras.

CAPÍTULO 8 - CONSIDERAÇÕES FINAIS

A generalização cartográfica 3D discutida neste trabalho auxilia na resolução de problemáticas relacionadas ao processamento e armazenamento de nuvem de pontos LiDAR. As implementações discutidas foram definidas a partir da consideração que as nuvens de pontos LiDAR fazem parte da LN, formando corpora geoespaciais 3D com repetibilidade estática e geométrica. Esses dois aspectos permitem, a partir da formalização de operadores de generalização por meio de algoritmos computacionais, revelar respostas e padrões. Isso possibilita explorar a HN centrada em nuvem de pontos LiDAR para estimar aspectos de autossimilaridade de forma automática. Além disso, devido compor um corpus 3D, nuvem de pontos LiDAR são dados passíveis de aplicação de estratégias de AM para interpretar e definir agregados pontuais por rotulação automática definida pelo algoritmo.

Como as nuvens de pontos LiDAR são dados complexos, optou-se por aplicar operadores de generalização complementares. Primeiramente, definiu-se um operador de generalização (Capítulo 4) para simplificar uma nuvem de pontos LiDAR, considerando que um ambiente interno forma uma geometria fractal, formada por subpartes que podem ser definidas e estimadas a partir da análise de similaridade de aspectos estatísticos e matemáticos. Nesse caso, demonstrou-se a necessidade da minimização da redundância da nuvem de pontos LiDAR, mas também, a importância de manter aspectos geométricos chave (pontos de borda), que minimizam erros em processos de modelagem futuros. Os mesmos princípios foram aplicados no Capítulo 5, entretanto, simplificando uma nuvem de pontos LiDAR a partir de uma RNC *autoencoder* que permite minimizar o número de pontos e comprimir um arquivo aplicando uma estratégia não supervisionada baseada na distância de distribuição dos pontos que compõem o conjunto. Ambos os processos demonstram a eficiência da exploração da HN centrada em nuvem de pontos LiDAR.

Como corpora geoespaciais 3D formados por nuvens de pontos LiDAR são complexos, apenas sua simplificação não permite seu uso efetivo, pois não apresentam semântica. Fator que os torna de difícil manipulação. Para contornar esse problema, a partir de uma nuvem de pontos LiDAR simplificada, optou-se por uma estratégia de agregação pontual baseada na rotulação de agregados pontuais, conforme objetos perfilados. Aqui, mais uma vez, explora-se a autossimilaridade em uma RNC para estimar a rotulação de cada ponto que forma uma nuvem de pontos LiDAR completa. O objetivo era reduzir o número de pontos e identificar subpartes que compunham um subespaço de um ambiente interno, considerando que

subespaços são formados por um conjunto de planos horizontais e verticais, compilando corpora geoespaciais 3D especializados para cada subespaço analisado (Capítulo 7).

Devido a áreas de oclusões e a erros de estimativa nos planos horizontais e verticais (que representa um forte fator para o sucesso do processo) empregou-se um método de otimização, para compilar subespaços completos com ausência de buracos. Aqui, foi explorada a parcimônia da descrição para generalizar subespaços, obtendo resultados satisfatórios.

Logo, considerando a questão: Como sistematizar corpora geoespaciais 3D formados por nuvens de pontos LiDAR de maneira que possam propiciar resultados úteis para a descrição e análise de ambientes internos como uma etapa introdutória na geração de mapas 3D de ambientes *indoor*? Conclui-se: os ambientes internos, principalmente construções modernas, apresentam em maioria geometrias planas, que se retem em diversos centros urbanos. Quando perfiladas por sensores fotogramétricos, forma-se para cada subespaço um corpus geoespacial 3D com dados brutos que necessitam de tratamento computacional. Este processo pode ser realizado a partir da exploração da HN para a formação de corpora geoespaciais 3D para estimar valores estatísticos e matemáticos que permitam generalizar corpora geoespaciais 3D gerais, simplificando-os e interpretando-os estatisticamente. Nesse caso, estratégias AM e a parcimônia da descrição auxiliaram como processos de interpretação e modelagem 3D de ambientes internos em uma operação geométrica. A qual é aplicada sobre corpora geoespaciais 3D de base para produzir um sinal apropriado, ou seja, a estimativa e visualização de um conjunto de primitivas geométricas 3D generalizadas que requerem poucos parâmetros, formando corpora geoespaciais 3D secundários a partir da interpretação do ambiente. Então, a aplicação dessas estratégias permite formalizar computacionalmente a definição de um subespaço permitindo a formação de corpora geoespacial 3D semantizados para ambientes internos.

Melhorias nos resultados podem ser implementadas, conforme tópicos apresentados na Subseção 8.1, que segue.

8.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

A determinação de funcionalidades e estrutura de aplicação de operadores de generalização 3D de nuvem de pontos LiDAR proposta neste trabalho apresentou resultados satisfatórios. Entretanto, desenvolvimentos futuros são requeridos para alcançar um nível de automatização, produtividade e interoperabilidade. As sugestões para pesquisas e aprofundamentos são listadas nos subtópicos que seguem:

- a) **Operadores de Generalização 3D:** os operadores de generalização 3D foram aplicados separadamente, no entanto, é interessante a implementação de pacotes que trabalhem de forma encadeada para obter superfícies paramétricas diretamente dos dados originais, sem a necessidade de geração de produtos intermediários e avaliações manuais. É interessante implementá-los considerando além de aspectos de processamento, mas também de armazenamento e usabilidade. A implementação de uma estrutura baseada em especializações de domínios é um processo de automatização relevante. A implementação de operadores de generalização 3D como módulos de análise de nuvem de pontos LiDAR para a extração de recursos automáticos até um subespaço generalizado reduz o tempo de processamento e retrabalhos. A concepção de um modelo conceitual de banco de dados geográfico 3D e a implementação de funcionalidades aproveita as funcionalidades de um SIG e amplia a aplicação de processamento e armazenamento.
- b) **Aprendizado de Máquina:** o refinamento das estimativas a partir de RNC é necessário. A agregação pontual de superfícies planas verticais e horizontais é uma tarefa essencial para a parametrização de superfícies. Logo, aumentar a acurácia e precisão do algoritmo é um processo importante. Além disso, os aspectos discutidos neste trabalho são restringidos a ambientes internos. Todavia, considerando a exploração de diferentes escalas e configurações de aquisição de nuvem de pontos LiDAR é importante definir estratégias que englobem ambientes externos para uma aplicação mais ampla.
- c) **Estruturas complexas:** neste trabalho, empregou-se apenas conjuntos de dados simples, com pouco ou nenhum detalhamento arquitetônico aprimorado. Certamente, atende a uma gama de edificações. Entretanto, para centros históricos e edifícios que apresentem estruturas complexas (planos inclinados, cúpulas etc.), a construção perfilada será demasiada simplificada para aspectos planos em decorrência de uma superfície plana (cuboide). Para contornar esse problema, algoritmos que considerem superfícies quadráticas podem auxiliar na parcimônia da descrição.
- d) **Aspectos topológicos:** a geração de subespaços considera apenas a conectividade entre planos verticais e horizontais. Porém, para alcançar uma representação efetiva e desenvolver aspectos de análise espacial entre subespaços é necessário identificar aberturas, como janelas e portas para definir conexões entre subespaços ou do ambiente interno com o externo. Este processo é importante para permitir uma das principais análises relacionadas a ambientes internos, o cálculo de rotas. Estruturas matemáticas denominadas de grafos podem auxiliar no processo para estimar relações topológicas entre subespaços adjacentes.

- e) **Modelagem geométrica de elementos não estruturais:** o presente trabalho considerou apenas elementos construtivos para formalizar geometricamente um subespaço. No entanto, modelar e simbolizar o mobiliário e objetos que estão presentes no interior das edificações são estratégias importantes a serem implementadas, principalmente no contexto de cálculo de rotas.

REFERÊNCIAS

- ALLAMANIS, Miltiadis; BARR, Earl T.; DEVANBU, Premkumar; SUTTON, Charles. A Survey of Machine Learning for Big Code and Naturalness. **Acm Computing Surveys**, [S.L.], v. 51, n. 4, p. 1-37, 31 jul. 2019. DOI: 10.1145/3212695.
- ARROYO OHORI, et al. Processing BIM na GIS models in practice: Experiences and Recommendations from a GeoBIM Project in the Netherlands. **ISPRS International Journal of Geo-information**, v. 7, n. 8, 2018. DOI: 10.3390/ijgi7080311
- ASGHARIAN, L.; EBRAHIMNEZHAD, H.. How many sample points are sufficient for 3D model surface representation and accurate mesh simplification? **Multimedia Tools And Applications**, [S.L.], v. 79, n. 39-40, p. 29595-29620, 12 ago. 2020. DOI: 10.1007/s11042-020-09395-3.
- BANASIK, P.; CHROBAK, T.; BIEGUN, B. Algorithm of automatic digital cartographic generalisation with the use of contractive self-mapping. **Polish Cartographical Review**, v. 54, n. 1, 2022. DOI: 10.2478/pcr-2022-0001
- BESL, P.; MCKAY, N. A Method for Registration of 3-D Shapes. **Trans. PAMI**, v. 14, n. 2, 1992
- BILJECKI, F.; et al. The variants of an LOD of a 3D building model and their influence on spatial analyses. **ISPRS Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 116, p. 42-54, jun. 2016. DOI: 10.1016/j.isprsjprs.2016.03.003.
- BELLO, Saifullahi Aminu; YU, Shangshu; WANG, Cheng; ADAM, Jibril Muhmmad; LI, Jonathan. Review: deep learning on 3d point clouds. **Remote Sensing**, [S.L.], v. 12, n. 11, p. 1729, 28 maio 2020. DOI: 10.3390/rs12111729.
- BRODEUR et al. Revisiting the Concept of Geospatial Data Interoperability Within the Scope of the Human Communication Processes. **Transactions in GIS**, v. 7, p. 243–265, 2003.
- BRASSEL, KURT E.; WEIBEL, ROBERT. A review and conceptual framework of automated map generalization. **International Journal of Geographical Information Systems**, v. 2, n 3, 229–244, 1988. :10.1080/02693798808927898
- CEBRYKOW, Paweł. Cartographic generalization yesterday and today. **Polish Cartographical Review**, [S.L.], v. 49, n. 1, p. 5-15, 1 mar. 2017. DOI: 10.1515/pcr-2017-0001.
- CECCHINI, C. From data to 3D digital archive: A GIS-BIM spatial database for the historical centre of Pavia (Italy). **Electronic Journal of Information Technology in Construction**, v. 24, p. 459-471. 2019
- CHEN, J.; CLARKE, K. C. Indoor cartography. **Cartography And Geographic Information Science**, [S.L.], v. 47, n. 2, p. 95-109, 27 jun. 2019. DOI: 10.1080/15230406.2019.1619482.
- CHEN, L.; LUO, H. A BIM-based construction quality management model and its applications. **Automation In Construction**, [S.L.], v. 46, p. 64-73, out. 2014. DOI: 10.1016/j.autcon.2014.05.009.

- COMÉ, S.; SLUTER, C. R. Uma proposição para detecção das condições geométricas em cartas topográficas de regiões urbanas na escala 1:10.000 derivadas de 1:2.000. **Revista Brasileira de Cartografia**, [S. l.], v. 67, n. 6, p. 1091 - 1102, 2015.
- COURTIAL, A. et al. Exploring the Potential of Deep Learning Segmentation for Mountain Roads Generalisation. **ISPRS International Journal Of Geo-Information**, [S.L.], v. 9, n. 5, p. 338, 25 maio 2020 DOI: 10.3390/ijgi9050338.
- DIAKITÉ, A. A.; ZLATANOVA, S.; LI, K.-J. ABOUT THE SUBDIVISION OF INDOOR SPACES IN INDOORGML. **ISPRS Annals Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, [S.L.], v. -4/5, p. 41-48, 23 out. 2017. DOI: 10.5194/isprs-annals-iv-4-w5-41-2017.
- DÖLLNER, J. Geospatial Artificial Intelligence: potentials of machine learning for 3d point clouds and geospatial digital twins. **Journal Of Photogrammetry, Remote Sensing And Geoinformation Science**, [S.L.], v. 88, n. 1, p. 15-24, fev. 2020. Springer Science and Business Media LLC. DOI: 10.1007/s41064-020-00102-3.
- DOUGLAS, D. H; PEUCKER, T. K. Algorithms for the ReGeneralization Constraintsduction of the Number of Points Required to Represent a Digitized Line or its Caricature. **The Canadian Cartographer**, v. 10, n. 2, p. 112–123, 1973.
- DUO, T.; ZHANG, P. Automatic Generalization of Residential Areas Based on “Paradigm” Theory and Big Data. **Computer Methods in medicine and Health Care**, p. 71–76, 2021. DOI. 10.3233/ATDE210244
- DOVRAT, O.; LANG, I.; AVIDAN, S. Learning to Sample. **Arxiv:1812.01659**, [S.L.], v. 2, n. 1, p. 1-16, dez. 2019. DOI: 10.48550/ARXIV.1812.01659.
- DYER, N.; KASTRISIOS, C.; DE FLORIANI, L. Label-based generalization of bathymetry data for hydrographic sounding selection. **Cartography and Geographic Information Science**, v. 0, n. 0, p. 1–16, 2022. DOI. 10.1080/15230406.2021.2014974
- EBRAHIMI, A.; CZARNUCH, S. Automatic Super-Surface Removal in Complex 3D Indoor Environments Using Iterative Region-Based RANSAC. **Sensors**, [S.L.], v. 21, n. 11, p. 3724, 27 maio 2021. MDPI AG. <http://dx.doi.org/10.3390/s21113724>
- ENSSLIN, L et al. ProKnow-C: **Processo de análise sistêmica**. Brasil: Processo técnico com patente de registro pendente junto ao Inuven de pontoI, 2010.
- ERVAN, O.; TEMELTAŞ, H. Downsampling of a 3D LiDAR Point Cloud by a Tensor Voting Based Method. 2019 **11th International Conference on Electrical and Electronics Engineering (ELECO)**. Anais IEEE. p.880–884, 2019.
- FENG, Y.; THIEMANN, F.; SESTER, M. Learning Cartographic Building Generalization with Deep Convolutional Neural Networks. **ISPRS International Journal Of Geo-Information**, [S.L.], v. 8, n. 6, p. 258, 30 maio 2019. DOI: 10.3390/ijgi8060258.
- FINATTO, J. M. B; LOPES, L.; CIULLA, A. Processamento de linguagem narual, Linguística de Corpus e Estudo Linguísticos: uma parceria bem sucedida. Domínios da Linguagem. [S.L.], v. 9, n. 5, p. 41-59, dez. 2015.
- FISCHLER, M., BOLLES, R., Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. **Communications of the ACM**. Vol 6(24), pp. 381–395, 1981.

- FIRKOWSKI, H. **Generalização cartográfica de grades retangulares regulares baseada na Teoria Matemática da Comunicação**. Tese (Doutorado em Geociências) Instituto de Ciências da Terra, Universidade Federal do Paraná, Curitiba. 2002
- FORBERG, A. Generalization of 3D building data based on a scale-space approach. *Isprs Journal Of Photogrammetry And Remote Sensing*, [S.L.], v. 62, n. 2, p. 104-111, jun. 2007. DOI: 10.1016/j.isprsjprs.2007.01.002.
- FU, X.; ZHANG, H.; WANG, P. Automatic Construction of Indoor 3D Navigation Graph from Crowdsourcing Trajectories. **ISPRS International Journal Of Geo-Information**, [S.L.], v. 10, n. 3, p. 146, 8 mar. 2021. DOI: 10.3390/ijgi10030146
- GAROFALO, S., G.; et al. Cognition and Spatial Concept Formation: comparing non-digital and digital instruction using three-dimensional models in science. **Technology, Knowledge And Learning**, [S.L.], v. 26, n. 1, p. 231-241, 5 out. 2019. DOI: 10.1007/s10758-019-09425-6.
- GENCARELLI, C. N.; et al. Geospatial Information Technologies for Mobile Collaborative Geological Mapping: The Italian CARG Project Case Study. **ISPRS International Journal of Geo-Information**, v. 11, n. 3, p. 192, 2022. DOI: 10.3390/ijgi11030192
- GRAÇA, S., A. J.; FIORI, S. R. Proposal for a tourist web map of the south area of rio: cartographic communication and the act of representing the landscape in different scales and levels of abstraction. **Revista Brasileira de Cartografia**, [S. l.], v. 67, n. 5, p. 1079-1190, 2015.
- GRÖBE, M., BURGHARDT, D. Scale-Dependent Point Selection Methods for Web Maps. **J. Cartogr. Geogr.** v.1, n. 71, p. 143–154, 2021. DOI: 10.1007/s42489-021-00079-y
- GRÖGER, G.; PLÜMER, L. CityGML – Interoperable semantic 3D city models. **ISPRS Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 71, p. 12-33, jul. 2012. DOI: 10.1016/j.isprsjprs.2012.04.004.
- HINDERINK, S.; MANDAD, M.; CAMPEN, M. Angle-bounded 2D mesh simplification. **Computer Aided Geometric Design**, [S.L.], v. 95, p. 102085, maio 2022. DOI: 10.1016/j.cagd.2022.102085.
- HINDLE, A.; et al. On the naturalness of software. **Communications Of The Acm**, [S.L.], v. 59, n. 5, p. 122-131, 2016. DOI: 10.1145/2902362.
- HOPPE, et al. Mesh optimization. **Proceedings Of The 20Th Annual Conference On Computer Graphics And Interactive Techniques**. Siggraph '93, [S.L.], p. 19-16, dez. 1993. DOI: 10.1145/166117.166119.
- HORNUNG, A., et al. OctoMap: an efficient probabilistic 3d mapping framework based on octrees. **Autonomous Robots**, [S.L.], v. 34, n. 3, p. 189-206, 7 fev. 2013. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10514-012-9321-0>.
- HUANG, L.; et al. OctSqueeze: Octree-Structured Entropy Model for LiDAR Compression. In: **Conference on Computer Vision and Pattern Recognition (CVPR)**, pp.1313–1323, May, 2020. DOI: 10.48550/arXiv.2005.07178
- HUBO, E.; et al. The Quantized kd-Tree: Efficient Ray Tracing of Compressed Point Clouds. In: **IEEE Symposium on Interactive Ray Tracing**, IEEE, pp. 105-113. 2006. DOI: 10.1109/RT.2006.280221.

- HUANG, M.; et al. An Efficient Encoding Voxel-Based Segmentation (EVBS) Algorithm Based on Fast Adjacent Voxel Search for Point Cloud Plane Segmentation. **Remote Sensing**, [S.L.], v. 11, n. 23, p. 2727, 20 nov. 2019. DOI: 10.3390/rs11232727.
- INTERNATIONAL CARTOGRAPHIC ASSOCIATION (ICA). **Multilingual Dictionary of Technical Terms in Cartography**. Wiedbaden, Franz Steiner Verlag, 1973.
- JANEČKA, Karel. Standardization supporting future smart cities – a case of BIM/GIS and 3D cadastre. **Geoscape**, [S.L.], v. 13, n. 2, p. 106-113, 1 dez. 2019. Walter de Gruyter DOI: 10.2478/geosc-2019-0010.
- JENNY, Bernhard. Terrain generalization with line integral convolution. **Cartography And Geographic Information Science**, [S.L.], v. 48, n. 1, p. 78-92, 29 out. 2020. DOI: 10.1080/15230406.2020.1833762.
- Ji, C.; LI, Y.; FAN, J.; LAN, S. A Novel Simplification Method for 3D Geometric Point Cloud Based on the Importance of Point. **IEEE Access**, [S.L.], v. 7, p. 129029-129042, 2019. Institute of Electrical and Electronics Engineers (IEEE). DOI: 10.1109/access.2019.2939684.
- JONES, C. B.; MARK WARE, J. Map generalization in the Web age. **International Journal of Geographical Information Science**, v. 19, n. 8, p. 859–870, 2005. DOI: 10.1080/13658810500161104
- KADA, M. Aggregation of 3D Buildings Using a Hybrid Data Approach. **Cartography And Geographic Information Science**, [S.L.], v. 38, n. 2, p. 153-160, jan. 2011. DOI: 10.1559/15230406382153.
- KANG, Hae-Kyong; LI, Ki-Joune. A Standard Indoor Spatial Data Model—OGC IndoorGML and Implementation Approaches. **ISPRS International Journal Of Geo-Information**, [S.L.], v. 6, n. 4, p. 116, 12 abr. 2017. DOI: 10.3390/ijgi6040116.
- KAZHADAN, M; BOLITHO, M; HOPPE, H. Poisson Surface reconstruction, Eurographics. 2006.
- KIM, J.; LI, K. Simplification of geometric objects in an indoor space. **ISPRS Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 147, p. 146-162, jan. 2019. DOI: 10.1016/j.isprsjprs.2018.11.017
- KOMARICHEV, A.; ZHONG, Z.; HUA, J. A-CNN: annularly convolutional neural networks on point clouds. **Arxiv:1904.08017 Search**, [S.L.], p. 1-16, abr. 2019. DOI: 10.48550/ARXIV.1904.08017.
- LANDRIEU, L.; SIMONOVSKY, M. Large-scale Point Cloud Semantic Segmentation with Superpoint Graphs. **Arxiv:1904.08017 Search**, [S.L.], p. 1-16, nov. 2017. DOI: 10.48550/ARXIV.1711.09869.
- LANG, I.; MANOR, A.; AVIDAN, S. Samplenet: differentiable point cloud sampling, **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**, pp. 7578–88.
- LEECH, G. Corpora and theories of linguistic performance. **SVARTVIK**. Directions in Corpus Linguistic. Proceedings of Nobel Symposium 82, New York, 1992 p. 105-127.
- LI, K. Indoor Space: a new notion of space. Web And Wireless Geographical Information Systems, [S.L.], p. 1-3, 2008. **Springer Berlin Heidelberg**. DOI: 10.1007/978-3-540-89903-7_1.

- LI, et al. Geometric structure simplification of 3D building models. **ISPRS Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 84, p. 100-113, out. 2013. DOI: 10.1016/j.isprsjprs.2013.07.006.
- LI, Z.; OPENSHAW, S. A Natural Principle for the Objective Generalization of Digital Maps. **Cartography And Geographic Information Systems**, [S.L.], v. 20, n. 1, p. 19-29, jan. 1993. Informa UK Limited. DOI: 10.1559/152304093782616779.
- LI, L.; et al. An Improved RANSAC for 3D Point Cloud Plane Segmentation Based on Normal Distribution Transformation Cells. **Remote Sensing**, [S.L.], v. 9, n. 5, p. 433, 3 maio 2017. DOI: 10.3390/rs9050433.
- LIU, T. et al. A Structure Landmark-Based Radio Signal Mapping Approach for Sustainable Indoor Localization. **Sustainability**, [S.L.], v. 13, n. 3, p. 1183, 23 jan. 2021. DOI: 10.3390/su13031183.
- LUO, N.; et al. KNN-based feature learning network for semantic segmentation of point cloud data. **Pattern Recognition Letters**, [S.L.], v. 152, p. 365-371, dez. 2021. Elsevier BV. DOI: 10.1016/j.patrec.2021.10.023.
- LV, C.; LIN, W.; ZHAO, B. Approximate Intrinsic Voxel Structure for Point Cloud Simplification. **Ieee Transactions On Image Processing**, [S.L.], v. 30, p. 7241-7255, 2021. DOI: 10.1109/tip.2021.3104174.
- MCMASTE, R. B.; SHEA, K. S. **Generalization in Digital Cartography**. 1^a ed. Association Amerriican Geography, 1992.
- MEMDUHOGLU, A.; BASARANER, M. An approach for multi-scale urban building data integration and enrichment through geometric matching and semantic web. **Cartography And Geographic Information Science**, [S.L.], v. 49, n. 1, p. 1-17, 2021. DOI: 10.1080/15230406.2021.1952108.
- MANDELBROI, B.B. **The Fractal Geometry of Nature**. *WH Freeman and Company*, New York, 1975.
- MOREHOUSE, S. **GIS-based map compilation and generalization. GIS and generalization:Methodology and practice**, GISDATA I. v. 1, p.278, 1995. London: Taylor & Francys.
- MORISON, J. L. A theoretical Framework for Cartographic Generalization with Emphasis on the Process of Symbolization. **International Yearbook of Cartography**, p. 115-127, 1974
- MORTARI, F.; et al. An indoor navigation model and its network extraction. **Applied Geomatics**, [S.L.], v. 11, n. 4, p. 413-427, 17 jun. 2019. DOI: 10.1007/s12518-019-00273-8.
- MULLER, J. C. **Generalization of Spatial Database. Geographyc Information Systems: Principals and applications**. 1^o ed, v. 1, 1991. New York: Logman Group.
- NEUVILLE, R.; et al. A Formalized 3D Geovisualization Illustrated to Selectivity Purpose of Virtual 3D City Model. **Isprs International Journal Of Geo-Information**, [S.L.], v. 7, n. 5, p. 194, 18 maio 2018. MDPI AG. <http://dx.doi.org/10.3390/ijgi7050194>.
- NI, H.; LIN, X.; ZHANG, J. Classification of ALS Point Cloud with Improved Point Cloud Segmentation and Random Forests. **Remote Sensing**, [S.L.], v. 9, n. 3, p. 288, 18 mar. 2017. DOI: 10.3390/rs9030288.

- NICKERSON, B. G; FREEMAN H. R. Development of a rule-based System for Automatic Map Generalization. **Proceedings, Second International Symposium on Spatial Data**, 1986, p. 537-556
- NIKOOHEMAT, S.; et al. Indoor 3D reconstruction from point clouds for optimal routing in complex buildings to support disaster management. **Automation In Construction**, [S.L.], v. 113, p. 103109, maio 2020. DOI: 10.1016/j.autcon.2020.103109.
- PAVAN, Nadisson Luis; SANTOS, Daniel Rodrigues dos. A Global Closed-Form Refinement for Consistent TLS Data Registration. **Ieee Geoscience And Remote Sensing Letters**, [S.L.], v. 14, n. 7, p. 1131-1135, jul. 2017. Institute of Electrical and Electronics Engineers (IEEE). DOI: 10.1109/lgrs.2017.2699940.
- PAULY, M., GROSS, M.; KOBELT, L.P. Efficient simplification of point-sampled surfaces, **IEEE Visualization**, pp. 1–8, 2002.
- POMBO, R. M.; DELAZARI, L. S. Automação dos operadores de agregação e deslocamento para a generalização cartográfica na representação de redes sociais. **Boletim de Ciências Geodésicas**, v. 20, n.1, p. 669–682, 2014. DOI. 10.1590/S1982-21702014000300038
- POUX, F. **The Smart Point Cloud: Structuring 3D intelligent point data**, 5. jun. 2019. Université de Liège, Liège, Belgique.
- QI, C. R.; et al. PointNet: deep learning on point sets for 3d classification and segmentation. **Arxiv:1612.00593**, [S.L.], v. 0, n. 0, p. 1-26, 2016. DOI: 10.48550/ARXIV.1612.00593.
- RATJSKI, L. Phenomene des points de generalization. In: K. Kirschbaum and K. H. Meine (editors), **International Yearbook of Cartography**, v. 7, p. 143–152, 1967.
- ROBERT, D.L.; et al. Learning Multi-View Aggregation In the Wild for Large-Scale 3D Semantic Segmentation. **arXiv 2022**, arXiv:2204.07548.
- ROBINSON, A.H.; MORRISON, J.L.; MUEHRCKE, P.C.; KIMERLING, A.J.; GUPTILL, S.C. **Elements of Cartography**. 6^a ed. New York: John Wiley & Sons, New York, 1995
- ROSA, J.L.G. **Fundamentos da Inteligência Artificial**. Rio de Janeiro: LTC, 2011
- SÁNCHEZ, A. **Corpus lingüístico del español contemporáneo: fundamentos, metodología y aplicaciones**. Sociedad General Española de Librería, 1995.
- SANTOS, D. R. dos; FREIMAN, F. P.; PAVAN, N. L. Global Refinement Of Terrestrial Laser Scanner Data Registration Using Weighted Sensor Poses. **The International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, [S.L.], v. -1, p. 121-125, 26 set. 2018. DOI: 10.5194/isprs-archives-xlii-1-121-2018.
- SARDINHA, T. B. Linguísticas de Corpus: histórico e problemática. **Delta: Documentação de Estudos em Linguística Teórica e Aplicada**, [S.L.], v. 16, n. 2, p. 323-367, 2000. FapUNIFESP (SciELO). DOI: 10.1590/s0102-44502000000200005.
- SÉBASTIEN et. al. Yaz. **Polygon mesh processing**. In CGAL User and Reference Manual. CGAL Editorial Board, 5.4 edition, 2022.
- RUSU, R.; COUSINS, S. 2011, 3D is here: Point Cloud Library (PCL). **IEEE International Conference on Robotics and Automation 2011 (ICRA 2011)**, pp. 1–4. DOI: 10.1109/ICRA.2011.5980567

- SARDINHA, B, T. **Linguística de Corpus**. Barueri, SP: Manole, 2004.
- SCHIEWE, Jochen. The need for disciplinarity, interdisciplinarity and scientific societies - the cartographic perspective. **Geo-Spatial Information Science**, [S.L.], v. 24, n. 1, p. 160-166, 2 jan. 2021. DOI: 10.1080/10095020.2020.1863748.
- SESTER, Monika. Cartographic generalization. **Journal Of Spatial Information Science**, [S.L.], v. 1, n. 21, p. 5-11, 21 dez. 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**, [S.L.], v. -4, p. 565-572, 19 set. 2018. DOI: 10.5194/isprs-archives-4-565-2018.
- STEWART, H. J. Cartographic Generalisation Some Concepts and Explanation. **Cartographica: The International Journal for Geographic Information and Geovisualization**, [S.L.], v. 11, n. 1, p. 1-50, 1 jun. 1974. DOI: 10.3138/u624-417u-054r-8674.
- SWISS SOCIETY OF CARTOGRAPHY (SSC). **Maps Graphics and Generalisation**. Cartographic Publication Series no 17, 2002.
- TANG, L.; et al. Fei. An application-driven LOD modeling paradigm for 3D building models. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 161, p. 194-207, mar. 2020. DOI: 10.1016/j.isprsjprs.2020.01.019.
- TAURA, T. A., et al. Generalização cartográfica das cartas do mapeamento urbano nas escalas 1: 2.000, 1. **Boletim de Ciências Geodésicas**, [S.L.], v. 16, n. 3, p. 386-402, set. 2010. DOI: 10.1590/s1982-21702010000300002.
- TÖPFER, F.; PILLEWIZER, W. The Principles of Selection. **The Cartographic Journal**, v. 3, n. 1, p. 10-16, 1966. DOI: 10.1179/caj.1966.3.1.10
- WANG, J. Z.; et al. Generalization of 3D linear building groups for 3D city modeling, **Proc. SPIE 6420, Geoinformatics 2006**:DOI: 10.1117/12.713276.
- WEINMANN, M.; JUTZI, B.; MALLET, C. Feature relevance assessment for the semantic interpretation of 3D point cloud data. **Isprs Annals Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, [S.L.], v. -5/2, n. 1, p. 313-318, 16 out. 2013. DOI: 10.5194/isprsannals-ii-5-w2-313-2013.
- WEIBEL, R. Amplified Intelligence and Rule-based Systems. **Map Generalization**, p. 172-186, London, 1991.
- XIA, et al. Automated semantic segmentation of bridge point cloud based on local descriptor and machine learning. **Automation In Construction**, [S.L.], v. 133, p. 103992, jan. 2022. DOI: 10.1016/j.autcon.2021.103992.
- 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**, [S.L.], v. 14, p. 2857-2885, 2021. DOI: 10.1109/jstars.2021.3060568.
- XU, S; et al. Plane Segmentation Based on the Optimal-Vector-Field in LiDAR Point Clouds. **Ieee Transactions On Pattern Analysis And Machine Intelligence**, [S.L.], v.

- 43, n. 11, p. 3991-4007, 1 nov. 2021. Institute of Electrical and Electronics Engineers (IEEE). DOI: 10.1109/tpami.2020.2994935.
- XUAN, W.; et al. A New Progressive Simplification Method for Point Cloud Using Local Entropy of Normal Angle. **Journal Of The Indian Society Of Remote Sensing**, [S.L.], v. 46, n. 4, p. 581-589, 1 dez. 2017. Springer Science and Business Media LLC. DOI: 10.1007/s12524-017-0730-6.
- XUE, F.; et al. BIM reconstruction from 3D point clouds: A semantic registration approach based on multimodal optimization and architectural design knowledge. **Advanced Engineering Informatics**, 42, 100965, 2019. DOI:10.1016/j.aei.2019.100965
- XUE, F.; et al. From LiDAR point cloud towards digital twin city: clustering city objects based on gestalt principles. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 167, p. 418-431, set. 2020. DOI: 10.1016/j.isprsjprs.2020.07.020.
- YAN, H.; WEIBEL, R. An algorithm for point cluster generalization based on the Voronoi diagram. **Computers & Geosciences**, [S.L.], v. 34, n. 8, p. 939-954, ago. 2008. DOI: 10.1016/j.cageo.2007.07.008.
- YAN, J.; et al. A generic space definition framework to support seamless indoor/outdoor navigation systems. **Transactions In Gis**, [S.L.], v. 23, n. 6, p. 1273-1295, 2 ago. 2019. DOI: 10.1111/tgis.12574.
- YING, S.; et al. 3D Space Shift from CityGML LoD3-Based Multiple Building Elements to a 3D Volumetric Object. **Isprs International Journal Of Geo-Information**, [S.L.], v. 6, n. 1, p. 17, 15 jan. 2017. DOI: 10.3390/ijgi6010017.
- YU, X.; et al. Risto. Predicting individual tree attributes from airborne laser point clouds based on the random forests technique. **ISPRS Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 66, n. 1, p. 28-37, jan. 2011. DOI: 10.1016/j.isprsjprs.2010.08.003.
- ZHANG, J.; WANG, J.; LI, H. Topology Conflict Detection Considering Incremental Updating of Multi-Scale Road Networks. **ISPRS International Journal of Geo-Information**, v. 10, n. 10, p. 655, 2021. DOI: 10.3390/ijgi10100655
- ZHOU, Q. Y., PARK, J.; KOLTUN, V. Open3D: A Modern Library for 3D Data Processing *ArXiv*, 2018. Disponível em: <https://arxiv.org/abs/1801.09847> Acesso em: jan. 2022.
- ZLATANOVA, S.; LIU, L.; SITHOLE, G.; ZHAO, J.; MORTARI, F. **Space subdivision for indoor applications**. Delf University Technology, 2014 p. 50
- ZOU, B.; QIU, H.; LU, Y. Point Cloud Reduction and Denoising Based on Optimized Downsampling and Bilateral Filtering. **IEEE Access**, [S.L.], v. 8, p. 136316-136326, 2020. DOI: 10.1109/access.2020.3011989.