

HANNAIMÉE DA FRAGA GONÇALVES

CLASSIFICAÇÃO AUTOMATIZADA DE NUVEM DE PONTOS 3D OBTIDA POR
LIDAR EM ÁREA URBANA

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

Orientadora: Nilcilene Medeiros das Graças

Coorientador: Daniel Camilo de Oliveira Duarte

VIÇOSA - MINAS GERAIS
2024

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

G635c
2024
Gonçalves, Hanna Aimée da Fraga, 1993-
Classificação automatizada de nuvem de pontos 3D obtida
por *LiDAR* área urbana / Hanna Aimée da Fraga Gonçalves. –
Viçosa, MG, 2024.

1 dissertação eletrônica (83 f.): il.

Inclui apêndices.

Orientador: Nilcilene das Graças Medeiros.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Engenharia Civil, 2024.

Referências bibliográficas: f. 77-81.

DOI: <https://doi.org/10.47328/ufvbbt.2024.178>

Modo de acesso: World Wide Web.

1. Solo urbano - Uso - Planejamento. 2. Mapeamento do
solo. 3. Planejamento urbano. I. Medeiros, Nilcilene das Graças,
1977-. II. Universidade Federal de Viçosa. Departamento de
Engenharia Civil. Programa de Pós-Graduação em Engenharia
Civil. III. Título.

CDD 22. ed. 711.4


HANNA AIMÉE DA FRAGA GONÇALVES

CLASSIFICAÇÃO AUTOMATIZADA DE NUVEM DE PONTOS 3D OBTIDA POR
LiDAR EM ÁREA URBANA


Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

APROVADA: 23 de fevereiro de 2024.

Assentimento:

Documento assinado digitalmente
 HANNA AIMÉE DA FRAGA GONÇALVES
Data: 14/03/2024 18:25:23-0300
Verifique em <https://validar.iti.gov.br>

Hanna Aimée da Fraga Gonçalves
Autora

Documento assinado digitalmente
 NILCILENE DAS GRACAS MEDEIROS
Data: 15/03/2024 11:10:37-0300
Verifique em <https://validar.iti.gov.br>

Nilcilene Medeiros das Graças
Orientadora

***Dedico a Deus, Maria, minha eterna Vó Luza,
meus Pais e a minha irmã...***

AGRADECIMENTOS

Agradeço do fundo do meu coração à Santíssima Trindade por me guiar e abençoar durante todo este percurso. À Maria, Mãe Celestial, agradeço pela inspiração e pela força divina que sempre me proporcionou.

Aos meus pais, José Roberto e Luciana Fraga, pilares na construção do alicerce dos meus valores, expresso minha gratidão pela dedicação, amor incondicional e apoio incessante ao longo desta jornada, sem vocês eu nada seria. À minha irmã, Rhava Isadora, agradeço pelos momentos de cumplicidade, risos e companheirismo que tornaram cada desafio mais leve. Não poderia deixar de lembrar e homenagear minha querida Vó Luza, pelo amor me dado em vida, pelo incentivo e encorajamento em buscar uma vida mais confortável, conquistar meus sonhos de forma honesta através dos estudos. Eu te amo, Vó.

Ao meu noivo Victor Costa, aos meus tios Luana, Liliana, Júnior, Douglas e familiares, minha gratidão pelo constante encorajamento e suporte, formando uma rede de apoio crucial para a minha trajetória. Agradeço por reconhecerem e acreditarem no meu potencial, por terem confiança em mim quando duvidei de mim mesmo. O incentivo constante e o apoio são essenciais. Não poderia deixar de mencionar as orações da tia Lili, lembrando-me que, como está escrito em Hebreus 10:37, "Porque ainda um pouquinho de tempo, e o que há de vir virá, e não tardará."

Aos meus professores, especialmente a Daniel Duarte e Nilcilene Medeiros, agradeço a orientação exemplar, incentivo constante e apoio fundamental para a realização desta missão. Suas contribuições foram além do ensino acadêmico, moldando meu crescimento pessoal e profissional.

Agradecer também aos parceiros e Instituições que contribuíram significativamente para o desenvolvimento deste projeto. Cada apoio e colaboração foram fundamentais para o sucesso do nosso trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Código de Financiamento 001. Contou também com o fomento da FAPEMIG pelo apoio financeiro, que foi essencial para viabilizar as etapas e a realização das pesquisas. À *Blue Marble Geographics*, desenvolvedora do programa Global Mapper Pro, e sua distribuidora exclusiva no Brasil e América Latina, a ENGESAT e Laurent Martin,

responsável pelo suporte técnico, expresse o meu reconhecimento pelo incentivo científico fornecido. A licença do *Software* comprovou o seu potencial em processo de informações espaciais, além disso, o suporte tecnológico e os recursos disponibilizados foram vitais para a análise de dados e a obtenção de resultados precisos.

Ao GENTE, pelo valioso apoio científico. E a Gestão Engenharia, representada pelo Engenheiro Agrimensor e Cartógrafo Matheus Vieira, expresse minha sincera gratidão pela colaboração dos dados, proporcionando insights valiosos e dados essenciais para o presente estudo.

Sou profundamente abençoada por Deus ao colocar pessoas tão especiais em minha vida, e expresse minha gratidão por compartilharem este caminho comigo. Agradeço por acreditarem no meu potencial, por me incentivarem nos momentos mais desafiadores e por sempre lembrarem que, com Deus ao meu lado, as possibilidades são infinitas. Minha trajetória até aqui foi enriquecida pela presença constante de uma rede familiar de apoio que tornou cada conquista mais significativa e cada desafio mais superável.

"Porque ainda um pouquinho de tempo, e o que há de vir virá, e não tardará."

(Hebreus 10:37)

RESUMO

FRAGA, Hanna Aimée da Fraga Gonçalves, M.Sc. Universidade Federal de Viçosa, fevereiro de 2024. **Classificação automatizada de nuvem de pontos 3D obtida por LiDAR em área urbana.** Orientadora: Nilcilene Medeiros das Graças. Coorientador: Daniel Camilo de Oliveira Duarte.

O mapeamento do uso e ocupação do solo de áreas urbanas é uma importante ferramenta para elaboração de Cadastro Territorial Multifinalitário (CTM), pois pode ser subsídio para tomada de decisão relacionadas ao Planejamento Urbano e a Gestão Territorial. Assim, este estudo tem como finalidade explorar as potencialidades da classificação automatizada de nuvem de pontos em uma área urbana em Município de médio porte, Viçosa – Minas Gerais. Para isso foram utilizados dados *Light Detection and Ranging (LiDAR)* e fotogramétricos obtidos por meio de Sistema de Aeronave Remotamente Pilotada (SARP). Os dados foram submetidos a diversos processamentos com uso de *Softwares* como o *ArcGIS* e *Global Mapper*, onde foi possível simular parâmetros geométricos como: tamanho da barra; desvio máximo; diferença máxima de altura; declividade máxima do terreno; largura máxima das edificações; resolução; altura mínima acima do solo; e, área mínima e máxima de ocupação no solo. Com isso foram determinadas classes de usos e ocupação do solo como solo exposto, construções e vegetação. A classificação foi validada de forma qualitativa e quantitativa por meio de um mapa de referência e de métricas de acurácia temática, como: Exatidão Global. Na fase de análise dos dados de referência foram identificadas distorções nas informações geradas pelo *LiDAR* e pela fotogramétricos, tendenciando ser fatores influentes no processamento final da classificação automatizada. Na validação do mapa de uso e ocupação do solo obteve-se uma acurácia de 81%, *Kappa* de 72% e ao avaliar a Variância do *Kappa* (0.0004), constatou-se que a classificação é melhor do que ao acaso. Assim, foi possível concluir que a simulação e teste de parâmetros geométricos é uma ferramenta eficaz para a classificação e que as métricas de validação são importantes ferramentas para determinar a qualidade dos produtos. Por fim, a abordagem tem potencial para contribuir para o Cadastro Territorial Multifinalitário e na Gestão Territorial, sendo uma valiosa ferramenta para o desenvolvimento de estratégias no Município de Viçosa - MG.

Palavras-chave: Uso e Ocupação; Mapeamento; CTM.

ABSTRACT

FRAGA, Hanna Aimée da Fraga Gonçalves, M.Sc. Universidade Federal de Viçosa, February de 2024. **Automated classification of 3D point cloud obtained by LiDAR in urban area.** Adviser: Nilcilene Medeiros das Graças. Co-advisers: Daniel Camilo de Oliveira Duarte.

The mapping of land use and land cover in urban areas is an important tool for the development of Multifunctional Territorial Register (MTR), as it can provide support for decision-making related to Urban Planning and Territorial Management. Thus, this study aims to explore the potential of automated point cloud classification in an urban area in a medium-sized municipality, Viçosa - Minas Gerais. For this purpose, Light Detection and Ranging (LiDAR) and photogrammetric data obtained through a Remotely Piloted Aircraft System (RPAS) were used. The data underwent various processing steps using software such as ArcGIS and Global Mapper, where it was possible to simulate geometric parameters such as: beam size; maximum deviation; maximum height difference; maximum terrain slope; maximum building width; resolution; minimum height above ground; and, minimum and maximum area of land occupation. This allowed for the determination of land use and land cover classes such as bare soil, buildings, and vegetation. The classification was validated qualitatively and quantitatively through a reference map and thematic accuracy metrics, such as Overall Accuracy. During the analysis of the reference data, distortions were identified in the information generated by LiDAR and photogrammetric data, which tended to be influential factors in the final processing of automated classification. In the validation of the land use and land cover map, an accuracy of 81%, a Kappa coefficient of 72%, and an evaluation of Kappa Variance (0.0004) were obtained, indicating that the classification is better than random. Thus, it was possible to conclude that the simulation and testing of geometric parameters are effective tools for classification, and that validation metrics are important tools for determining the quality of products. Finally, the approach has the potential to contribute to the Multifunctional Territorial Register and Territorial Management, being a valuable tool for the development of strategies in the municipality of Viçosa - MG.

Keywords: Land use and land cover; Mapping; CTM.

LISTA DE FIGURAS

Figura 1 - Componentes básicos do sistema <i>LiDAR</i>	25
Figura 2 - Sensor <i>LiDAR AlphaAir 450</i>	25
Figura 3 - Parâmetros de filtragem	27
Figura 4 - Exemplo de acurácia temática na classificação	31
Figura 5 - Estrutura da matriz de confusão	32
Figura 6 - Mapa da área de estudo.....	36
Figura 7 - Ortomosaico da área de estudos.....	38
Figura 8 - Fluxograma - pré-processamento.....	39
Figura 9 - Fluxograma - pós-processamento	41
Figura 10 - Distorção no ortomosaico na região Sul da cena	44
Figura 11 - Distorção no ortomosaico na região Noroeste da cena	45
Figura 12 - Distorção no ortomosaico - telhados	45
Figura 13 - Mapa da nuvem de pontos	46
Figura 14 - Mapa da nuvem de pontos - córrego.....	47
Figura 15 - Mapa da nuvem de pontos com falhas de oclusão.....	48
Figura 16 - Mapa da nuvem de pontos com falhas de registro	48
Figura 17 - Mapa com ortomosaico e nuvem de pontos 3D	49
Figura 18 - Perfil de rota	50
Figura 19 - Perfil de rota - vegetação	51
Figura 20 - <i>GCPs</i> em alvo natural	51
Figura 21 - Mapa com os pontos de controle.....	52
Figura 22 - Mapa de elevação	54
Figura 23 - Mapa com métrica da construção.....	56
Figura 24 - Mapa classificação solo e não solo	57
Figura 25 - Mapa classificação solo e não solo com o ortomosaico	58

Figura 26 - Mapa referencial.....	59
Figura 27 - Pontos críticos - solo	60
Figura 28 - Pontos eficazes - solo	60
Figura 29 - Antes x depois - classificação solo e não solo.....	61
Figura 30 - Parâmetros de filtragem - vegetação.....	63
Figura 31 - Altura da ocupação solo	64
Figura 32 - Árvores extraídas e polígonos de cobertura	65
Figura 33 - Mapa classificação final da nuvem de pontos	66
Figura 34 - Pontos críticos - edificações x vegetação.....	67
Figura 35 - Pontos eficazes - edificações e vegetação.....	68
Figura 36 - Antes x depois - classificação edificação e vegetação	69
Figura 37 - Modelos 3D classificado	73

LISTA DE QUADROS

Quadro 1 - Valores de referência para o coeficiente Kappa	33
---	----

LISTA DE TABELAS

Tabela 1 - Atributos vetoriais da nuvem de pontos 3D	55
Tabela 2 - Tabela com parâmetros - edificação e vegetação.....	62
Tabela 3 - Dados de classificação	70
Tabela 4 - Matriz de confusão	71
Tabela 5 - Cálculo da exatidão global e <i>Kappa</i>	72
Tabela 6 - Cálculo variância do <i>Kappa</i>	72

LISTA DE ABREVIATURAS E SIGLAS

ALS	<i>Airbone Laser Scanning</i>
ASPRS	<i>American Society for Photogrammetry and Remote Sensing</i>
CDGV	Conjunto de Dados Geoespaciais Vetoriais
CTM	Cadastro Territorial Multifinalitário
DJI	<i>Dà-Jiāng Innovation Science and Technology</i>
DSG	Diretoria de Serviço Geográfico
ET-CQDG	Norma de Especificação Técnica para Controle de Qualidade de Dados Espaciais
FN	<i>False Negative</i>
FP	<i>False Positive</i>
GCP	<i>Ground Point Control</i>
GENTE	Grupo de Engenharia para Gestão Territorial da UFV.
GNSS	<i>Global Navigation Satellite</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IDW	<i>Inverse Distance Weighted</i>
IMU	<i>Inertial Measure Unit</i>
INCRA	Instituto Nacional de Colonização e Reforma Agrária
ISO	<i>International Organization for Standardization</i>
LiDAR	<i>Light Detection and Ranging</i>
MDE	Modelos Digitais de Elevação
MDS	Modelo Digital de Superfície
MDT	Modelos Digitais de Terreno
NIR	<i>Near Infrared</i>
PDI	Processamento Digital de Imagens

<i>PPK</i>	<i>Post-Processing Kinematic</i>
PPP	Posicionamento por Ponto Preciso
RMSE	Erro Quadrático Médio
<i>RPA</i>	<i>Remotely Piloted Aircraft</i>
<i>RTK</i>	<i>Real Time Kinematic</i>
SARP	Sistema de Aeronave Remotamente Pilotada
SR	Sensoriamento Remoto
UFV	Universidade Federal de Viçosa
<i>VN</i>	<i>True Negative</i>
<i>VP</i>	<i>True Positive</i>

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Objetivo Geral	20
1.2	Objetivos Específicos	20
1.3	Justificativas	20
2	REVISÃO DE LITERATURA.....	22
2.1	Gestão Territorial e o Cadastro Territorial Multifinalitário	22
2.2	Sensoriamento Remoto.....	23
2.2.1	Sistema <i>LiDAR</i>	24
2.2.2	Classificação Nuvem de Pontos 3D	26
2.3	Análise da Qualidade	30
2.3.1	Acurácia Temática.....	30
3	MATERIAIS E MÉTODOS.....	36
3.1	Materiais.....	37
3.2	Metodologia.....	38
3.2.1	Pré-Processamento	38
3.2.2	Processamento	41
4	RESULTADOS E DISCUSSÕES	44
4.1	Análise dos Dados de Referência	44
4.2	Análise de Perfil de Rota	49
4.3	Calibração da Nuvem de Pontos.....	51
4.4	Classificação Solo e Não Solo	54
4.5	Classificação Edificação e Vegetação.....	62
4.6	Validação da Classificação.....	70
5	CONCLUSÕES	74
	REFERÊNCIAS BIBLIOGRÁFICAS	77

APÊNDICES.....	82
-----------------------	-----------

1 INTRODUÇÃO

A expansão populacional desordenada afeta diretamente o bem-estar social, ambiental e econômico do planeta. No contexto urbano, a problemática é ainda mais preocupante, de modo que são necessárias ferramentas de Planejamento Urbano e Gestão Territorial para subsidiar um progresso eficiente e sustentável das cidades (De Ramos Giacomini; Vuelma, 2020).

A Gestão Territorial é uma área interdisciplinar que envolve a coleta, análise e interpretação de dados geoespaciais para tomar decisões relacionadas ao uso da terra, ordenamento do território e desenvolvimento urbano. Amorim *et al.* (2018) destacam que a Gestão Territorial está intrinsecamente ligada à integração, envolvendo o conhecimento e o alinhamento do campo de atuação dos gestores. Isso é fundamental para orientar e fundamentar as tomadas de decisão, seguindo o princípio da democratização territorial.

Church e Murray (2009) destacam que a Gestão Territorial desempenha um papel importante na identificação de áreas de conflito de uso da terra e no desenvolvimento sustentável, pois à medida que as cidades crescem e as pressões sobre o ordenamento territorial são proporcionais, a Gestão Territorial torna-se uma área cada vez mais essencial para garantir um futuro equilibrado e harmonioso para sociedade.

Para subsidiar estas ações, tem-se o Cadastro Territorial Multifinalitário (CTM) como o inventário oficial e sistemático das parcelas do município, sendo associado a dados geométricos e cadastrais temáticos (Brasil, 2022). Amorim, *et al.* (2018), expõe que o CTM é um sistema de informações territoriais, tendo como orientação principal, a sua utilização como ferramenta para tomadas de decisões na esfera da Gestão Territorial (Averbeck; Cesare, 2010).

Para o estabelecimento do CTM são necessário dados e informações espaciais que podem ser obtidas através da ciência, entre elas o Sensoriamento Remoto (SR) e o Processamento Digital de Imagens (PDI). É notório que o avanço do SR e do PDI tem desempenhado um papel significativo na transformação da pesquisa e na abordagem dos desafios ambientais e, conseqüentemente, na Gestão Territorial (Fraga, 2021).

Jensen (2009), Lillesand, Kiefer e Chipman (2015), destacam que a capacidade de obter informações detalhadas e em tempo real, por meio de sensores instalados em plataformas orbitais, aéreas ou terrestres, revolucionou a maneira como entende-se as mudanças na paisagem, no que tange ao: monitorar mudanças no uso da terra; analisar fenômenos como inundações e deslizamentos de massa; avaliar a cobertura vegetal; agricultura de precisão; conservação da biodiversidade; gestão de recursos hídricos; elaboração de cartografia de referência; planejamento urbano, Gestão Territorial, entre outros.

Com estas tecnologias é possível identificar os elementos da superfície a partir de suas propriedades físico/químicas por meio de sua resposta espectral e radiométrica. Além disso, as características geométricas dos objetos como a altura, tamanho e forma, surge como uma possibilidade promissora para otimizar a identificação automática de elementos em áreas urbanizadas, como demonstra trabalhos de Pessoa *et al.* (2018) e Carrilho *et al.* (2018).

Neste contexto, os dados *Light Detection and Ranging (LiDAR)* são particularmente relevantes na captura de informações geométricas tridimensionais como as Nuvens de Pontos e na modelagem de superfícies terrestres. Shan e Toth (2018) explicam que o *LiDAR* oferece uma solução precisa para a aquisição de dados topográficos, com aplicações que vão desde o mapeamento do uso e ocupação do solo até a criação de Modelos Digitais de Elevação (MDE) de altíssima resolução espacial.

Ademais, a classificação de nuvens de pontos é explorada por diversos autores. Giacom-Ribeiro (2019) que expressa a importância da classificação de nuvem de pontos na Sociedade, tendo em vista que, a integração do planejamento e da gestão viabiliza a tomada de decisões mais adequadas ao contexto local em relação ao território. E Sousa, *et al.* (2019), na qual, demonstram o destaque da classificação de nuvens de pontos, provenientes de dados *LiDAR*, na aquisição e estudo de informações territoriais.

Vosselman e Maas (2010) explicam que a classificação com parâmetros geométricos é fundamental para aplicações que exigem dados tridimensionais, como modelagem 3D e análises geoespaciais avançadas, pois é possível identificar edifícios, árvores, estruturas e outros objetos com grande precisão.

Guiada por iniciativas dos trabalhos de Lin *et al.* (2014) abordando a descrição de imagens, Russakovsky *et al.* (2015) realiza a detecção de vários objetos e na sequência Caelles *et al.* (2018) propõe a segmentação de objetos, tendo como fundamento pesquisas em visão computacional utilizando os mesmos conjuntos de dados e convenções de padrão para treinamento e validação.

Contudo, é imprescindível realizar o controle de qualidade dos modelos classificados, na qual, tem-se como métrica de avaliação a Matriz de Confusão e o Índice *Kappa*. Conforme mencionado por Landis e Koch (1977) é possível formular diversas medidas de concordância interobservador do tipo *Kappa* para examinar *simultaneamente* padrões específicos de discordância. Essas medidas podem ser obtidas ao escolher conjuntos correspondentes de pesos que representam o papel de cada categoria de resposta em um determinado índice de concordância, as quais são frequentemente usados para quantificar o desempenho dos modelos de classificação, garantindo a precisão das informações obtidas (Ariza, 2002; Ghilani; Wolf, 2006; Rodrigues; 2008; Santos, 2010; Anjos, 2016; Pessoa *et al.*, 2018; Messias; Cobra, 2018; Mendes *et al.*, 2023).

Diante do exposto, pode-se notar que a problemática em relação à classificação do uso e ocupação do solo em áreas urbanas ocorre pela inserção de parâmetros espectrais provenientes das imagens, sem considerar os parâmetros geométricos característicos da área classificada. Neste trabalho, tem-se como hipótese a realização da classificação automatizada através do sensor *LiDAR* e imagens provenientes da fotogrametria, com o uso de parâmetros geométricos presentes na área. Com isso, espera-se fornecer informações geográficas para estudos territoriais.

1.1 Objetivo Geral

Avaliar o uso de *LiDAR* e Fotogrametria no processo de classificação de nuvens de pontos para determinação do uso e ocupação do solo.

1.2 Objetivos Específicos

- Avaliar se o uso de dados adquiridos por tecnologia *LiDAR* e fotogrametria podem ou não subsidiar informações geométricas das áreas urbanas para estudos territoriais;
- Avaliar se classificação de nuvem de pontos automatizada foi ou não satisfatória com a inserção de parâmetros geométricos, de acordo com a ET-CQDG/2016;
- Avaliar de forma temática a classificação automatizada da nuvem de pontos;
- Avaliar se há ou não contribuição da classificação automatizada da nuvem de pontos em área urbana no subsídio informações geométricas territoriais.

1.3 Justificativas

Observou-se em alguns trabalhos, como os de Kumar, Rahman e Buyuksalih (2017), Carrilho *et al.* (2018) e Pessoa *et al.* (2018), a problemática em relação à classificação de uso e ocupação da terra, principalmente na identificação de áreas urbanas. Os desafios incluíram a distinção entre o solo exposto, vegetação e áreas antrópicas construídas, entre outros.

Nota-se que em grande parte das investigações acerca dessa problemática, há o uso da classificação com parâmetros espectrais inerentes das imagens, não sendo consideradas informações geométricas em suas análises. Portanto, existe um diferencial na utilização da classificação de nuvem de pontos com inserção de parâmetros geométricos que reside na capacidade de fornecer uma representação mais completa e precisa do ambiente.

Tendo isso em vista, tem-se por justificativa realizar a classificação de uso e ocupação do solo de área urbana com dados provenientes de *LiDAR* para subsidiar informações geográficas, bem como no uso de atualizações de dados cadastrais. E com a classificação de uso e ocupação do solo, tende-se a possibilitar informações no que tange o número das edificações, delimitação das construções, censo arbóreo e determinação de Modelos Digitais de Terreno (MDT).

Essa abordagem eleva a qualidade das análises e decisões, contribuindo para avanços substanciais em pesquisas e aplicações práticas nas mais diversas áreas são beneficiadas, como no CTM. A capacidade de classificar e distinguir as diversas classes de uso e ocupação, especialmente com considerações espaciais específicas, pode fornecer informações valiosas para a Gestão Territorial e melhorar a tomada decisão, tornando as cidades mais sustentáveis.

2 REVISÃO DE LITERATURA

2.1 Gestão Territorial e o Cadastro Territorial Multifinalitário

A Gestão Territorial é um conjunto de práticas que envolvem o planejamento, monitoramento e tomada de decisões relacionadas ao uso da terra e dos recursos naturais em uma determinada área geográfica. Na qual, aborda-se a organização e administração do espaço territorial para garantir um desenvolvimento sustentável, promovendo a harmonização entre as atividades humanas e a preservação do meio ambiente (Julião, 2015; Amorim *et al.*, 2018).

Amorim, *et al.* (2018, p. 16), destaca ainda que no âmbito da gestão:

(...) gestão é o conjunto de tarefas que procuram garantir a afetação eficaz de todos os recursos disponibilizados, a fim de serem atingidos os objetivos técnicos pré-determinados. E fundamentadas na aquisição e tratamento de dados e informações relevantes, e, por essa via, contribuir para seu desenvolvimento e para a satisfação dos interesses e necessidades de seus atores e agentes no geral ou de um grupo em particular (Amorim *et al.*, 2018, p. 16).

A somar, Julião (2015, p. 94-95) expressa que:

Atuar no domínio da Gestão Territorial implica necessariamente considerar e articular as múltiplas perspectivas e os vários interesses que nele se conjugam. (...). É importante reforçar o conceito e a prática de uma Gestão Territorial integrada, na qual a informação é base do conhecimento da situação, suporte do planejamento e programação, bem como fundamento das decisões, que, em cada momento, devem ser tomadas democraticamente (Julião, 2015, p. 16).

De acordo com os autores, a base para Gestão Territorial é ter conhecimento da área de interesse por meio de dados confiáveis e atualizadas. Neste contexto, o CTM desempenha um papel fundamental na documentação de informações cadastrais relacionadas às parcelas. Isso implica, não apenas o registro de dados diretamente associados às parcelas, mas também de informações sobre outros elementos vinculados as parcelas.

No que tange às fundamentações jurídicas do CTM no Brasil, Carneiro (2003), expressa que o cadastro urbano não possui leis próprias que norteiam as práticas e consequentemente as classes de uso e ocupação do solo. Contudo, cada Município é responsável pela legislação do solo urbano, ficando implícito nas legislações municipais, as diretrizes para o CTM, sendo que as principais referências legislativas

municipais são: Plano Diretor; Parcelamento e Uso do Solo; Zoneamento Urbano; Código de Obras; e, Código de Posturas.

É importante ressaltar que, na esfera federal, existem leis que servem como base para a implementação do CTM sendo: Decreto Nº 89.817/1984, que estabelece as instruções reguladoras das Normas Técnicas da Cartografia Nacional; Lei Nº 10.257/2001 que regulamenta o Estatuto das Cidades e Ministérios das Cidades; Portaria Nº 511 de 2009 do Ministério das Cidades do Brasil que dispõe sobre as Diretrizes do CTM; NBR 14.166 de 2022 que estabelece a Rede de Referência Cadastral; Portaria Nº 3242 de 2022 que aprova as diretrizes para a criação, a instituição e atualização do CTM nos municípios brasileiros; e, NBR 17047 de 2022 que dispõe sobre o Levantamento Cadastral Territorial para Registro Público.

De fato, o CTM apresenta multifinalidades e potencial para fornecer dados dos diferentes segmentos sociais e econômicos e, conseqüentemente, informações para os vários níveis da Gestão Territorial (Duarte, 2019). Contudo, estes dados apresentam custos elevados de aquisição e processamento, sendo necessários desenvolvimento de tecnologias capazes de abstrair dados em informações de modo a serem utilizadas no processo de tomada de decisão.

2.2 Sensoriamento Remoto

O Sensoriamento Remoto é uma ferramenta fundamental na coleta de informações sobre objetos, áreas ou fenômenos da superfície terrestre, sem a necessidade de contato físico direto (Meneses; Almeida, 2012). Isso é alcançado por meio da aquisição de dados provenientes de sensores instalados em plataformas, como satélites, aeronaves, drones, entre outros. Esses sensores são capazes de capturar informações em diferentes partes do espectro eletromagnético, incluindo luz visível, infravermelho, radar e outras frequências (Jensen, 2009; Lillesand; Kiefer; Chipman, 2020).

Chuvienco (2016) destaca que o SR é amplamente aplicado em várias áreas das ciências, sendo utilizado para: avaliar o uso do solo; identificar mudanças no uso da terra; determinar vetores de expansão urbana; monitoramento do desmatamento; desenvolvimento agrícola; gestão sustentável de recursos naturais; manejo e conservação de florestas, água e solos. No âmbito do CTM, o SR é aplicado no mapeamento das parcelas e da infraestrutura urbana, de modo a subsidiar finalidades

ficais (Ex.: avaliação e tributação), legais (Ex.: transferências e certidões), administrativas (Ex.: planejamento e controle do uso da terra), ambiental (Ex.: desenvolvimento sustentável e proteção ambiental) (Amorim, *et al.*, 2018; Duarte, 2019).

Para desenvolver estas aplicações no âmbito urbano, é necessário realizar uma minuciosa escolha das plataformas e sensores disponíveis, sendo observadas questões referentes: ao objetivo dos trabalhos desenvolvido; tamanho da área a ser mapeada; resolução espacial dos produtos; qualidade cartográfica em relação a escala de mapeamento; e, relação custo-benefício (De Moraes Novo, 2001). Assim, em conjunto, essas questões contribuem para uma compreensão mais abrangente do território e seus processos dinâmicos, demonstrando a importância do SR em diversas áreas de pesquisa e prática.

2.2.1 Sistema LiDAR


No que tange a plataforma de aquisição de dados provenientes de SR, o Sistema de Aeronave Remotamente Pilotada (SARP) é um conjunto formado pela Aeronave Remotamente Pilotada ou *Remotely-Piloted Aircraft (RPA)* do inglês, pela Estação de Pilotagem Remota (RPS), pelo link de comando e controle e por qualquer outro componente que faça parte do projeto da aeronave (ANAC, 2017). O SARP, em comparação com os métodos tradicionais de SR, apresenta algumas vantagens, diante dos seguintes fatores: escalabilidade e segurança; custos de aquisição e manutenção; controle da resolução espacial e temporal; entre outras.

Um componente do SARP que vem ganhando destaque no mapeamento é o sensor *LiDAR*, sendo definida como um sistema ativo, tendo como princípio a emissão de um pulso *laser*, que após a interação com um determinado objeto na superfície terrestre, retorna para o sensor em um dado intervalo de tempo. E essa diferença de tempo entre a emissão e recepção, permite representar em três dimensões as feições do terreno e as estruturas verticais presentes na superfície terrestre (Hudak *et al.*, 2009; NOAA, 2012; Araújo, 2015).

Baseado nos estudos de Silva (2020), os componentes básicos do sistema *LiDAR* (Figura 1) são: sensor *laser* (Figura 2); sistema ótico de transmissão e recepção do pulso *laser*; unidade de *Inertial Measure Unit (IMU)*; receptor *Global Navigation Satellite System (GNSS)*; computadores de bordo com programas para

gerenciamento de todo o sistema; e, unidade de armazenamento dos dados brutos provenientes do *GNSS*, do *IMU* e das medições *laser*.

Figura 1 - Componentes básicos do sistema *LiDAR*



Fonte: Giongo, 2010, p.232.

Figura 2 - Sensor *LiDAR AlphaAir 450*



Fonte: CPE, 2023, p.1.

HE (2020) afirma que o *LiDAR* é um método de detecção avançado, que combina tecnologia *laser* com fotoeletrônica e fotoelétrica moderna, que é capaz de obter nuvens de pontos 3D de objetos terrestres. O *LiDAR* apresenta tecnologia inovadora no campo do SR, sendo essencial para a coleta de dados tridimensionais de alta resolução e vem desempenhando um papel fundamental em uma ampla gama de aplicações, inclusive na Gestão Territorial e o Planejamento Urbano. Contudo, o

processamento destas informações requer métodos específicos para obtenção de produtos para o CTM.

2.2.2 Classificação Nuvem de Pontos 3D

A análise geométrica, no âmbito do Processamento Digital de Imagens, foca na compreensão das características espaciais e geométricas dos objetos presentes em uma imagem. Uma de suas funções primordiais é a extração de características importantes, tais como forma, tamanho, orientação e distribuição. Essas informações, muitas vezes subestimadas em abordagens puramente baseadas em *pixels* desempenham um papel crucial na distinção entre diferentes classes de objetos (Global Mapper, 2023).

Cavalcanti, Candeias e Tavares Junior (2016) expõe que o *LiDAR* abrange técnicas para a coleta de dados 3D, onde o produto gerado consiste em uma nuvem de pontos, sendo composta por coordenadas tridimensionais, além de informações do nível de intensidade do alvo refletido, permitindo melhora na interpretação e visualização das feições do terreno, desde que a classificação dos objetos presentes na nuvem de pontos seja realizada de maneira adequada.

A somar, Antonarakis, Richards e Brasington (2008) *apud* Zhang, Lin e Ning (2013, p. 3750), expressam que a importância da classificação de nuvens de pontos é destacada na área de processamento de dados *Airborne Laser Scanning* (ALS), visto que essa classificação é essencial para várias aplicações, como a reconstrução de edifícios, modelagem de vegetação e análise de inundações. A segmentação de nuvens de pontos envolve a categorização dos pontos em diferentes classes, como vegetação, construções ou solo. Cada uma dessas classes requer um entendimento específico de suas características (Zhang; Lin; Ning, 2013, p. 3750).

Zhang, Lin e Ning (2013, p. 3751) expressam também a existência de dois métodos de classificação existentes:

- Classificação baseada em pontos: é conduzida pela análise das propriedades de um único ponto laser. Ao examinar um ponto específico na superfície e contrastar suas características com as de outro ponto, a informação adquirida é limitada em relação à natureza da superfície amostrada Zhang, Lin e Ning (2013, p. 3751).

- E a classificação baseada em segmentos segundo Zhang, Lin e Ning (2013, p. 3751-3752):

consiste em primeiro segmentar os dados e, em seguida, realizar uma classificação com base nesses segmentos. Um caso especial de classificação baseada em segmentos é a filtragem baseada em segmentos. (...) Os filtros baseados em segmentos são tipicamente projetados para áreas urbanas onde muitas arestas de degraus podem ser encontradas nos dados (Zhang; Lin; Ning 2013, p. 3751-3752).

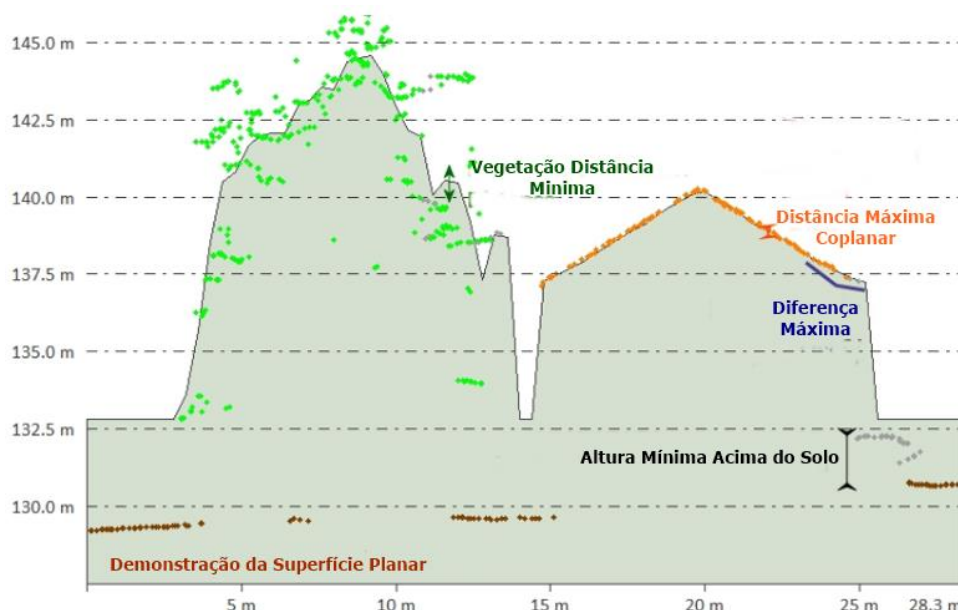
A classificação geométrica de nuvens de pontos, por meio do Método de Grade, desempenha um papel fundamental ao classificar pontos com base na sua proximidade com uma superfície plana de melhor ajuste calculada em segmentos específicos de dados de pontos (Global Mapper, 2023). Conforme destaque do autor:

O algoritmo envolve uma etapa de agrupamento e uma etapa de identificação. Os pontos são reunidos em *clusters* com base em uma medida de similaridade entre pontos próximos, com a intenção de agrupar pontos que pertencem ao mesmo objeto ou feição (Global Mapper, 2023).

Segundo o autor, o algoritmo envolve uma etapa de agrupamento e uma de identificação. Os pontos são reunidos em *clusters* com base em uma medida de similaridade entre pontos próximos, com a intenção de agrupar pontos que pertencem ao mesmo objeto ou feição. Os pontos de construção são identificados com base em diversas estatísticas sobre o *cluster* ao qual pertencem, incluindo covariância, orientação e curvatura da vizinhança local.

Para otimizar a aplicação do método o algoritmo oferece parâmetros de filtragem personalizáveis (Figura 3). A altura mínima acima do solo diz respeito a distância vertical em relação ao plano de referência, que um ponto deve ter para ser considerado uma possível construção, vegetação alta, ou seja, um ponto que não seja terreno. A configuração da distância máxima (coplanar) e a diferença máxima de ângulo (inclinação) são elementos cruciais na classificação automática de pontos não terrestres, fornecendo tolerância e controle sobre a identificação de superfícies planas de construção (Global Mapper, 2023).

Figura 3 - Parâmetros de filtragem



Fonte: Global Mapper, 2023 adaptado pela Autora, 2024.

Importante expressar que, infelizmente, devido à natureza comercial e não de código aberto do *software* utilizado, não foi possível aprofundar mais sobre o classificador por método de grade, assim como em todos os procedimentos para a classificação da nuvem de pontos. No entanto, é importante ressaltar que, dentro dos limites do programa comercial, foi prestado suporte para o entendimento e utilização do mesmo.

Na etapa de calibração da nuvem de pontos, emprega-se o interpolador do cálculo da Ponderação pelo Inverso da Distância ou *Inverse Distance Weighted (IDW)* do inglês. Segundo Jakob e Young (2006), ao empregar métodos de interpolação como o *IDW*, prevê-se um valor para uma localização não medida com base nos valores amostrados em sua proximidade, sendo que esses valores próximos têm um peso maior do que os mais distantes. Conseqüentemente, cada ponto de amostra exerce uma influência sobre o novo ponto a ser estimado, uma influência que diminui conforme a distância aumenta. Gomes (2018) complementa que essa influência de cada ponto é inversamente proporcional à sua distância do nó da malha.

Além disso, de acordo com Landim (2020) e Gomes (2018), ao empregar o método de interpolação *IDW*, é necessário fornecer certos parâmetros. Estes incluem os números mínimos e máximos de vizinhos, que estabelecem a quantidade mínima e máxima de pontos que impactam na estimativa dos valores. Além disso, o expoente é um parâmetro importante que permite ajustar o peso dos pontos conhecidos na

interpolação, dependendo da distância do ponto de saída, sendo representado pela Equação 1 (Landim 2020).

$$Z = \frac{\sum_i^n \frac{Z_i}{h_{ij}^\beta}}{\sum_i^n \frac{1}{h_{ij}^\beta}} \quad (1)$$

Onde:

- z: valor interpolado para o nó do reticulado;
- z_i: valor do ponto amostrado vizinho ao nó;
- h_{ij}: distância entre o nó da grade e z_i;
- β: expoente de ponderação;
- n: número de pontos amostrados utilizados para interpolar cada nó (Landim, 2020 *apud* Gomes, 2018, p. 4).

À medida que a tecnologia avança, a precisão e a eficiência dos algoritmos também melhoram, tornam a classificação de nuvem de pontos uma ferramenta cada vez mais poderosa na análise geoespacial e na Gestão Territorial. Assim, com a classificação da nuvem de pontos é possível gerar imagens *raster* que representam o uso e ocupação do solo. Contudo, é importante avaliar a qualidade destas imagens classificadas, de modo que os produtos gerados possam ser aplicados de maneira eficiente e acurada.

Além disso, segundo Araki (2006), é notável que a combinação dos dados espectrais e tridimensionais resultam em melhorias significativas em comparação com o uso isolado de cada um deles. Contudo, é fundamental garantir que esses conjuntos de dados estejam em uma base geométrica compatível, o que requer a ortorretificação da imagem de satélite, o que é implícito no processamento fotogramétrico. Nesse sentido, a utilização da informação altimétrica proveniente do *LiDAR* é altamente vantajosa, pois além de representar o relevo, também oferece informações sobre os objetos presentes na superfície.

2.3 Análise da Qualidade

Em Cartografia a principal importância do controle de qualidade é informar a qualidade a fim de proporcionar a destinação do uso da informação inerente nos dados espaciais. A produção de modelos da realidade na Cartografia visa a tomada de decisões. Santos (2010, p. 24) afirma que “quanto maior o nível de controle de qualidade em um dado ou produto cartográfico, mais confiável ser a tomada de decisão com base nestes dados”.

A ISO 19157/2023 estabelece diretrizes para a avaliação da qualidade dos dados geoespaciais. Ela define uma estrutura para descrever a qualidade dos dados em cinco dimensões principais: completude, consistência lógica, acurácia posicional, acurácia temporal e acurácia temática, explica DCT/DSG (2016, p. 17-18).

Conforme DCT/DSG (2016, p. 18):

essas categorias agrupam elementos de qualidade similares que descrevem se os dados estão completos (Completude), se estão na posição correta (Acurácia posicional), se os atributos estão corretos (Acurácia temática) e se cumprem com todas as regras lógicas (Consistência lógica) (García-Balboa, 2011) (DCT/DSG, 2016, p. 18).

2.3.1 Acurácia Temática

Segundo Santos (2010), a acurácia representa o nível de proximidade entre uma estimativa e o parâmetro para o qual foi calculada, ou seja, o valor mais provável. O autor destaca que a acurácia engloba tanto os efeitos aleatórios quanto os sistemáticos, conforme mencionado por Mikhail e Ackermann (1976), *apud* Monico *et al.*, (2009). Nesse sentido, a acurácia pode ser compreendida como a combinação de precisão e tendência (Santos, 2020).

Conforme descrito por DCT/DSG (2016), a acurácia temática está relacionada à interpretação correta das características e atributos, além de sua classificação nas categorias definidas no modelo conceitual. Essa acurácia é subdividida em:


- “Acurácia da classificação: obtém-se pela comparação das classes ou atributos encontrados no conjunto de dados geoespaciais com o modelo de dados adotado” (DCT/DSG, 2016, p. 21);
- “Acurácia de atributos não quantitativos: obtém-se pela avaliação dos atributos que não podem ser contados (não quantitativos) ao compará-

los com os atributos das mesmas feições na fonte de maior precisão” DCT/DSG, 2016, p. 21); e

- “Acurácia de atributos quantitativos: obtém-se pela avaliação dos atributos que podem ser contados (quantitativos) ao compará-los com os atributos das mesmas feições na fonte de maior precisão” DCT/DSG, 2016, p. 21).

Para melhor exemplificar, a DCT/DSG (2016) expressou a seguinte situação: uma área (Figura 4) em que ocorre a classificação inadequada, sendo erroneamente identificada como “solo exposto”. Isso demonstra uma situação em que a inconsistência dos dados está ligada à acurácia temática da classificação.

Figura 4 - Exemplo de acurácia temática na classificação



Fonte: DCT/DSG, 2016, p.21.

2.3.1.1 Matriz de Confusão

Conforme o DCT/DSG (2016, p. 50), a matriz de confusão estabelece duas métricas para avaliar a precisão da classificação: a exatidão global da classificação e o índice Kappa. A Diretoria de Serviço Geográfico (DSG) elaborou a Norma Cartográfica para Controle de Qualidade de Dados Geoespaciais (ET-CQDG) em 2016, na qual expressa a matriz de confusão como:

Ferramenta popular para avaliar a acurácia da classificação em dados geoespaciais é a matriz de confusão (Foody, 2002), também chamada matriz de erro (Stehman, 1997). Congalton (1991) indica que uma matriz de confusão é geralmente formada pela mesma quantidade de colunas e linhas que expressam a quantidade de uma determinada categoria no produto avaliado (linhas) em relação a uma referência (colunas). Essas categorias podem ser *pixels* em uma imagem, ou regiões classificadas em

uma imagem segmentada, ou inclusive classes em um produto Vetorial (DCT/DSG, 2016, p. 26).

A somar, Rennó (1995) também expressa que a matriz de confusão (Figura 5) tem por finalidade a avaliação de uma classificação que ocorre por meio da precisão total, a qual é determinada pela proporção de amostras classificadas corretamente. Essa métrica é calculada pela divisão da soma dos valores da diagonal da matriz de confusão, representando as amostras corretamente classificadas e pela soma de todos os elementos da matriz, sendo o número total de amostras.

Figura 5 - Estrutura da matriz de confusão

		Classificação				Total
		1	2	...	c	
V e r d a d e	1	x_{11}	x_{12}	...	x_{1c}	x_{1+}
	2	x_{21}	x_{22}			x_{2+}
	⋮	⋮		⋮		⋮
	c	x_{c1}			x_{cc}	x_{c+}
	Total	x_{+1}	x_{+2}	...	x_{+c}	N

Fonte: Rennó, 1995, p.76.

Cada elemento está representado por x_{ij} , sendo i (linhas) e j (colunas), onde o i é em relação aos dados de referência e j em relação aos dados da classificação. E o número total da matriz, atribui-se ao número total das amostras, sendo x_{i+} da classe i e x_{j+} da classe j .

Quando se tem conhecimento das verdadeiras classes da região escolhida, tem-se o referencial para avaliar a métrica da classificação, podendo então construir a relação do referencial com o classificado, ou seja, obter o quanto se relacionou a classes obtida com as amostras tidas como “verdadeiras”.

2.3.1.2 Exatidão Global

A DCT/DSG (2016, p. 51), define a exatidão global (EG) como “a probabilidade global de um produto estar bem classificado (...) A medida é calculada usando a soma dos valores da diagonal principal e dividindo pela quantidade total das instâncias investigadas”, Equação 2 (Congalton, 1991):

$$EG = \frac{1}{N} \sum_{i=1}^t X_{i,i} \quad (2)$$

A partir dos resultados podem ser geradas as análises da classificação e conclusões sobre este processo levando em consideração o modelo classificado

2.3.1.3 **Kappa**

Segundo DCT/DSG (2016, p. 52), “a análise de *kappa* (*k*) é uma técnica multivariada discreta usada na avaliação da pressão temática que utiliza todos os elementos da matriz de erro no seu cálculo”, Equação 3 (Congalton, 1991):

$$k = \frac{N \cdot \sum_{i=1}^t X_{i,i} - \sum_{i=1}^t X_{i+} \cdot X_{+i}}{N^2 - \sum_{i=1}^t X_{i+} \cdot X_{+i}} \quad (3)$$

Outro fator indicador de validação dos produtos classificados, fundamenta-se no uso do coeficiente *Kappa* (Landis e Koch, 1977), onde são atribuídos os seguintes intervalos para o índice *Kappa*, Quadro 1.

Quadro 1 - Valores de referência para o coeficiente Kappa

Estatística <i>Kappa</i>	Concordância
< 0,00	Ruim
0,00 – 0,20	Pouco
0,21 – 0,40	Justo
0,41 – 0,60	Moderado
0,61 – 0,80	Substancial
0,81 – 1,00	Quase perfeito

Fonte: Landis e Koch, 1977, p.165.

Ressalta-se a explicação de Landis e Koch (1977, p. 163), no que acerca o coeficiente *Kappa*:

Várias medidas do tipo *Kappa* de concordância interobservador podem ser formuladas para investigar padrões selecionados de discordância *simultaneamente*, escolhendo conjuntos correspondentes de pesos que refletem o papel de cada categoria de resposta em um dado índice de concordância (Landis; Koch, 1977, p. 163).

Rosenfield e Fitzpatrick-Lins (1986), Hudson e Ramm (1987) e Foody (1992), consideram o estimador *Kappa* definido nas seguintes Equações 4, 5, 6, 7, 8 e 9.

$$\hat{k} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (4)$$

Onde:

$$\theta_1 = \frac{\sum_{i=1}^c x_{ii}}{N} \quad (5)$$

$$\theta_2 = \frac{\sum_{i=1}^c x_{i+} x_{+i}}{N^2} \quad (6)$$

$$\theta_3 = \frac{\sum_{i=1}^c x_{ii} (x_{i+} + x_{+i})}{N^2} \quad (7)$$

$$\theta_4 = \frac{\sum_{j=1}^c x_{+j} \sum_{j=1}^c x_{ij} (x_{j+} + x_{+j})}{N^3} \quad (8)$$

Onde conforme Rennó (1995):

- \hat{k} é o estimador do *kappa*;
- $\theta_1, \theta_2, \theta_3$ e θ_4 são as variáveis;
- x_{i+} é o número de amostras da classe i ;
- x_{+j} é o número total de amostras da classe j ;
- x_{ij} é o número de amostras verdadeiramente da classe i .

Segundo as observações de Rennó (1995), o coeficiente *Kappa* pode variar de -1 a 1. A condição em que todas as amostras são classificadas corretamente, resultando em uma matriz de confusão com todos os elementos fora da diagonal sendo nulos, leva a um valor de *Kappa* igual a 1. Valores reduzidos de *Kappa*, conforme apontado por Landis e Koch (1977), indicam que a classificação não atingiu um desempenho satisfatório.

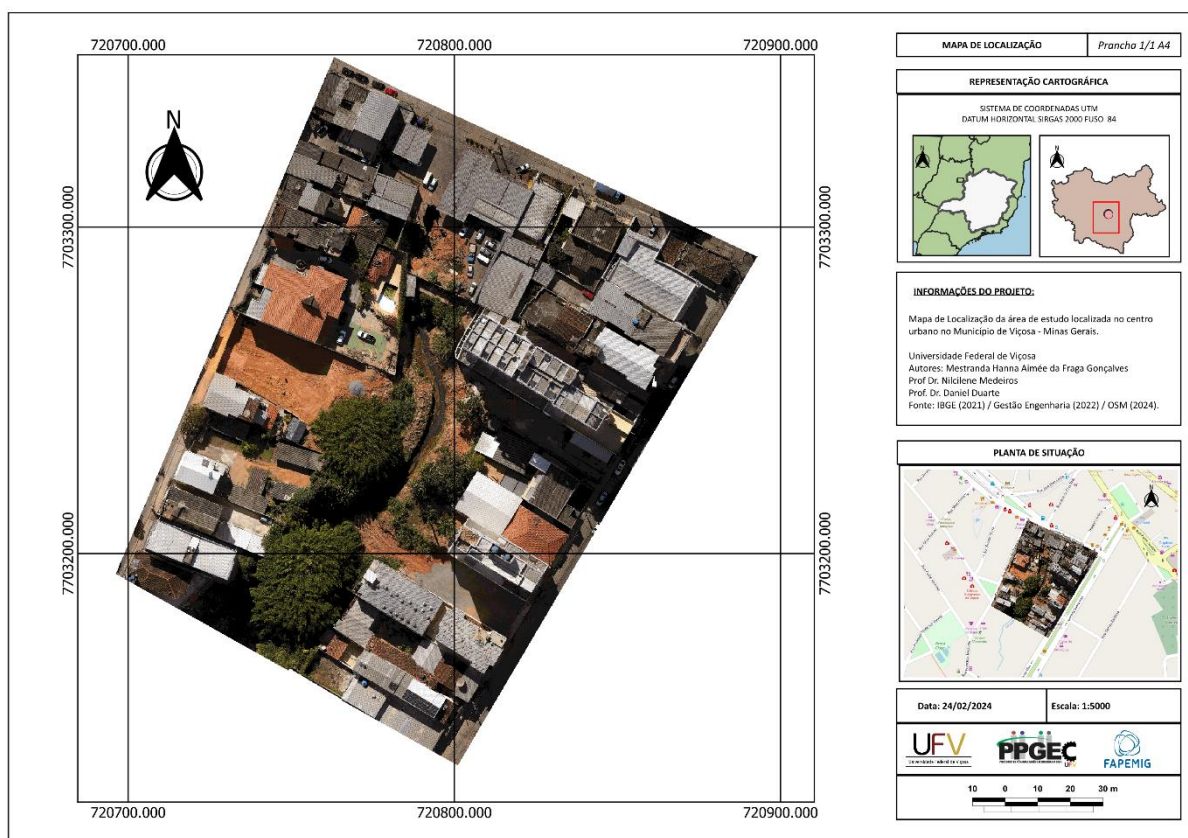
É importante realizar a validação do *Kappa*, sendo aplicado a variância do *Kappa* ($VAR_{\hat{k}}$) possibilitando a análise da classificação ao acaso, sendo menor que zero, a classificação pior do que ao acaso; igual a zero, igual a classificação ao acaso; e maior que zero, classificação melhor do que o acaso, conforme expressa Cohen (1960) na Equação 9.

$$VAR_{\hat{k}} = \frac{1}{N} \left[\frac{\theta_{\perp}(1 - \theta_{\perp})}{(1 - \theta_2)^2} + \frac{2(1 - \theta_{\perp})(2\theta_{\perp}\theta_2 - \theta_3)}{(1 - \theta_2)^3} + \frac{(1 - \theta_{\perp})^2(\theta_4 - 4\theta_2^2)}{(1 - \theta_2)^4} \right] \quad (9)$$

3 MATERIAIS E MÉTODOS

Para o presente estudo, foi escolhida uma região da área urbana do Município de Viçosa – Minas Gerais (Figura 6). A seleção criteriosa dessa localidade se justifica pelas características urbanizadas verticalmente que predominam no centro comercial do Município. Ao optar-se por essa região, visa-se capturar a complexidade da dinâmica urbana, explorando as nuances de suas características.

Figura 6 - Mapa da área de estudo



1

Fonte: Autora, 2024.

Adicionalmente, a escolha foi influenciada pela presença de áreas com solo exposto, vegetação e construções variadas como prédios e casas, proporcionando uma oportunidade de examinar as interações entre o ambiente construído e os elementos naturais. Desta forma, essa região de Viçosa se apresenta como um

¹ FRAGA. Hanna Aimée. **Mapa da área de estudo**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_LOCALIZACAO_HF.pdf. Acesso em: 26 fev. 2024.

cenário propício para classificação e análise da viabilidade de dados *LiDAR* na Gestão Territorial.

3.1 Materiais

A integração de tecnologias aumenta a tendência na agregação de conhecimento e inovação. Neste trabalho foram utilizados os materiais tecnológicos, sendo: *RPA Matrice 300 RTK*; *LiDAR AlphaAir 450* integrado a câmera profissional - CHCNAV de 24MP; *Software Global Mapper Pro*; *Software ArcMap 10.8*; *Software Microsoft Office Excel*; *GNSS Topomap Modelo T10*; e *Software Topcon Tools*.

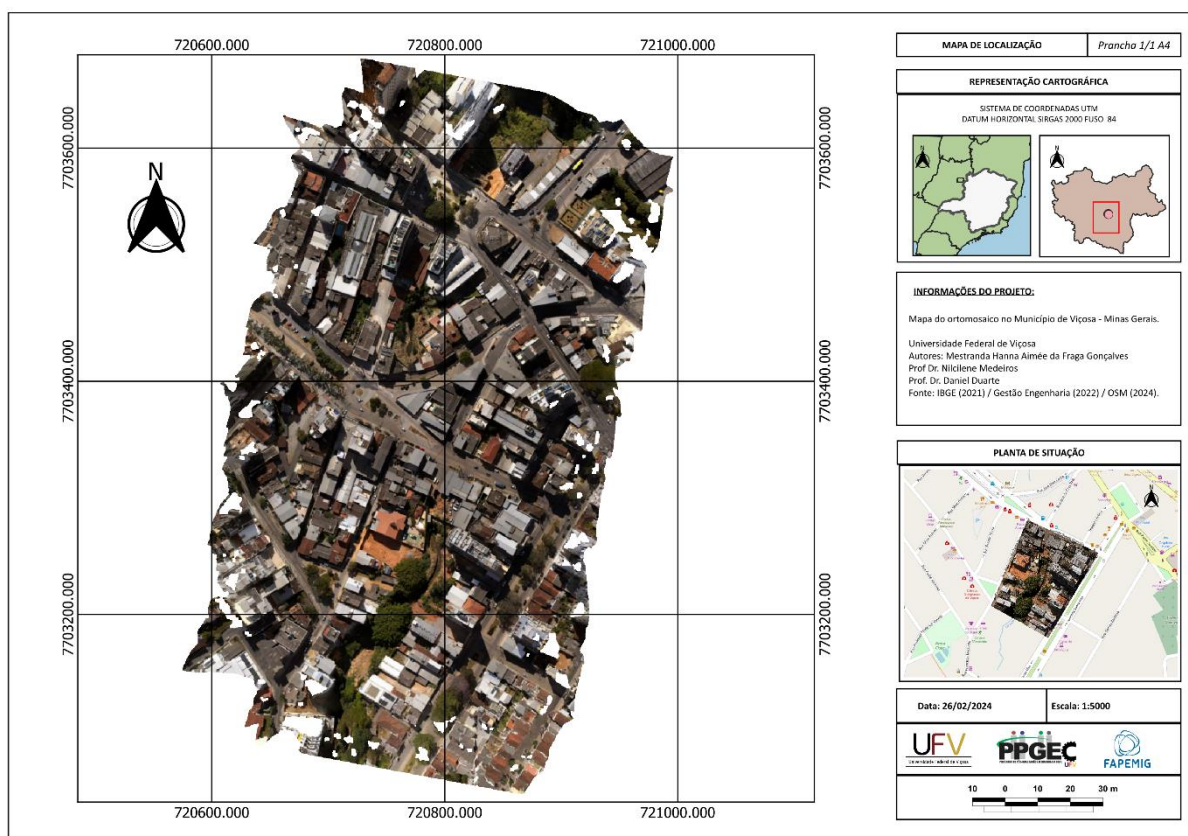
Válido destacar que o *Matrice 300 RTK* é um drone comercial de alta qualidade desenvolvido pela *Dà-Jiāng Innovations Science and Technology* (DJI). Acoplado ao sensor *Matrice 300 RTK*, tem-se o *Laser Scanner AlphaAir 450*, que integra um receptor *GNSS* e uma *IMU* de alta precisão com 3 retornos. A precisão elevada da *IMU* é essencial para a obtenção de dados *LiDAR* de alta qualidade. Sem essa tecnologia, a nuvem de pontos resultante seria apenas uma coleção aleatória de pontos. Essa característica possibilita que o *AlphaAir 450* alcance uma precisão absoluta na faixa de 5 a 10 cm (CPE, 2023).

O levantamento fotogramétrico e o perfilamento a *laser* ocorreram no dia 22 de julho de 2022, a uma altura de 100 metros e velocidade de 7 m/s, sendo realizado pela Empresa Gestão Engenharia que generosamente forneceu os dados de referência para execução deste trabalho. De acordo com a empresa, no levantamento e processamento dos dados *GNSS*, foi utilizado como base o equipamento CHC i50 e técnica de Posicionamento por Ponto Preciso (PPP) aliado ao serviço IBGE-PPP do Instituto Brasileiro de Geografia e Estatística (IBGE). Para obter as coordenadas do *rover* foi utilizada a técnica *Post-Processing Kinematic (PPK)* para a correção das observações do *rover (Laser Scanner CHC AlphaAir 450)*, expressa-se que se teve como referencial a altitude elipsoidal (GESTÃO ENGENHARIA, 2022).

Segundo a Gestão Engenharia (2022), com as imagens georreferenciadas foi elaborado o ortomosaico (Figura 7) por meio do *Software Agisoft Metashape* seguindo as seguintes etapas: alinhamento das imagens, construção da nuvem densa, construção do Modelo Digital de Superfície (MDS) e do ortomosaico. O ortomosaico apresenta as seguintes características: Sistema de Referência Cartográfica UTM –

Zona 23 Sul; área levantada de 2,65 ha; Resolução Espectral no visível (RGB); e, Resolução Espacial 0,023 metros.

Figura 7 - Ortomosaico da área de estudos



2

Fonte: Autora, 2024.

3.2 Metodologia

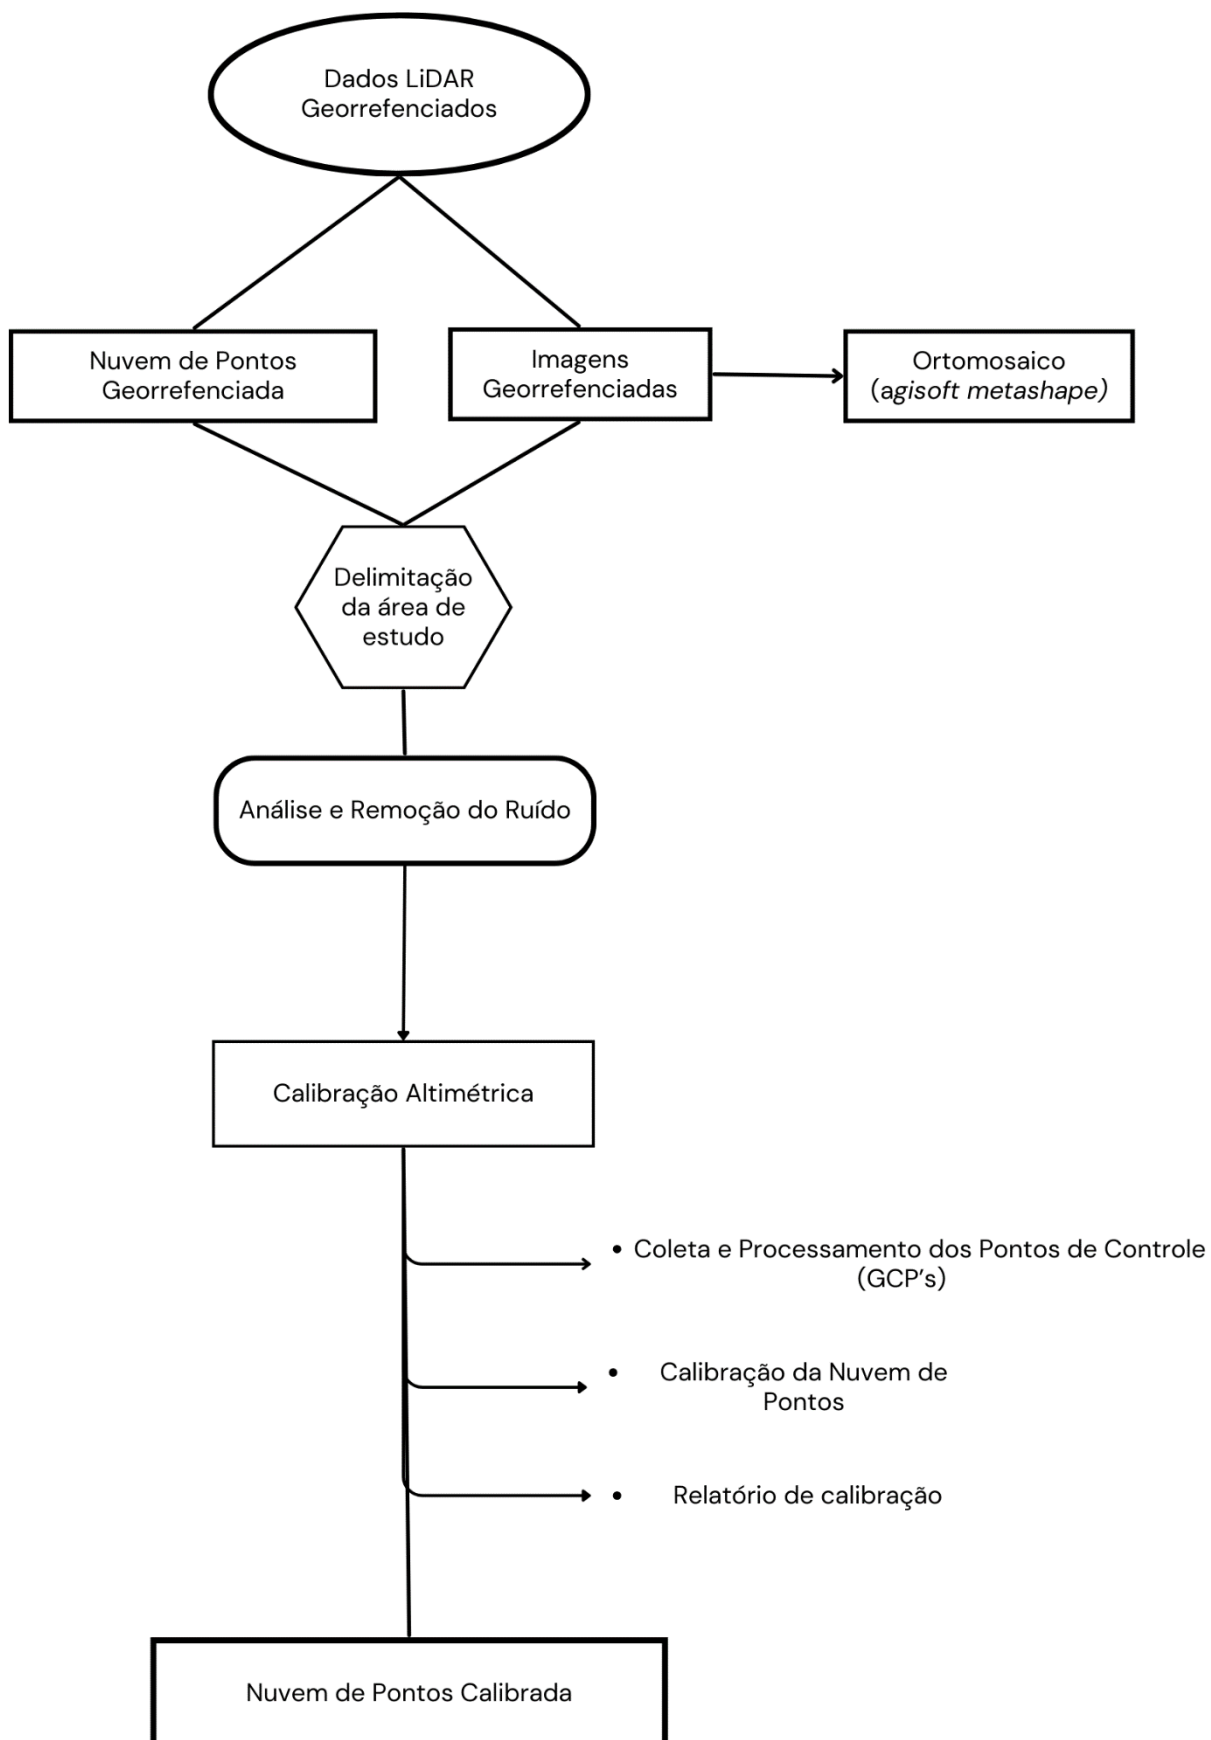
A metodologia deste trabalho foi dividida em duas etapas, sendo o pré-processamento e o processamento

3.2.1 Pré-Processamento

Um fluxograma de atividades para etapa de pré-processamento é apresentado na Figura 8.

² FRAGA, Hanna Aimée. **Ortomosaico da área de estudos**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_ORTO_HF.pdf. Acesso em: 26 fev. 2024.

Figura 8 - Fluxograma - pré-processamento



Fonte: Autora, 2024.

Iniciou-se a metodologia desse trabalho com a delimitação da área de interesse através do *software ARCGIS*. E posteriormente, deu-se início ao pré-processamento com o *software Global Mapper Pro*.

Para a análise de alinhamento da nuvem de pontos com o ortomosaico, recorreu-se à ferramenta "Perfil da Rota", onde ocorreu a análise altimétrica através do perfil vertical. Assim, foi possível analisar o intervalo dos pontos que estão fora da faixa de elevação, no qual foram definidos como registro e, posteriormente foram classificados os pontos baixos ("*low points*") e pontos altos ("*hight points*").

Com a remoção do registro, a próxima etapa do pré-processamento foi a calibração da nuvem de pontos, na qual, foi necessário ir a campo para a coleta de pontos de controle via receptor *GNSS Topomap Modelo T10*. Para processar os dados utilizou-se o método Relativo e ajuste dos vetores à Rede Brasileira de Monitoramento Contínuo dos Sistemas *GNSS (RBMC) – VICO – Viçosa (Apêndice A)*, por meio do *Software Topcon Tools*.

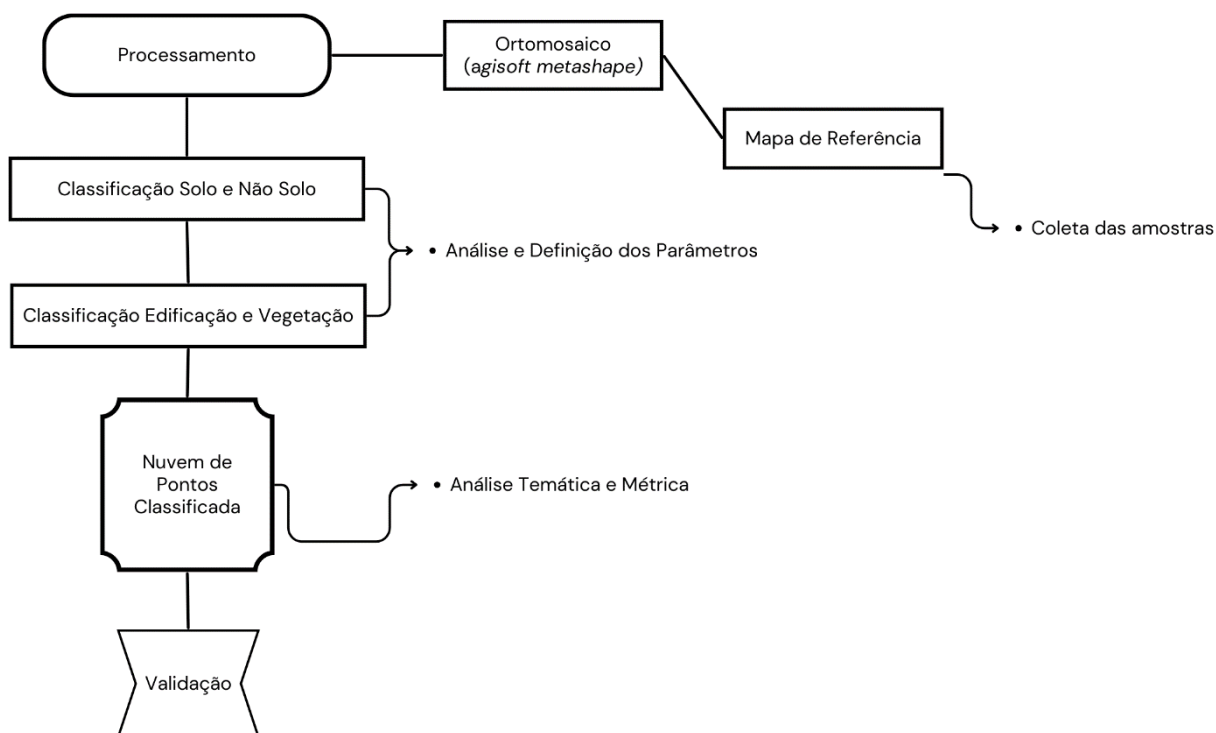
A calibração altimétrica da nuvem de pontos por meio dos *Ground Control Points (GCP)*, emprega-se o método do cálculo do *IDW* dos *GCP* para o cálculo altimétrico esperados dos pontos *LiDAR* próximos. Desse modo, os pontos na nuvem que estão mais próximos do controle têm influência maior em relação a elevação média dos pontos *LiDAR*.

Com isso, é gerado um relatório para uma análise detalhada de cada conjunto de coordenadas, contendo a Raiz do Erro Quadrático Médio (RMSE), a elevação média dos pontos próximos, a diferença de elevação entre os pontos *LiDAR* e os de controle, visando analisar o controle de qualidade da nuvem de pontos com objetivo de comparar e corrigir a altimetria.

3.2.2 Processamento

Com a calibração da nuvem de pontos realizada, procedeu-se à etapa de processamento, conforme fluxograma apresentado na Figura 9.

Figura 9 - Fluxograma - pós-processamento



Fonte: Autora, 2024.

A classificação da nuvem de pontos é uma técnica essencial na análise geoespacial e envolve a categorização desses pontos em diferentes classes ou categorias com base em características como altura, intensidade de retorno, densidade e cor. Para classificação da nuvem de pontos foi estabelecido as classes: “solo”, “não solo”, “edificação” e “vegetação”, na qual, trabalhou-se com o *software Global Mapper Pro*.

Nessa etapa, foram analisados e inseridos parâmetros geométricos na nuvem de pontos com a finalidade de classificar solo e não solo de maneira coerente com a realidade da área, onde adota-se tais parâmetros:

- Tamanho da barra (metros): desempenha um papel importante na verificação de desvios de curvatura. O algoritmo principal dessa classificação depende da comparação de pontos com seus vizinhos dentro de uma pequena área local. Esse valor pode ser calculado em metros a partir dos espaçamentos dos pontos;

- Desvio máximo (metros): especifica a alteração máxima permitida em relação à altura mínima média local, o valor padrão é de 0,3 metros. Este é um filtro usado para modelar uma superfície curva do solo, onde valores pequenos removerão a vegetação rasteira da classificação do solo, e valores maiores, geralmente, são utilizados para dados *LiDAR* de resolução mais baixa;
- Diferença máxima de altura (metros): este parâmetro permite aos usuários controlarem os valores para a remoção dos pontos que provavelmente não são pontos de terreno. Nesse campo, ocorre a especificação da alteração máxima na elevação do solo, definindo-se o intervalo esperado da elevação do solo em toda a nuvem.
- Declividade máxima do terreno (graus): refere-se à inclinação do terreno. É sugerido o valor padrão de 7,5° para áreas planas;
- Largura máxima da edificação (metros): é um filtro que compara o mínimo local com vizinhos em áreas progressivamente maiores, visando remover telhados de edifícios da classificação do solo com a especificação da largura máxima. O valor sugerido é de 50 metros, considerando-o recomendado para muitas áreas urbanas.

Na etapa em questão, classificação de solo e não solo, os parâmetros foram definidos e analisados de acordo com as características da área, os quais estão expostos na etapa de resultados e discussões deste trabalho. Após a análise temática, foram definidos os parâmetros adequados para a região de estudo e procedeu-se com a classificação de edificações e vegetação, também realizada no *software Global Mapper Pro*.

Na função de “classificação personalizada” em nuvem de pontos, é possível definir com maior detalhamento a nível de filtragem a classificação de edificações e vegetação. Trabalhou-se então com tais variáveis no modelo de feição da edificação:

- Resolução (metros): determina a região que será avaliada em torno de um ponto com objetivo de determinar as propriedades locais da superfície;
- Altura mínima acima do solo (m): neste parâmetro define-se apenas os pontos que estão a uma altura mínima acima do solo, onde essas são classificadas como não-terreno;

- Área mínima e máxima de ocupação no solo (m^2): podem aumentar (valores menores) ou reduzir (valores maiores) a probabilidade de detecção.

Assim, empregou-se o método grade, no qual abrange a distância máxima (metros), e a diferença angular máxima (graus) que define a distância coplanar máxima a ser usada para classificar pontos não terrestres. Vale ressaltar que o método grade opera classificando os elementos com base na sua relação com uma determinada superfície plana calculada como melhor ajuste dentro de cada segmento.

De posse da classificação, se faz imprescindível avaliar o modelo classificado para que se tenha o controle de qualidade do produto cartográfico. Desse modo, fundamentou-se na ET-CQDG para a realização da validação, logo, necessitou da matriz de confusão. Para obter esta matriz, foi necessário o mapa referencial por meio da coleta de amostras das classes espectrais presentes na região urbanizada. Com o mapa referencial, tendo como base o ortomosaico, adotou-se o mesmo como fundamentação para análise de aprendizagem da classificação, em outras palavras, se avaliou de forma comparativa o que realmente pertencia a classe na realidade e com o que foi classificado no modelo, sendo validado com visitas *in-loco* para somar com análise temática.


Tendo o mapa referencial, gerou-se a matriz de confusão através do *software ArcGIS 10.8* com a ferramenta “*Compute Confusion Matrix*”, no qual, se trabalhou com a comparação *pixel a pixel* com o *raster* da nuvem de pontos classificada. E com esta comparação obteve-se a matriz de confusão e as equações avaliatórias, onde se avaliou de forma quantitativa o modelo classificado por meio validação pela Acurácia Temática (Schade, 2020), Coeficiente *Kappa* (Landis e Koch, 1977) e a Variância do *Kappa* (Cohen, 1960).

4 RESULTADOS E DISCUSSÕES

4.1 Análise dos Dados de Referência

Foi realizado uma análise visual no ortomosaico (Figura 7) onde foram identificadas diversas distorções, destacando-se no sentido Sul e Nordeste na imagem, notavelmente sobre os telhados e nas extremidades (Figuras 10, 11 e 12). Essas distorções podem ser observadas em áreas específicas da imagem, como edificações e seus telhados, onde há uma aparente deformação na representação. Santos Junior (2019), expressa que as distorções podem estar associadas a fatores como variações na elevação do terreno, ângulos de incidência do *laser*, reflexões múltiplas, variações na intensidade do sinal do retorno, calibração do equipamento e velocidade da aeronave.

Figura 10 - Distorção no ortomosaico na região Sul da cena




3

Fonte: Autora, 2024.

³ FRAGA, Hanna Aimée. **Distorção na ortomosaico na região Sul da cena**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_DISTORCAO_HF.pdf. Acesso em: 26 fev. 2024.


Figura 11 - Distorção no ortomosaico na região Noroeste da cena



4

Fonte: Autora, 2024.

Figura 12 - Distorção no ortomosaico - telhados



5

Fonte: Autora, 2024.

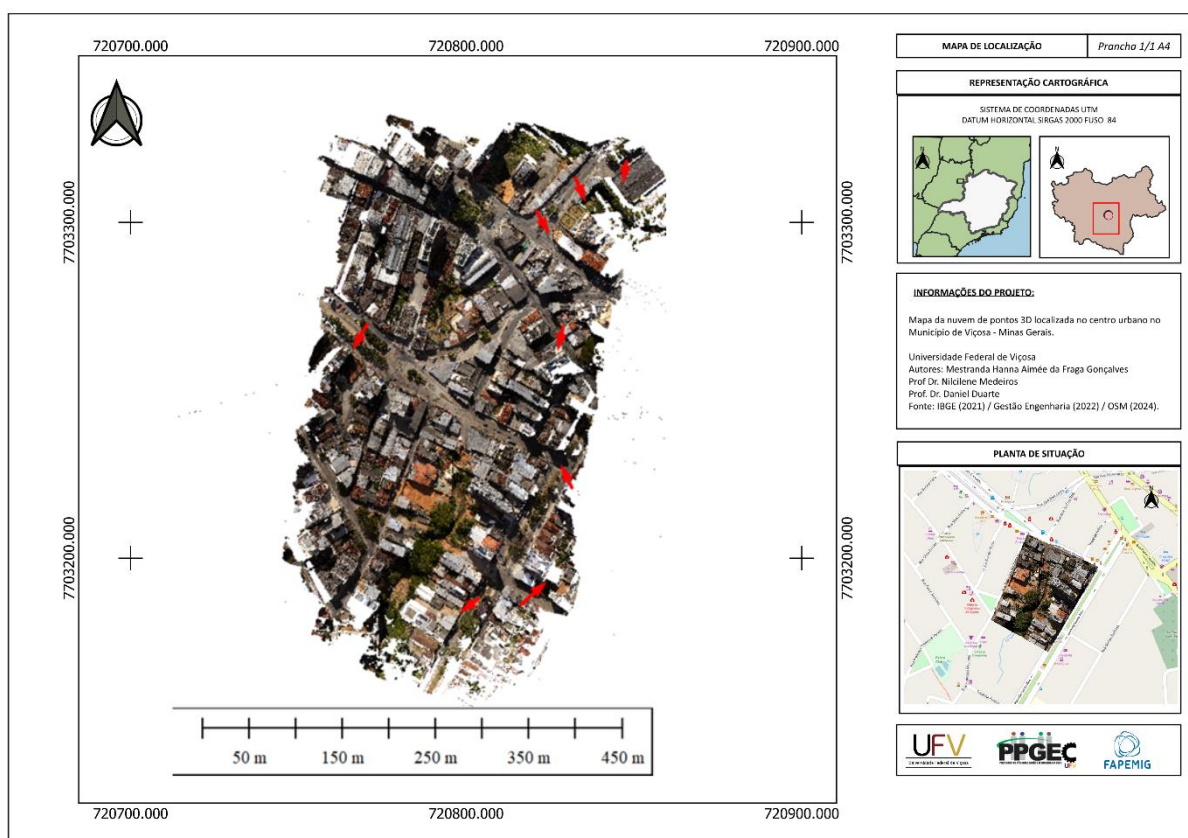
⁴ FRAGA. Hanna Aimée. **Distorção na ortomosaico na região Noroeste da cena**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_DISTORCAO_2_HF.pdf. Acesso em: 26 fev. 2024.

⁵ FRAGA. Hanna Aimée. **Distorção na ortomosaico**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_DISTORCOES_TELHADO_HF.pdf. Acesso em: 26 fev. 2024.

No que tange as distorções nos telhados, considera-se fatores de oclusão por estruturas adjacentes, como paredes ou outras edificações que podem impedir o *laser* de atingir certas partes dos telhados. Além disso, Carrilo (2021), expressa que as reflexões em superfícies reflexivas, tais como telhados feitos de materiais de metal, podem criar reflexões que afetam a qualidade dos dados coletados.

Em relação a nuvem de pontos (Figura 13), é válido acrescentar que em sua totalidade apresentou 92.646.011 milhões pontos e na área delimitada para esse estudo 2.936.429 milhões de pontos.

Figura 13 - Mapa da nuvem de pontos



6

Fonte: Autora, 2024.

É importante destacar que a nuvem de pontos apresentou características de não penetração do *LiDAR* em áreas submersas (Figura 14). Isso ocorre devido à interação com os meios aquáticos, que pode ser causada por penetração limitada na água, reflexões na superfície da água, condições ambientais, profundidade e

⁶ FRAGA. Hanna Aimée. **Mapa da nuvem de pontos**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_NUVEM_DE_PONTOS_HF.pdf. Acesso em: 26 fev. 2024.

resolução vertical, configuração do equipamento e distância entre a água e o *LiDAR* (Bertão, 2018).

Figura 14 - Mapa da nuvem de pontos - córrego




7

Fonte: Autora, 2024.

Adicionalmente, foi identificadas áreas em que os dados não foram coletados e/ou não foram adequadamente registrados durante o processo de varredura a *laser*, resultando em lacunas e falhas na representação tridimensional da região na nuvem de pontos. Conforme expõe Santos Junior (2019), essas deficiências podem impactar significativamente a precisão e integridade dos resultados obtidos. As razões para esses "buracos" (Figuras 15 e 16) podem ser diversas, incluindo: obstruções e sombreamento, onde objetos como árvores, edifícios ou outras estruturas podem bloquear o feixe de *laser*, criando até mesmo sombras e áreas sem dados; reflexões e superfícies reflexivas; áreas sombreadas por estruturas elevadas, onde o feixe de *laser* pode não ser adequadamente recebido, resultando em falhas nos dados; e até mesmo problemas na configuração do equipamento com erros sistemáticos.

⁷ FRAGA, Hanna Aimée. **Mapa da nuvem de pontos – córrego**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CORREGO_HF.pdf. Acesso em: 26 fev. 2024.

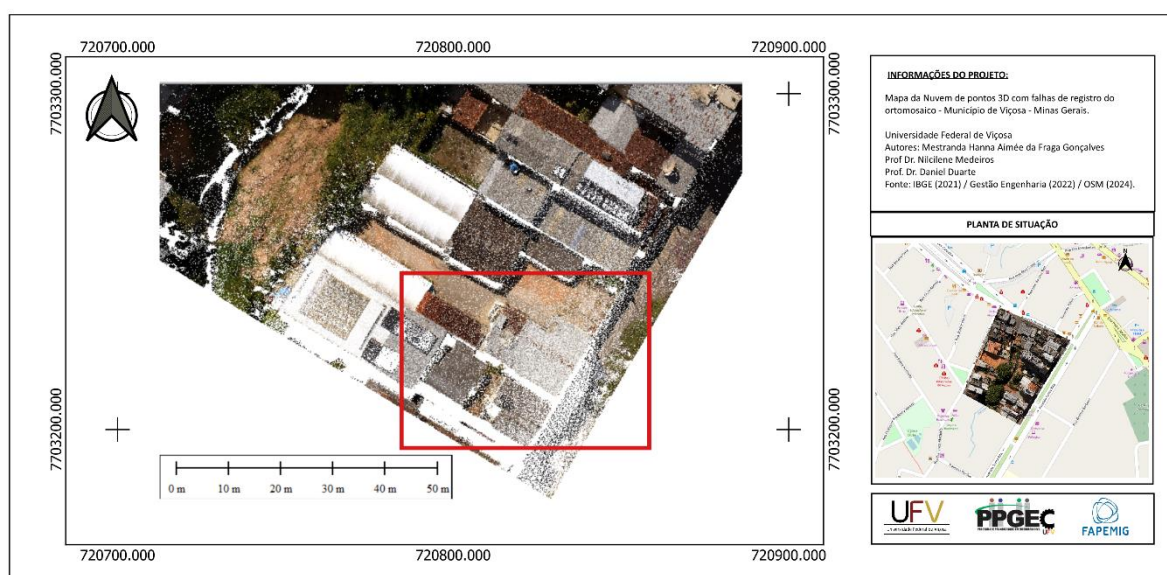
Figura 15 - Mapa da nuvem de pontos com falhas de oclusão



8

Fonte: Autora, 2024.

Figura 16 - Mapa da nuvem de pontos com falhas de registro



9

Fonte: Autora, 2024.

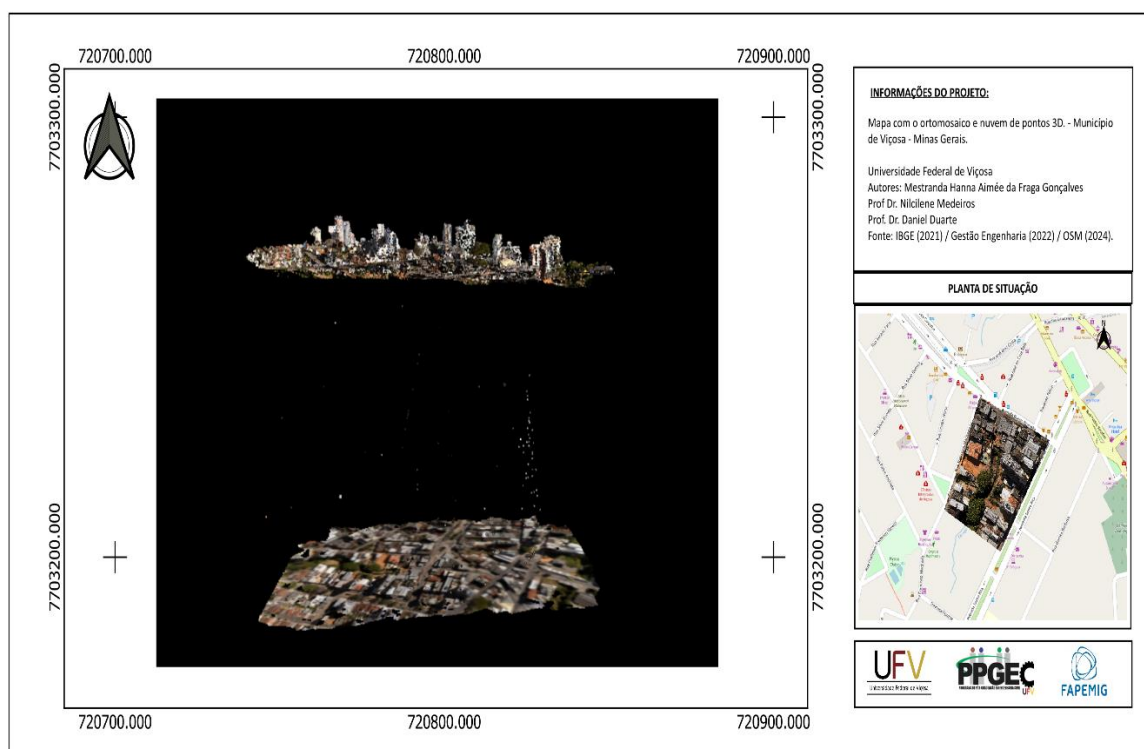
⁸ FRAGA, Hanna Aimée. **Mapa da nuvem de pontos com falhas de oclusão**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_OCLUSAO_HF.pdf. Acesso em: 26 fev. 2024.

⁹ FRAGA, Hanna Aimée. **Mapa da nuvem de pontos com falhas de registro**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_NUVEM_FALHAS_HF.pdf. Acesso em: 26 fev. 2024.

4.2 Análise de Perfil de Rota

Nos resultados da fase de análise, foi possível perceber na visualização 3D (Figura 17), que a nuvem de pontos não estava no mesmo plano altimétrico que o ortomosaico, sendo isso um indicativo de registro, para tal, ocorreu a geração do perfil da rota (Figura 18) para que pudesse ser localizado, sendo classificado como registro fora do intervalo de 639 – 692 metros e adotando esse critério visual, o mesmo foi removido, conforme expressa a Figura 18. Ressalta-se que esse intervalo foi definido tendo como fundamentação análise do perfil de rota.

Figura 17 - Mapa com ortomosaico e nuvem de pontos 3D




10

Fonte: Autora, 2024.

¹⁰ FRAGA. Hanna Aimée. **Mapa com o ortomosaico e nuvem de pontos 3D**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_ORTO_NUVEM_HF.pdf. Acesso em: 26 fev. 2024.

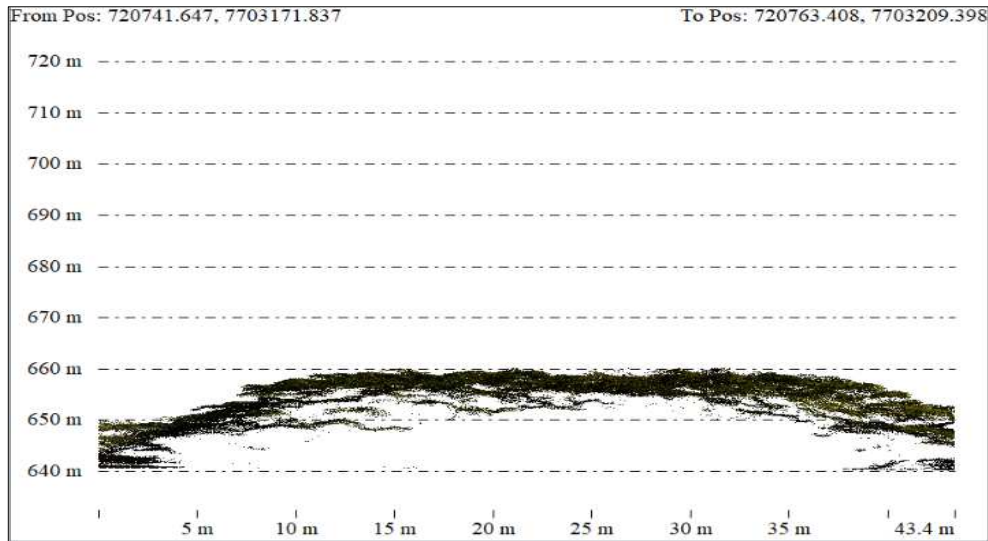
Figura 18 - Perfil de rota



Fonte: Autora, 2024.

Ao realizar a análise dos perfis de rota nas árvores, conforme representado na Figura 19, observou-se a ausência de penetração do *LiDAR* na vegetação, evidenciando que a maioria estão concentrados na altura das árvores, sem alcançar o solo. Essa limitação na capacidade de penetração pode ter implicações significativas na obtenção de informações detalhadas sobre a estrutura vertical da vegetação e, conseqüentemente, na precisão dos resultados relacionados à cobertura vegetal e a determinação da classe solo. Ressalta-se que esta ausência de penetração *LiDAR* é inesperada, tendo em vista que o *laser* penetra nas árvores.

Figura 19 - Perfil de rota - vegetação



Fonte: Autora, 2024.

4.3 Calibração da Nuvem de Pontos

Para calibração da nuvem de pontos, foram coletados 15 pontos de controle, na qual, os alvos utilizados para os pontos de controle foram de caráter natural, ou seja, alvos que estão visíveis na imagem, como: bueiros; caixa de eletricidade; caixa de esgoto; caixa de águas pluviais; e, canto da faixa de pedestre (Figura 20). Ressalta-se que para a calibração o referencial altimétrico foi elipsoidal.

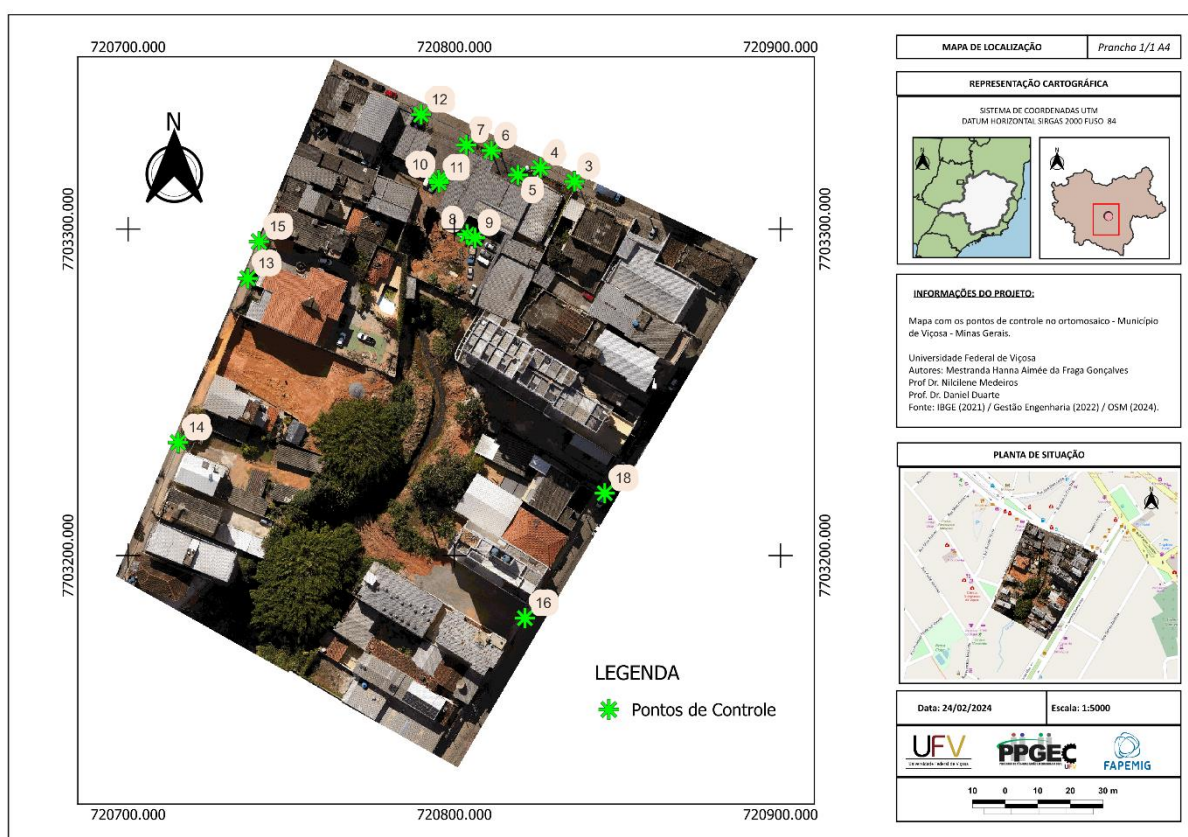
Figura 20 - GCPs em alvo natural



Fonte: Autora, 2024.

Para melhor entendimento, produziu-se o mapa com os pontos de controle representados na área de estudo (Figura 21) e o Gráfico 1 com a discrepância posicionais altimétricas, na qual encontra-se no Apêndice B o relatório de ajustamento na íntegra. Expressa-se também, a dificuldade em acessar a região central da área de estudo, visto que não são de acesso público e sim de área privada. Por isso, não se deu uma espacialização melhor dos pontos de controle.

Figura 21 - Mapa com os pontos de controle

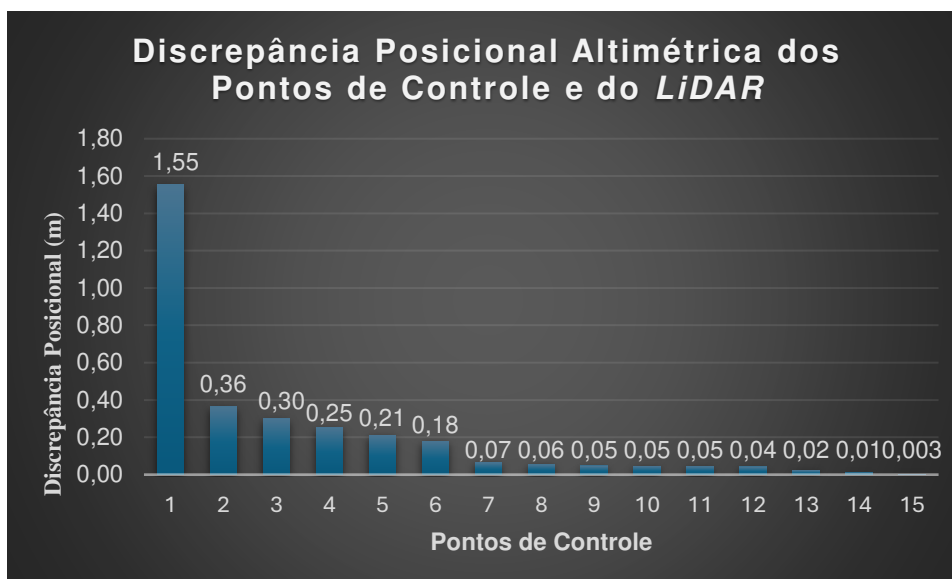


11

Fonte: Autora, 2024.

¹¹ FRAGA, Hanna Aimée. **Mapa com os pontos de controle**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_GCPS_HF.pdf. Acesso em: 26 fev. 2024.

Gráfico 1 - Métricas do GCPs.



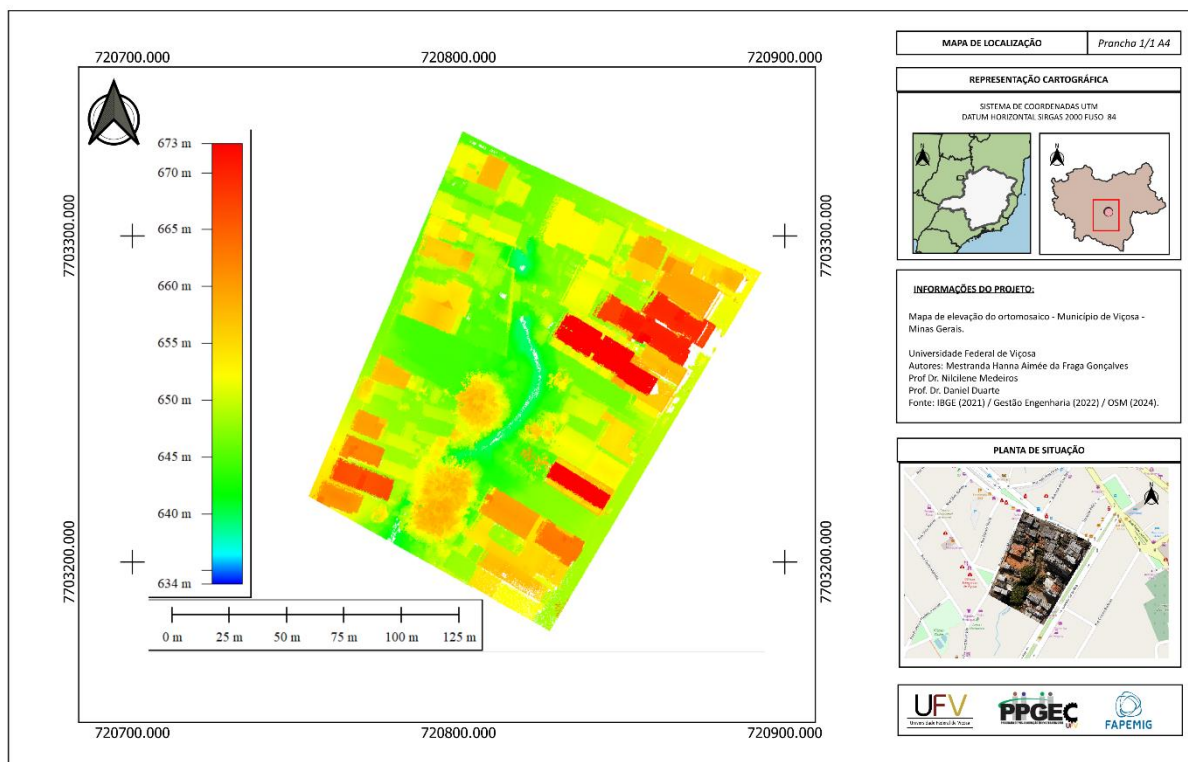
Fonte: Autora, 2024.

No que tange ao Gráfico 1, expressa-se que a “Discrepância Posicional Altimétrica dos Pontos de Controle e do *LiDAR*”, é a diferença entre a elevação esperada dos pontos de controle e os valores *LiDAR* medidos, ou seja, foi calculado sobre os pontos de controle, sendo um valor absoluto da diferença entre os pontos de controle e da nuvem de pontos.

A título de discussão, ressalta-se que os *GCP*'s são fundamentais para garantir a qualidade dos produtos gerados a partir de imagens e dados espaciais. Ao incluir pontos de controle em uma análise geoespacial, é possível corrigir distorções geométricas, eliminar erros sistemáticos e calibrar imagens para que elas correspondam com acurácia à realidade do terreno.

Ao final do ajustamento obteve-se um RMSE altimétrico de 0.431 metros, correspondência próxima encontrada para os 15 pontos de controle, ou seja, \cong 43 centímetros de medida em relação a diferença entre a elevação esperada dos pontos de controle e dos valores *LiDAR* medidos. Gerando então o mapa de elevação, onde leva-se em consideração a altitude elipsoidal (Figura 22).

Figura 22 - Mapa de elevação



12

Fonte: Autora, 2024.

4.4 Classificação Solo e Não Solo

Mediante o tratamento de dados da nuvem de pontos no pré-processamento, procedeu-se com a classificação de solo e não solo, e nessa etapa foram analisados os parâmetros da seguinte forma:

- Tamanho da barra: adotou-se o valor de 0,5 metro;
- Desvio máximo: foi utilizado o valor de 0,3 metros, tendo em vista sua influência na modelagem da superfície do solo, além disso, esse valor é orientado para superfícies com variação moderada de altura;
- Diferença máxima de altura: foi coletada através dos atributos dos dados vetoriais da nuvem de pontos (Tabela 1), obtida através dos dados com as alturas acima do solo.
- Declividade máxima do terreno: adotou-se a orientação de $7,5^\circ$, com a fundamentação de que a área estudada apresenta pequenas variações

de declividade do solo, tendo algumas variações maiores somente na região próximo ao córrego (Figura 15).

- Largura máxima de edificação: recorre-se aos atributos dos dados vetoriais além da análise geométrica das edificações (Figura 23), atingindo 25 metros. Desse modo, foi classificada a nuvem de pontos de solo (Figuras 24 e 25), utilizando tais parâmetros.


Tendo em vista que a nuvem de pontos investigada apresenta 2.936.429 milhões de pontos e que são dados vetoriais, tem-se então na Tabela 1, as 2.936.429 linhas referente a cada ponto e com os atributos elevação (m) e altura acima do solo (m). Logo, por conta da quantidade, atribui-se na Tabela 1 apenas algumas das milhões de linhas encontradas nos atributos vetoriais.

Tabela 1 - Atributos vetoriais da nuvem de pontos 3D

Elevação (m)	Altura Acima do Solo (m)
651,101	8,447
646,478	2,739
650,904	8,566
(...)	(...)
656,677	12,243

Fonte: Autora, 2024.

Figura 23 - Mapa com métrica da construção

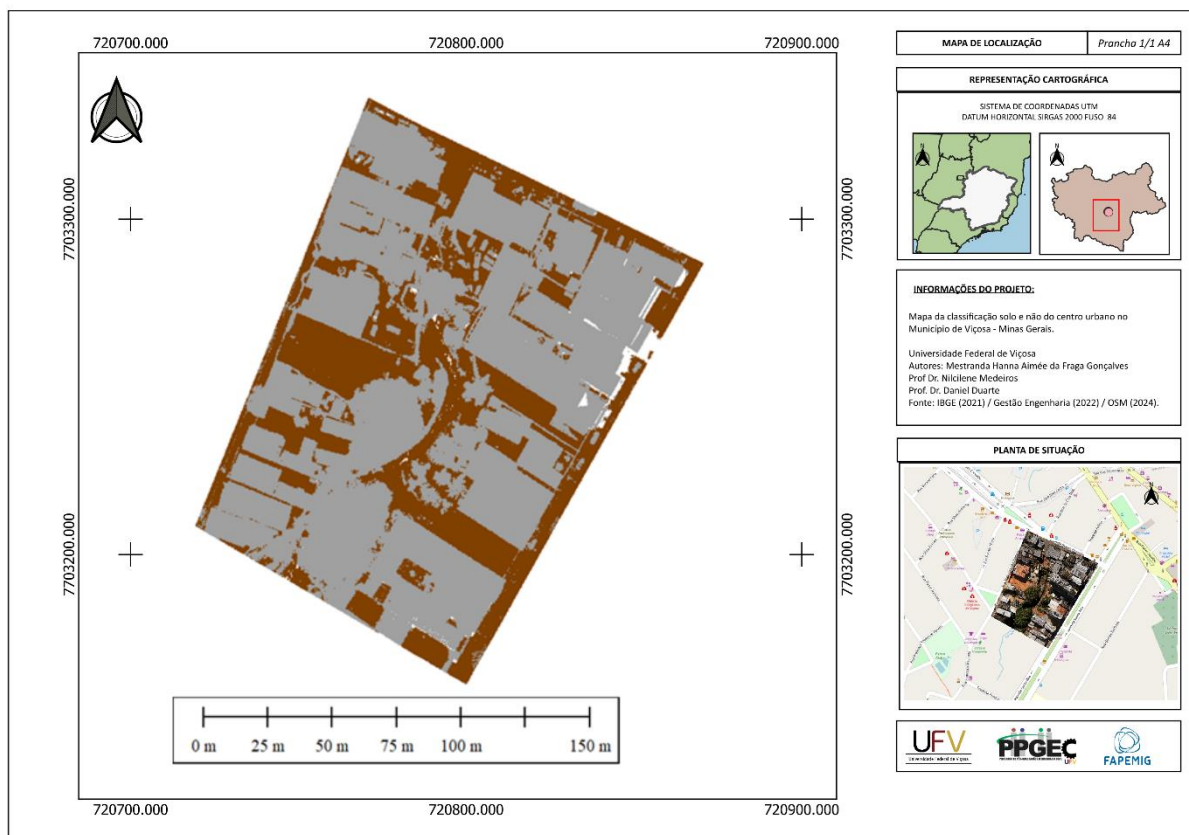


13

Fonte: Autora, 2024.

¹³ FRAGA. Hanna Aimée. **Mapa com métrica da construção**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CONSTRUCAO_HF.pdf. Acesso em: 26 fev. 2024.

Figura 24 - Mapa classificação solo e não solo



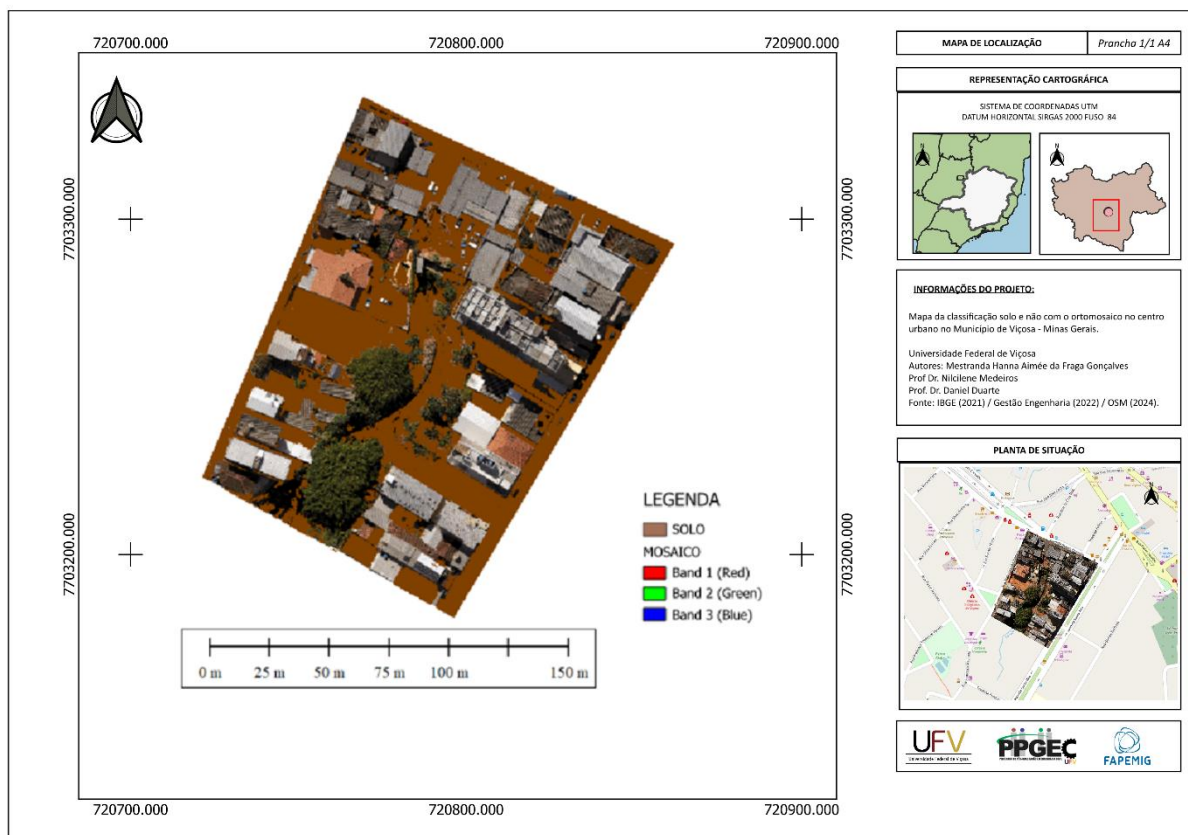
14

Fonte: Autora, 2024.

Para uma análise temática mais aprimorada, incorporou-se uma nuvem de pontos em segundo plano, previamente classificada para identificar exclusivamente a categoria de solo (Figura 25).

¹⁴ FRAGA, Hanna Aimée. **Mapa classificação solo e não solo**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CLASS_SOLO.pdf. Acesso em: 26 fev. 2024.

Figura 25 - Mapa classificação solo e não solo com o ortomosaico



15

Fonte: Autora, 2024.

Levando em consideração a particularidade da região em sua maior abrangência de área construída, o solo ocorre somente entre os prédios e onde não há árvores. Visto que não há penetração dos feixes de raios de *laser* nas árvores, excluem-se os pontos de solo no meio das árvores, logo o percentual de classificação quando analisado de forma temática, se mostra coerente visualmente com a realidade geográfica da área.

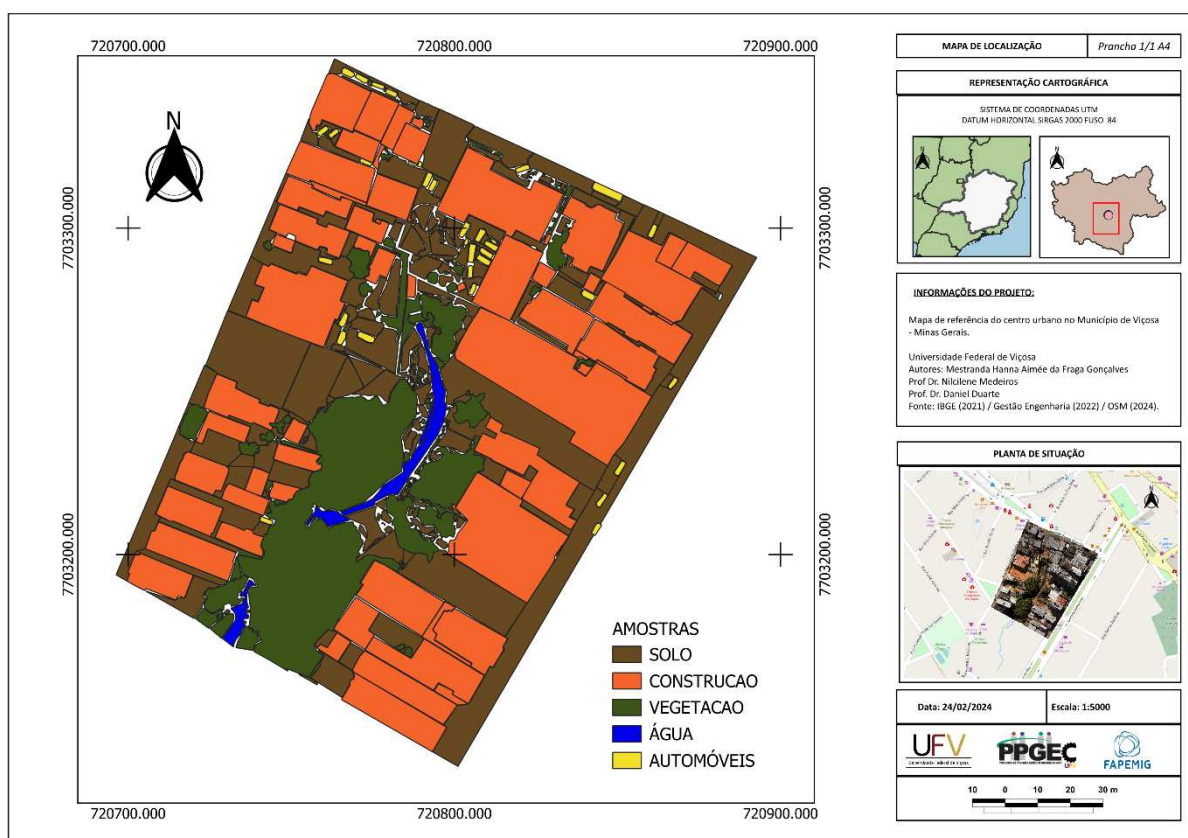
Evidencia-se a importância do entendimento e aplicação da filtragem, desde a compreensão breve da área de estudo até a coleta de informações espaciais da forma mais fiel possível em relação à realidade da região. Neste caso, devido ao terreno apresentar poucas mudanças de declividade, optou-se pela aplicação do padrão de declividade, sendo de $7,5^\circ$, ao contrário dos demais parâmetros, como a diferença de altura e largura das edificações.

¹⁵ FRAGA. Hanna Aimée. **Mapa classificação solo e não solo com a ortofoto**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CLASS_ORTO_HF.pdf. Acesso em: 26 fev. 2024.

A fim de solidificar a análise temática da classificação em consonância com a realidade da região em estudo, tornou-se imperativo a exposição de pontos comparativos utilizando o mapa referencial (Figura 26).

Nesse contexto, procedeu-se à coleta de forma manual (vetorização) das informações relacionadas às classes de solo exposto, vegetação e construção. A somar, para fins somente de representação da área, categorizou o córrego e os automóveis, tendo em vista a não penetração do *LiDAR* na água e da não classificação da classe dos automóveis.

Figura 26 - Mapa referencial




16

Fonte: Autora, 2024.

Nessa abordagem comparativa, os pontos críticos e eficazes foram analisados, como evidenciados nas Figuras 27 e 28. Este procedimento permitiu uma


compreensão mais profunda das discrepâncias e concordâncias entre a classificação realizada e a realidade da região em estudo.

Figura 27 - Pontos críticos - solo



Fonte: Autora, 2024.


Figura 28 - Pontos eficazes - solo



Fonte: Autora, 2024.

Acrescido disto, segue o antes e depois da classificação de solo e não solo comparada com o ortomosaico (Figura 29), com objetivo de relatar os pontos eficazes da classificação.

Figura 29 - Antes x depois - classificação solo e não solo



Fonte: Autora, 2024.

Nota-se que, mesmo com os parâmetros de classificação, ainda é possível perceber algumas falhas (Figura 27), como em 'barreiras' de areia com pedras em torno do córrego. Quase toda a trajetória foi classificada corretamente, mas em alguns trechos o classificador não atribuiu os *pixels* em nenhuma das classes trabalhadas, definindo como “não classificadas”. Um dos motivos para isto, além do córrego, se justifica também porque ao aumentar a altura mínima do solo, a classificação abrange os automóveis.

A sugestão para resolver essa situação específica seria realizar um novo levantamento com a banda espectral do infravermelho próximo (*NIR*, do inglês *Near-Infrared*), com o intuito de gerar índices espectrais e colorizá-los com a nuvem de pontos para uma reclassificação com os alvos críticos dessa classe.

No que concerne aos pontos classificados (Figura 28), o algoritmo resultou em uma classificação satisfatória, tendo em vista sua aprendizagem baseada nos filtros

expressados anteriormente. Detecta-se também o alinhamento da classificação eficaz em torno de construções, vegetação e automóveis.

4.5 Classificação Edificação e Vegetação

Prosseguiu-se com a classificação de edificações e vegetação adotando como filtragem os parâmetros de distância máxima, diferença angular máxima, altura mínima acima do solo, área mínima de ocupação do solo e área máxima de ocupação do solo para as classes espectrais de construção e dispersão mínima da árvore, distância máxima da árvore, altura mínima acima do solo e limite de vegetação média para a classe espectral de vegetação (Tabela 2).

Tabela 2 - Tabela com parâmetros - edificação e vegetação

Método de grade
Distância Máxima (m): 0.09
Diferença Angular Máxima (°): 5
Edifício
Altitude Mínima Acima do Solo (m): 3
Área Mínima de Ocupação do Solo (m ²): 10
Área Máxima de Ocupação do Solo (m ²): 10000
Vegetação
Dispersão Mínima Árvore (m): 4
Dispersão. Máxima Árvore (m): 15
Altitude Mínima. Acima do Solo (m): 2
Limite de Vegetação Média (m): 10
Limite de Vegetação Máxima (m): 18

Fonte: Autora, 2024.

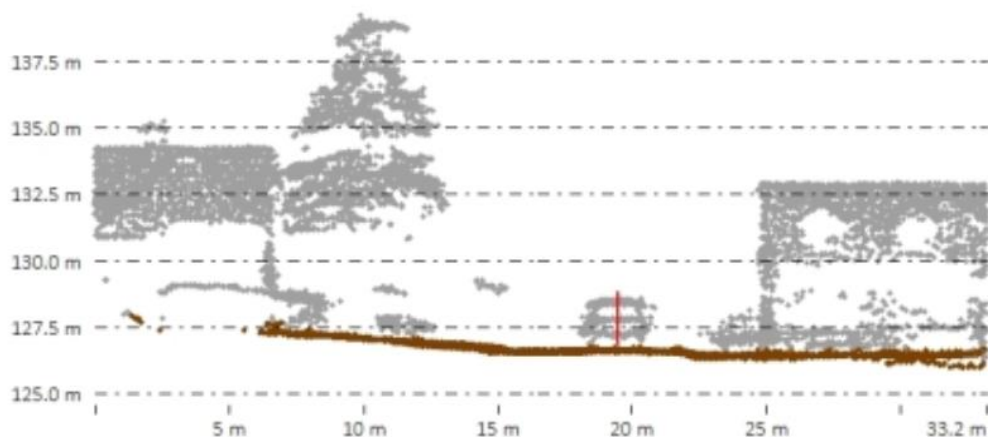
Quanto aos parâmetros usados (Tabela 2), para a sua definição também foram analisadas as características da área como a declividade, altura máxima e mínima de ocupação do solo e acima do solo, além das peculiaridades da vegetação, filtragens por cores, distância, retornos, alturas, tamanho de barra, ou seja, aspectos espectrais e geométricos.

No âmbito da distância máxima, considerou-se a densidade presentes na nuvem de pontos de $123,77 \text{ pixels/m}^2$, buscando melhor espacialização de busca para a classificação, o mesmo foi considerado para a distância mínima de vegetação. E na diferença angular máxima adotou-se o valor de 5° correspondente entre a angulação máxima entre os planos adjacentes de melhor ajuste (Global Mapper, 2023).

No que compete a vegetação, o parâmetro de altura mínima do solo está relacionado com a altura mínima que determinado ponto dever ter para ser considerado possivelmente classe de construção ou vegetação alta, tal esse recurso foi usado para diferenciar arbustos, ajudando inclusive a minimizar e até mesmo eliminar, classificação errônea com os automóveis.

Bem como ilustrado na Figura 30, a linha marrom mostra a altura acima do solo quando comparada com o carro, todos os pontos abaixo dessa linha serão eliminados da classificação de construção e vegetação. Para esse filtro, adotou-se o valor de 3 metros.

Figura 30 - Parâmetros de filtragem - vegetação



Fonte: Global Mapper, 2023.

A Determinação do limite de vegetação média e máxima dessa área é respaldado nos atributos de dados vetoriais, além da conferência dos pontos através da tabela de atributos da nuvem de pontos. A altura mínima de ocupação do solo está diretamente ligada com a influência da área de *pixels* ocupados, assim, definiu-se o valor de 10 m², tendo em consideração a presença de automóveis na região (Figura 31), ressalta-se que a área do automóvel é de $\cong 6$ m².

Figura 31 - Altura da ocupação solo



Fonte: Autora, 2024.

Quanto as dispersões mínima e máxima de árvores, utilizou-se a ferramenta “Extração de Feições”, onde ocorre a extração das feições em 3D, neste caso, gerou-se as árvores e polígonos em torno de cada árvore (Figura 32). Com isso, ocasionou-se em uma tabela de atributos com os dados vetoriais de cada árvore individualizada, contendo as métricas de dispersão máxima e mínima da copa. Partindo disso, realizou-se a média de cada dispersão, na qual, chegou-se nos valores de 4 metros para dispersão mínima e 15 metros para dispersão máxima.

Figura 32 - Árvores extraídas e polígonos de cobertura



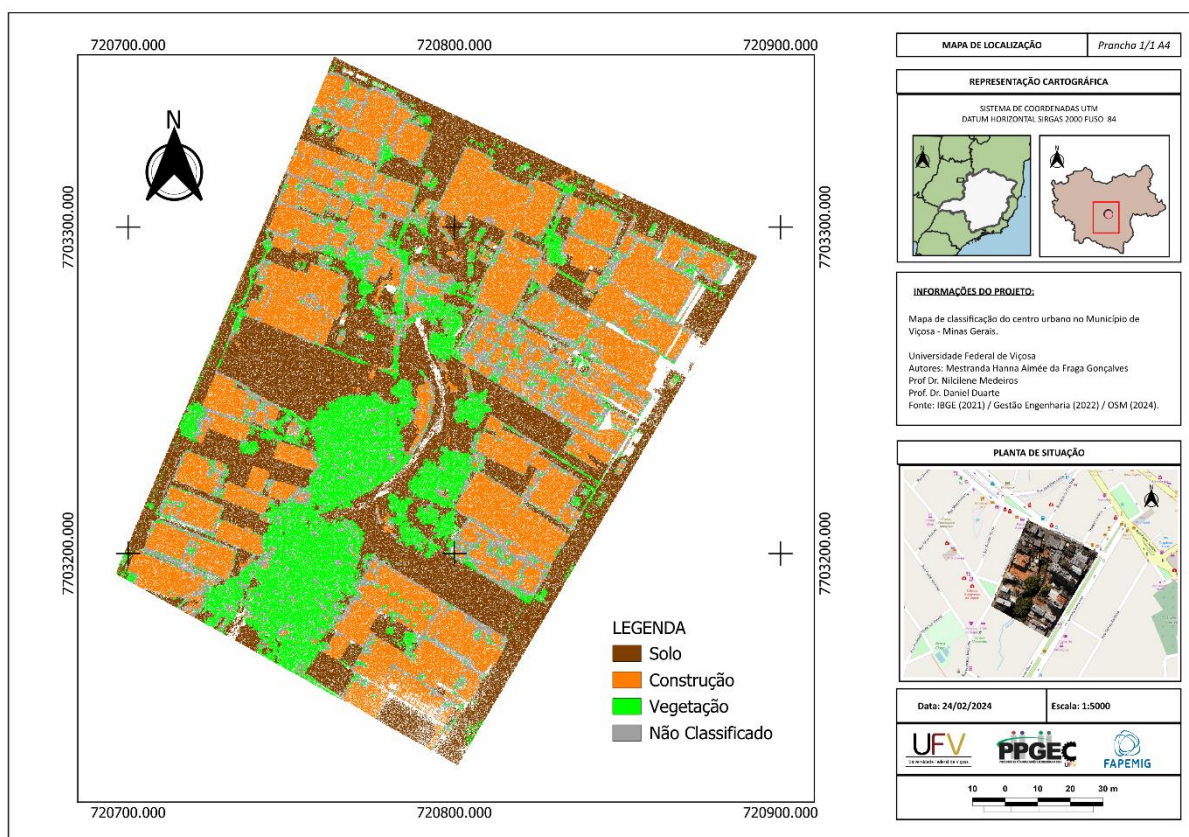
Fonte: Autora, 2024.

Acrescentado a isso, a distância máxima no método de grade foi aproximadamente a do espaçamento entre os pontos da nuvem, ou seja, de $\cong 9$ cm, tendo em consideração o objetivo de representar da forma mais fiel os dados fornecidos e com isso refinar a classificação.

Visando a classificação diferenciada dos grupos de vegetação, para essa específica área, não foram adotadas as ramificações entre vegetação rasteira, média e densa, tendo em vista as características presentes na área. Por fim, foi possível obter o modelo classificado, Figura 33.

Com o modelo classificado (Figura 33) iniciou-se a análise da classificação executada, expondo os pontos críticos e os pontos classificados de maneira eficaz. Nesta classificação utilizou o mapa de referencial, e o ortomosaico como análise espacial referente a classificação.

Figura 33 - Mapa classificação final da nuvem de pontos



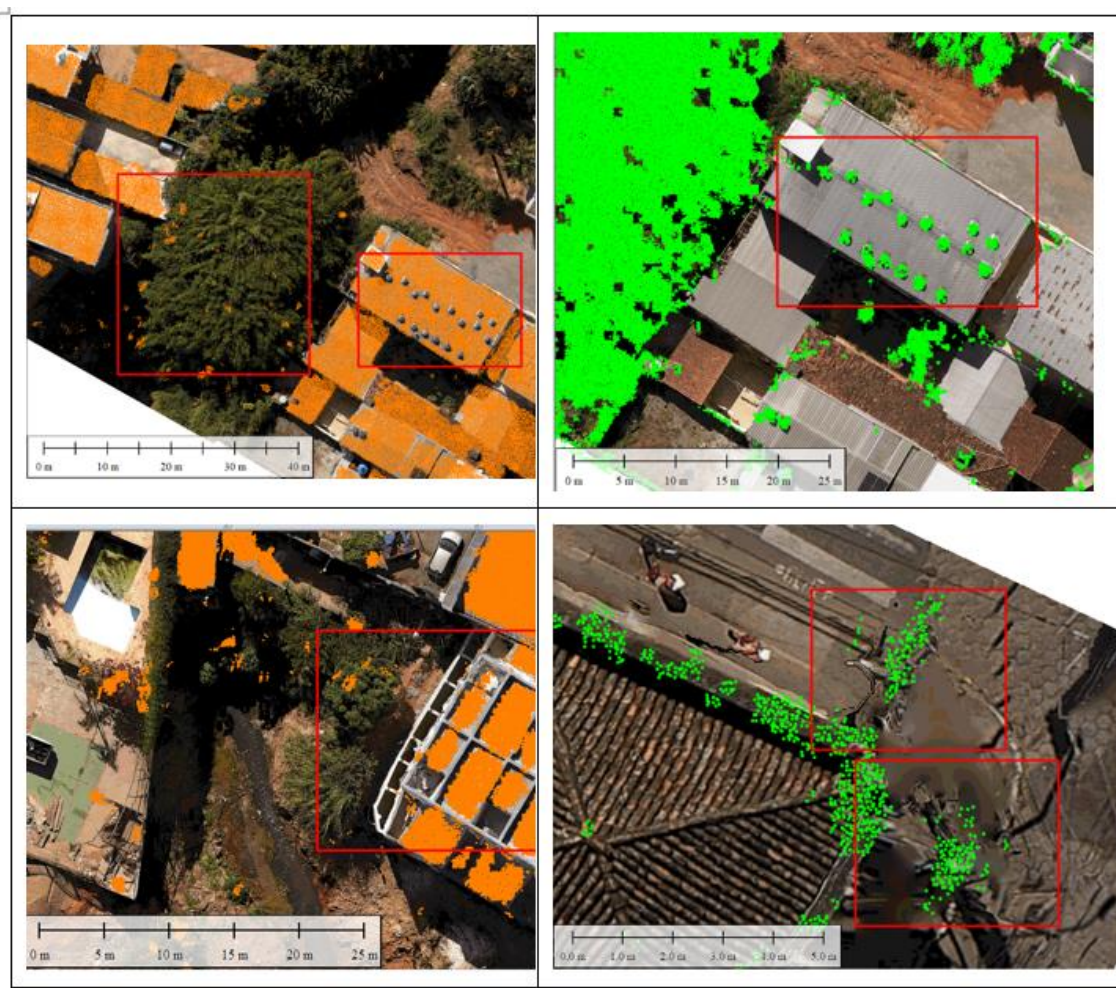
17

Fonte: Autora, 2024.

Nota-se no modelo classificado a presença de *pixels* de vegetação na classe espectral de construção e vice e versa (Figura 34). Uma possível justificativa para isto, é a ausência de penetração de feixes do *laser* no solo na varredura da vegetação. Adicionalmente, ressalta-se que as distorções também são fatores que não contribuem para a caracterização espectral e geométrica da classe.

¹⁷ FRAGA, Hanna Aimée. **Mapa classificação final da nuvem de pontos**. 2024. Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CLASS_FINAL_HF.pdf. Acesso em: 26 fev. 2024.

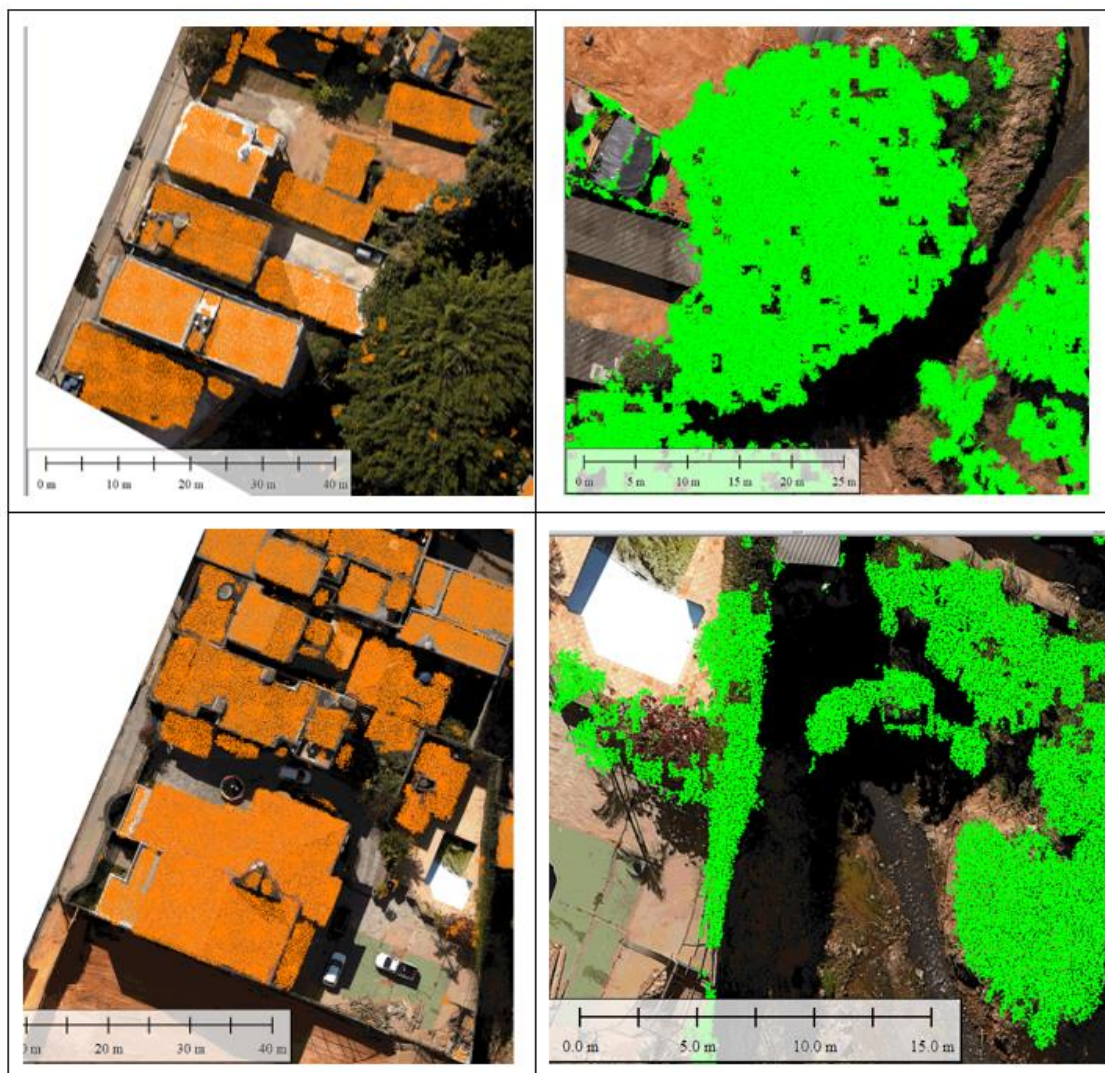
Figura 34 - Pontos críticos - edificações x vegetação



Fonte: Autora, 2024.

Além do mais, houve confusão entre os exaustores eólicos nos telhados, isso pode ser explicado por conta de o formato dos exaustores serem confundidos com a textura similar, Figura 34. Apesar de apresentar pontos críticos e de não seguir a classificação ideal, neste trabalho, buscou-se a maior fidelidade possível, tendo em vista a classificação automatizada, resultando nos produtos com pontos eficazes representados na Figura 35.

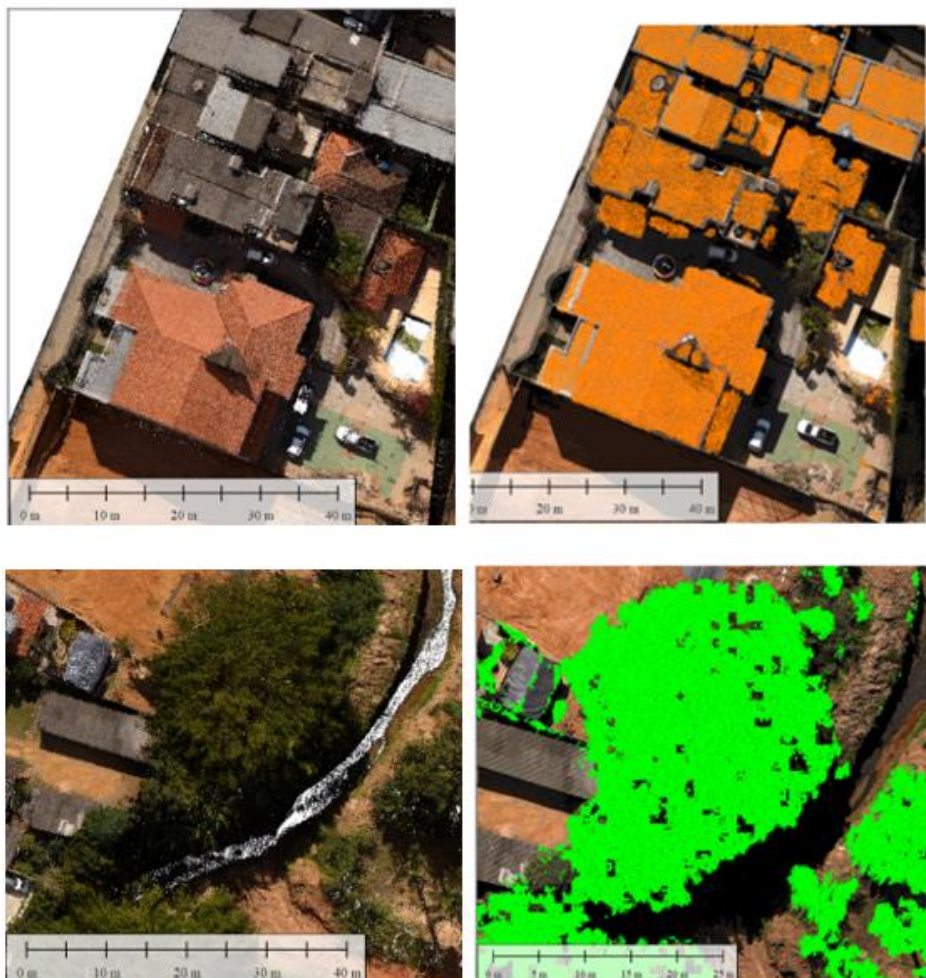
Figura 35 - Pontos eficazes - edificações e vegetação.



Fonte: Autora, 2024.

É importante ressaltar que nos pontos classificados obteve-se resposta positiva quanto a sua discriminação de classes em quase sua totalidade, bem como ilustrado na Figura 36. Ademais, os parâmetros de altura mínima acima do solo e área mínima de ocupação do solo foram fundamentais para evitar a confusão do algoritmo entre as alturas das edificações e dos automóveis.

Figura 36 - Antes x depois - classificação edificação e vegetação



Fonte: Autora, 2024.

Ao final da classificação, obteve-se o percentual de classificação de cada classe espectral, na qual, expressa-se que a área classificada como solo abrange 32,24% da região, representando aproximadamente 946.818 pontos. Além disso, o percentual de não classificado pode ser explicado pela não identificação do classificador em nenhuma das classes espectrais escolhidas, sendo solo, vegetação e construção. A somar, pode-se ter influência da dificuldade de absorção e dispersão de luz pela água e dos automóveis presentes na área. Tais dados (Tabela 3) são fornecidos após a classificação.

Tabela 3 - Dados de classificação

Classes LiDAR	Classificação	Contagem dos pontos	%
0	Não classificado	516.267	17.58
2	Solo	943.818	32.24
5	Vegetação	425.324	15.40
6	Construção	1021.020	34.77

Fonte: Autora, 2024.

Em relação a classe solo, nota-se o percentual menor da classe construção, o que é coerente ao analisarmos a área (Figura 7), pois predomina-se a classe construção. Além disso, considera-se nesta classificação a pavimentação pertencente a classe solo, o que se pode implicar no somatório do percentual.

A vegetação na região é menor quando comparada as classes espectrais de construção e solo, na qual, os dados da classificação foram coerentes com a realidade do levantamento, sendo a maior concentração de vegetação em torno do córrego. Em relação a classe construção, o percentual foi superior quando comparado com as outras classes espectrais, o que é entendível ao se analisar a região urbanizada de Viçosa – MG. Além disso, observa-se o indicativo de expansão urbana na região de solo exposto na direção Oeste da cena (Figura 29), visto que a mesma apresenta materiais de construção ao entorno e solo exposto entre as construções.

Destaca-se que a filtragem da nuvem de pontos não apenas auxilia a análise, mas também demonstra a relevância e a extensão da presença de solo na área estudada. Esses dados detalhados proporcionam uma base precisa para investigações mais aprofundadas, oferecendo *insights* valiosos.

4.6 Validação da Classificação

Para a etapa de validação da classificação, utilizou-se o mapa referencial (Figura 26) realizado com coleta manual, para se ter uma base mais confiável na identificação das classes temáticas, tendo em vista o poder de interpretação do usuário, conhecimento da área e contextualização dos alvos da cena. Tal mapa foi utilizado na análise de acurácia do algoritmo classificatório, ou seja, analisar de forma

quantitativa o quanto foi eficaz no processamento, analisando desta forma seu desempenho. Para tal, adotou-se a matriz de confusão, expressa na Tabela 4, tendo como avaliador métrico o índice e variância do *Kappa*.

Tabela 4 - Matriz de confusão

Unidade avaliada	Unidade de referência			Total Linhas	%
	Solo	Vegetação	Construção		
Solo	235	10	6	251	86
Vegetação	32	128	97	257	93
Construção	6	0	295	301	74
Total Coluna	273	138	398	809	

Fonte: Autora, 2024.

Com isso, ocorreu a validação de forma quantitativa dos resultados, sendo que o produto avaliado de acordo com ET-CQDG/2016, adotou-se com avaliador exatidão global, coeficiente *Kappa* e variância. Sendo assim, foi possível avaliar a classificação final de acordo com o conjunto de dados geoespaciais vetoriais (CDGV) em grandes escalas, tendo em vista a escala 1:5000 da nuvem classificada (Figura 33).

Tendo em vista que a matriz de confusão compara as previsões de um modelo com as classes reais, o uso da acurácia temática é frequentemente usado para calcular várias métricas de desempenho. Dessa maneira, a exatidão global da classificação foi de 0.81, ou seja, 81% (Tabela 5) do modelo classificado está mais próximo da realidade encontrada com as observações precisas.

Por conseguinte, foi obtido o índice *Kappa* de 0.72 (Tabela 5) e a variância do *Kappa* ($VAR_{\hat{k}}$) de $\cong 0.0004$ (Tabela 6), isso significa que se tem a classificação avaliada com concordância substancial no que tange a estatística do *Kappa*, e a variância do *Kappa* como maior que zero, ou seja, essa classificação é melhor do que ao acaso no modelo tridimensional classificado (Figura 37).

Fundamentando-se ET-CQDG (2016, p. 62) para a validação da nuvem de pontos classificada, tem-se que a conformidade permitida é menor que 4%, ou seja, a exatidão global deve apresentar resultados melhores que 96%, tendo em vista que a

nuvem classificada obteve exatidão global de 81%, logo a classificação não foi satisfatória. Porém, a nuvem de pontos classificada pode subsidiar estudos geométricos no que tange a área urbanizada, tal como as medições das edificações, áreas de vegetação, subsídio para análise temática do uso e ocupação do solo e MDT. Esses são apenas alguns exemplos de estudos geométricos que a classificação da nuvem de pontos pode fornecer para o cadastro territorial multifinalitário.

Tabela 5 - Cálculo da exatidão global e *Kappa*

Validação	Resultado	%
Exatidão global	0.81	81
<i>Kappa</i>	0.72	72

Fonte: Autora, 2024.


Tabela 6 - Cálculo variância do *Kappa*

Variáveis	Resultado
θ_1	0.813349815
θ_2	0.341930476
θ_3	0.580467577
θ_4	0.538751183
Variância do <i>Kappa</i>	0.000410384

$K > 0$ – Classificação é melhor do que ao caso

Fonte: Autora, 2024.

Figura 37 - Modelos 3D classificado



Fonte: Autora, 2024.

5 CONCLUSÕES

O uso de mapas temáticos derivados de dados *LiDAR* tendenciam a construção de mapeamentos com nível de refinamento na qualidade que atendem as peculiaridades territoriais. Na qual, pode-se citar mapas temáticos utilizados no CTM, mapa planialtimétrico, mapa de aptidão do solo, mapa de uso e ocupação da terra, mapa de declividade, mapa de rede hidrográfica, mapa viário, bem como explica Julião (2015).

No que tange a análise temática, verificada por meio do conhecimento das características antrópicas e naturais da região com visitas *in loco*, do ortomosaico e do mapa referencial, conclui-se que tais insumos foram fundamentais para a análise espacialmente do modelo classificado quando equiparado a realidade da região. Além disso, tais fatores influenciaram no alcance de um melhor resultado na classificação de nuvem de pontos, devido a inserção dos aspectos geométricos da nuvem de pontos na definição dos parâmetros da classificação.

Entende-se também que a compreensão da realidade espacial da área de estudo é ferramenta diferencial na análise temática da classificação. O conhecimento técnico para as análises de interpretação nas respostas de classificação do algoritmo é muito importante, pois a análise temática atrelada a métrica, são ações para validação dos produtos.

A interpretação qualitativa é essencial para compreender as respostas de classificação. A identificação de registro e calibração altimétrica na nuvem de pontos contribuem diretamente para a melhoria da qualidade dos dados geoespaciais, proporcionando uma representação mais fidedigna do ambiente estudado. A definição cuidadosa de parâmetros, como altura mínima e área mínima de ocupação do solo, mostrou-se importante para a inserção dos parâmetros da área estudada. Além disso, a adaptação da distância máxima no método de grade contribuiu para representação dos dados.

A vantagem em realizar a classificação de forma não manual e utilizar algoritmos automáticos ou semiautomáticos reside na eficiência e na velocidade do processo. Os algoritmos automatizados podem processar grandes conjuntos de dados de forma rápida e consistente, reduzindo significativamente o tempo e o esforço necessários para classificar os dados. Além disso, a abordagem automatizada

minimiza o viés humano e a subjetividade na classificação (quando não se tem o conhecimento da área), proporcionando resultados mais objetivos e consistentes. Ao empregar algoritmos de classificação em nuvem de pontos, é possível utilizar grandes volumes de dados de forma eficiente, identificando padrões e características específicas de forma mais rápida do que seria possível manualmente. Isso é particularmente útil em cenários onde a precisão e a rapidez na análise são essenciais, como em projetos de Gestão Territorial.

Apesar de não atender plenamente às especificações da ET-CQDG/2016, a nuvem de pontos classificada pode ser útil para subsidiar estudos geométricos na área urbanizada. Esses estudos incluem medições de edificações, áreas de vegetação e análise do uso e ocupação do solo, MDT e dentre outros.

A avaliação da qualidade dos produtos gerados é importante para a tomada de decisões em projetos de: planejamento urbano; elaboração de Plano Diretor; zoneamento urbanístico; delimitação de áreas de expansão urbana; ordenamento territoriais; diagnósticos territoriais; dimensionamento de rede de drenagem, de sistema viário, fluxos de transportes e mobilidade urbana; gestão ambiental; gestão de recursos hídricos; conservação da biodiversidade; análises multi-temporais; levantamento planialtimétrico e cadastrais; *as built*; dentre outros. Enfim, com base nos resultados apresentados, verifica-se que a abordagem adotada, tem-se implicações significativas na Gestão Territorial e na utilização prática dessas informações. Permitindo aos gestores do executivo e legislativo do Município, tomar decisões acuradas e detalhadas no que acerca as características geográficas do Município visando políticas públicas para o ordenamento e desenvolvimento territorial.

Sugere-se abordagens diferentes para futuros estudos, tais como:

- Obtenção de mapeamento fotogramétrico contendo as bandas do espectro visível e no *NIR*. A barreira da falta de penetração na vegetação destaca a necessidade de explorar dados *LiDAR* com RGB + *NIR* em pesquisas futuras.
- Criação de novas classes *LiDAR*, tendo em vista as especificações da *American Society for Photogrammetry and Remote Sensing (ASPRS)*, visando aprimorar a diferenciação entre edificações, pavimentação e estruturas de diferentes andares;

- Uso da técnica do filtro majoritário no *raster*, onde desempenha um papel importante na eliminação de *pixels* que podem ter sido incorretamente classificados, manifestando-se como pontos dentro das categorias designadas;
- Inserção integrada de parâmetros espectrais e geométricos na classificação;
- Utilização de algoritmos de Inteligência Artificial na classificação.

Em conclusão, a aplicação prática e eficaz do *LiDAR*, aliada à classificação da nuvem de pontos, são fatores que podem subsidiar os estudos geográficos presentes na Gestão Territorial, como no diagnóstico de expansão urbana, sendo este de suma importância para o planejamento ordenado do território. A precisão aprimorada, a análise detalhada da nuvem de pontos e a capacidade de enfrentar desafios complexos na classificação de uso e ocupação da terra são elementos-chave que proporcionam benefícios tangíveis. Essa abordagem não apenas resolve desafios específicos, mas também destaca a importância de utilizar tecnologias avançadas para promover uma Gestão Territorial mais sustentável e eficaz.

REFERÊNCIAS BIBLIOGRÁFICAS

- AMORIM, A., PELEGRINA, M. A. e JULIÃO, R. P. **Cadastro e Gestão Territorial: uma visão luso-brasileira para a implementação de sistemas de informação cadastral nos Municípios**. São Paulo: UNESP DIGITAL, 2018.
- ANJOS, Camila S. **Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não paramétricos**. Dissertação - Instituto Nacional de Pesquisas Espaciais, 2016.
- ANTONARAKIS, A. S.; RICHARDS, Keith S.; BRASINGTON, James. **Object-based land cover classification using airborne LiDAR**. Remote Sensing of environment, v. 112, n. 6, p. 2988-2998, 2008.
- ARAKI, H. **Fusão de Informações Espectrais, Altimétrica e de Dados Auxiliares na Classificação de Imagens de Alta Resolução Espacial**. Boletim de Ciências Geodésicas, v. 12, n. 1, p. 167-168, 2006.
- ARAÚJO, Adolfo Lino de **Cadastro 3D no Brasil a partir de varredura a laser (laser scanning)**. 2015. Tese (Doutorado) - - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2015.
- ARIZA, F.J. **Qualidade na Produção Cartográfica**, RA-MA, Madrid. 2002.
- AVERBECK, C. E. e CESARE, C. M. **Da Avaliação de Imóveis. Diretrizes para a Criação, Instituição e Atualização do Cadastro Territorial Multifinalitário (CTM) nos Municípios Brasileiros: Manual de Apoio**. Brasília. Ministério das Cidades, 2010.
- BERTÃO, Miguel Alexandre Vilela. **Seguimento multisensorial de objetos dinâmicos para aplicações robóticas**. 2018.
- BRASIL. **Portaria Nº 3.242 de 11 de novembro de 2022**. Diretrizes para a criação, instituição e atualização do Cadastro Territorial Multifinalitário (CTM) nos Municípios brasileiros. Brasília: Ministério do Desenvolvimento Regional, 2022.
- CAELLES, Sergi *et al.* **The 2018 davis challenge on video object segmentation**. arXiv preprint arXiv:1803.00557, 2018.
- CARNEIRO, Andrea Flávia Tenório. **Cadastro imobiliário e registro de imóveis: a lei n. 10.267/2001, decreto n. 4.449/2002 e atos normativos do INCRA**. Sergio Antonio Fabris, 2003.
- CARRILHO, A. C., Galo, M., SANTOS, R., & Pessoa, G. G. (2018). **Avaliação da extração automática de edificações a partir de dados LiDAR aerotransportado**. Anais do COBRAC, 2018.
- CARRILHO, André Caceres. **Extração e refinamento de contornos de telhados utilizando descritores geométricos e integração de dados LiDAR e imagens aéreas**. 2021.
- CAVALCANTI, R. C.; CANDEIAS, A. L.; TAVARES JUNIOR, J. R. **Metodologia para obtenção de polígonos 3D a partir de nuvem de pontos LiDAR**. Revista Brasileira de Geomática, v. 4, n. 1, p. 42-48, 2016.
- CHURCH, R. L.; MURRAY, A. T. **Business Site Selection, Location Analysis, and GIS**. John Wiley & Sons, 2009.

CHUVIECO, E.; HUETE, A. **Fundamentals of Satellite Remote Sensing**. New York, 2010: Taylor y Fransis group. 2016.

COHEN, J. **A coefficient of agreement for nominal scales**. *Educational and Psychological Measurement*, v. 20, n. 1, p. 37–46, 1960.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. *Remote Sensing of Environment*, v. 37, n. 1, p. 35–46, 1991.

CPE. **Drone DJI Matrice 300 + Laser Scanner AlphaAir 450**. Disponível em: <https://loja.cpetopografia.com.br/alphaair-450-drone-Matrice-300/#:~:text=O%20AlphaAir%20450%20combina%20GNSS,de%205%20a%2010%20cm..> Acesso em: 14 nov. 2023.

DCT/DSG. Norma da Especificação Técnica para Controle de Qualidade de Dados Geoespaciais – **ET-CQDG**. 1ª Edição. Brasília, 2016.

DE MORAES NOVO, Evlyn Márcia Leão; PONZONI, Flávio Jorge. **INTRODUÇÃO AO SENSORIAMENTO REMOTO**. Instituto Nacional de Pesquisas Espaciais (INPE). São José dos Campos, 2001.

DE RAMOS GIACOMINI, Queila; VUELMA, Ana Luiza. A IMPORTÂNCIA DO PLANEJAMENTO URBANO. **Seminário de Iniciação Científica e Seminário Integrado de Ensino, Pesquisa e Extensão**, p. e24927-e24927, 2020.

DUARTE, Daniel Camilo de Oliveira. **Análise multicritério e geoestatística aplicadas na avaliação em massa de imóveis urbanos**. 2019.

FOODY, G. M. **Status of land cover classification accuracy assessment**. *Remote Sensing of Environment*, v. 80, n. 1, p. 185–201, 2002.

FOODY, G.M. **On the compensation for change agreement in image classification accuracy assessment**. *Photogrammetric Engineering Remote Sensing*, v.58, n.10, p.1459-1460, Oct. 1992.

FRAGA, Hanna Aimée da Fraga. **Análise Comparativa da Classificação de Ortofoto Arp e Imagens de Sentinel-2a com Orfeo Toolbox em Figueira da Foz, Portugal**. 2021. 81 f. TCC (Graduação) - Curso de Engenharia de Agrimensura e Cartográfica, Departamento de Engenharia, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2021.

GARCÍA-BALBOA, J. L. **Normas de Calidad**. En: Experto Universitario em Evaluación de La Información Geográfica (4ª Edición). Master Universitario em Evaluación y Gestión de La Calidad de La Información Geográfica (1ª Edición). Jaén: Universidad de Jaén, 2011.

GESTÃO ENGENHARIA, **Gestão Engenharia**, Ponte Nova-MG, 2022

GHILANI, C. D.; WOLF, P. R. **Adjustment computations: spatial data analysis**. 4ª edição, editora Jonh Wiley & Sons, Inc. Estados Unidos da América. 2006.

GIACCOM-RIBEIRO, Bárbara M. **Sensoriamento remoto para mapeamento urbano: classificação de cobertura, uso e ocupação do solo**. XIX Simpósio Brasileiro de Sensoriamento Remoto-SBSR, p. 1811-1814, 2019.

GIONGO, Marcos *et al.* **LiDAR: princípios e aplicações florestais**. *Pesquisa Florestal Brasileira*, v. 30, n. 63, p. 231-231, 2010.

GLOBAL MAPPER. **Welcome to Global Mapper.** Disponível em: <https://www.bluemarblegeo.com/knowledgebase/global-mapper-25/GlobalMapper.htm>. Disponível em: 15 nov. 2023.

GOMES, M. *et al.* **Aplicação do interpolador IDW para elaboração de mapas hidrogeológicos paramétricos na região da Serra Gaúcha.** Scientia cum industria, v. 6, n. 3, p. 38-43, 2018.

HE, G. B.; LI, L. L. **Research and application of LiDAR technology in cadastral surveying and mapping.** The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 43, p. 33-37, 2020.

HUDAK, A. T., LEFSKY, M. A., COHEN, W. B., & BERTERRETICHE, M. (2002). **Integration of LiDAR and Landsat ETM+ data for estimating and mapping forest canopy height.** Remote sensing of Environment, 82(2-3), 397-416.

HUDSON, W.D.; Ramm, C.W. **Correct formulation of the Kappa coefficient of agreement.** Photogrammetric Engineering Remote Sensing, v.53, n.4, p.421-422, Apr. 1987.

ISO. **ISO 19157:2013.** Geographic information - Data quality. International Organization for Standardization (ISO), 2013.

JAKOB, A.A.E.; YOUNG, A.F. **O uso do método de interpolação espacial das análises sociodemográficas.** IN: Anais do XV Encontro Nacional de Estudos Populacionais, Caxambu-MG: ABEP, 2006, p. 1-22.

JENSEN, John R. **Remote sensing of the environment: An earth resource perspective 2/e.** Pearson Education India, 2009.

JULIÃO, Rui Pedro. **INFORMAÇÃO GEOGRÁFICA, CADASTRO E GESTÃO TERRITORIAL.** 2015.

KUMAR, Pankaj; RAHMAN, Alias Abdul; BUYUKSALIH, Gurcan. **Automated extraction of buildings from aerial LiDAR point cloud and digital imaging datasets for 3D cadastre—preliminary results.** Cadastre: Geo-Information Innovations in Land Administration, p. 159-165, 2017.

LANDIM, P.M.B. **Introdução aos métodos de estimação espacial para confecção de mapas.** DGA, IGCE, UNESP/Rio Claro, Lab. Geomatemática, Texto Didático 02, 20p, 2000. Disponível em: <http://www.rc.unesp.br/igce/aplicada/textodi.html>

LANDIS, J.R.; KOCH, G.G. **The measurements of observer agreement for categorical data.** Biometrics, v.33, n.3, p.159-179. Mar, 1977.

LILLESAND, Thomas; KIEFER, Ralph W.; CHIPMAN, Jonathan. **Remote sensing and image interpretation.** John Wiley & Sons, 2015.

LIN, Tsung-Yi *et al.* **Microsoft coco: Common objects in context.** In: Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13. Springer International Publishing, 2014. p. 740-755.

MENDES, Tatiana Sussel Gonçalves *et al.* **FILTRAGEM DE NUVEM DE PONTOS DE DADOS DE VANT: APLICAÇÃO EM ÁREA ÍNGREME.** XX Simpósio Brasileiro de Sensoriamento Remoto – SBSR - Florianópolis - SC, 2 - 5 de abril de 2023.

MENESES, P. R.; ALMEIDA, T. d. **Introdução ao processamento de imagens de sensoriamento remoto.** Universidade de Brasília, Brasília, 2012.

MESSIAS, Cassiano Gustavo; COBRA, Rafael Lacerda. **CLASSIFICAÇÃO DE IMAGENS LANDSAT E MUDANÇAS NO USO DO SOLO DE UMA ÁREA DA REPRESA DE FURNAS, ENTRE OS ANOS DE 2004 E 2014**. Simpósio Nacional de Geografia e Gestão Territorial e Semana Acadêmica de Geografia da Universidade Estadual de Londrina, v. 1, p. 674-687, 2018.

MIKHAIL, E.; ACKERMAN, F. **Observations and Least Squares**. University Press of America, 1976. 497 p.

MONICO, João Francisco Galera *et al.* **Acurácia e precisão: revendo os conceitos de forma acurada**. Boletim de Ciências Geodésicas, v. 15, n. 3, p. 469-483, 2009.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION COASTAL (NOAA) SERVICES CENTER. **LiDAR 101: and introduction to LiDAR technology, data and applications**. Charsleston: NOAA Coastal Services Center, 2012. 72p.

PESSOA, G. G., dos Santos, R. C., Carrilho, A. C., Amorim, A., & Galo, M. **Classificação de nuvem de pontos obtida por RPAs: uma fonte de dados para a atualização de documentos cartográficos**. Anais do COBRAC, 2018.

REGULAMENTO Brasileiro de Aviação Civil Especial – **RBAC – E nº 94**. ANAC, 2 de maio de 2017.

RENNÓ, Camilo Daleles. **Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens sir-c/x-sar do perímetro irrigado de bebedouro**, petrolina-pe. INPE, São José dos Campos, 1995.

RODRIGUES, D.D. Topografia : **Planimetria para engenheiros agrimensores e cartógrafos. (em desenvolvimento)**. Apostila. Universidade Federal de Viçosa. 2008.

ROSENFELD, G.H.; Fitzpatrick-Lins, K. **A coefficient of agreement as a measure of thematic classification accuracy**. Photogrammetric Engineering Remote Sensing, v.52, n. 2, p.223-227, Feb. 1986.

RUSSAKOVSKY, Olga *et al.* **Imagenet large scale visual recognition challenge**. International journal of computer vision, v. 115, p. 211-252, 2015.

SANTOS JUNIOR, Francisco Marino. **Análise de nuvem de pontos obtida por meio de imagens coletadas através de ARP**. 2019.

SANTOS, AFONSO DE PAULA DOS *et al.* **Controle de qualidade posicional em dados espaciais utilizando feições lineares**. Boletim de Ciências Geodésicas, v. 21, p. 233-250, 2015.

SANTOS, Afonso de Paula dos. **Avaliação da acurácia posicional em dados espaciais com o uso da estatística espacial**. 2010.

SCHADE, G. Machine learning: Métricas para Modelos de Classificação. 2020. Disponível em: <https://gabrielschade.github.io/2019/03/12/ml-classificacao-metricas.html>. Acessado em: 01/12/2022.

SHAN, Jie; TOTH, Charles K. (Ed.). **Topographic laser ranging and scanning: principles and processing**. CRC press, 2018.

SILVA, M. L. **Classificação da cobertura do solo urbano utilizando imagens aéreas, produtos *LIDAR*, razão de bandas e índices de vegetação.** 2020. Dissertação de Mestrado. Universidade Federal de Pernambuco.

SOUSA, Luis Antônio Soares *et al.* **DETECÇÃO E QUANTIFICAÇÃO DE ALTERAÇÕES EM ÁREA URBANA POR MEIO DA COMPARAÇÃO DE NUVENS DE PONTOS *LIDAR* VIA TERRASCAN.** In: XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos, Sp. XIX Anais Simpósio Brasileiro de Sensoriamento Remoto. Santos, Sp: Galoá Proceedings, 2019. p. 1-4.

STEHMAN, S. V. ***Selecting and interpreting measure of thematic classification accuracy.*** Remote Sensing of Environment, v. 62, n. 1, p. 77–89, 1997.

VOSSelman, George; MAAS, Hans-Gerd. ***Airborne and terrestrial laser scanning.*** CRC Press (Taylor & Francis), 2010.

ZHANG, Jixian; LIN, Xiangguo; NING, Xiaogang. ***SVM-based classification of segmented airborne LiDAR point clouds in urban areas.*** Remote sensing, v. 5, n. 8, p. 3749-3775, 2013.


APÊNDICES

APÊNDICE A – Relatório de Processamento da Base

Imagem: J:\ARTIGO23\CONTOS\Processamento\Dados\Imagem

TRACED

11



APÊNDICE B – Relatório de Calibração da Nuvem de Pontos 3D.

RELATÓRIO DE PROCESSAMENTO DA CALIBRAÇÃO DA NUVEM DE PONTOS 3D

RMSE	LIDAR_ELEV	GCP_X	GCP_Y	GCP_Z	ELEV_DIFF	ELEV_DIFF_ABS
1.5541 m	648.5521 m	720811.322	7703324.05	646.998 m	1.5541 m	1.5541 m
0.3631 m	649.8721 m	720715.324	7703234.65	649.509 m	0.3631 m	0.3631 m
0.3013 m	649.3853 m	720846.105	7703219.114	649.084 m	0.3013 m	0.3013 m
0.254 m	645.9821 m	720789.81	7703335.065	645.728 m	0.254 m	0.254 m
0.212 m	648.91 m	720836.803	7703314.651	648.698 m	0.212 m	0.212 m
0.1797 m	647.5128 m	720819.52	7703316.588	647.333 m	0.1797 m	0.1797 m
0.0667 m	646.9457 m	720803.857	7703298.381	646.879 m	0.0667 m	0.0667 m
0.0558 m	646.0668 m	720740.163	7703296.183	646.011 m	0.0558 m	0.0558 m
0.0468 m	648.6362 m	720821.619	7703180.835	648.683 m	-0.0468 m	0.0468 m
0.0462 m	646.4462 m	720795.248	7703314.228	646.4 m	0.0462 m	0.0462 m
0.045 m	646.4111 m	720795.136	7703315.148	646.366 m	0.045 m	0.045 m
0.0428 m	646.9708 m	720806.283	7703297.303	646.928 m	0.0428 m	0.0428 m
0.0248 m	646.3538 m	720736.664	7703284.916	646.329 m	0.0248 m	0.0248 m
0.0112 m	648.0768 m	720826.362	7703318.793	648.088 m	-0.0112 m	0.0112 m
0.0034 m	646.5756 m	720803.733	7703325.775	646.579 m	-0.0034 m	0.0034 m

Fonte: Autora, 2023.