

ANÁLISE DA CLASSIFICAÇÃO AUTOMATIZADA DE NUVEM DE PONTOS 3D OBTIDA POR LIDAR EM ÁREA URBANA DE VIÇOSA, MG

AUTOMATED CLASSIFICATION ANALYSIS OF 3D POINT CLOUD OBTAINED BY LIDAR IN URBAN AREA OF VIÇOSA, MG

ANÁLISIS DE LA CLASIFICACIÓN AUTOMATIZADA DE NUBE DE PUNTOS 3D OBTENIDA POR LIDAR EN ÁREA URBANA DE VIÇOSA, MG

AUTOR

Hanna Aimée da Fraga Gonçalves¹ 

Nilcilene Medeiros das Graças¹ 

Daniel Camilo de Oliveira Duarte¹ 

William Rodrigo Dal Poz¹ 

Afonso de Paula dos Santos¹ 

FILIAÇÃO INSTITUCIONAL

¹ UNIVERSIDADE FEDERAL DE VIÇOSA

E-MAIL

hannafraga@ufv.br

nilcilene.medeiros@ufv.br

Daniel.duarte@ufv.br

william.dalpoz@ufv.br

afonso.santos@ufv.br

DATA DE SUBMISSÃO: 18/07/24

DATA DE APROVAÇÃO: 17/11/25

DOI: 10.12957/GEOUERJ.2025.85988



E-ISSN 1981-9021

ESTE É UM ARTIGO DE ACESSO ABERTO
DISTRIBUÍDO SOB OS TERMOS DA LICENÇA
CREATIVECOMMONS BY-NC-SA 4.0, QUE
PERMITE USO, DISTRIBUIÇÃO E REPRODUÇÃO
PARA FINS NÃO COMERCIAIS, COM A CITAÇÃO
DOS AUTORES E DA FONTE ORIGINAL E SOB
A MESMA LICENÇA.

// RESUMO

O presente artigo discute as relações entre a trajetória do processo de acumulação capitalista e a produção material do espaço urbano, enfatizando sua articulação com o avanço da financeirização. Argumenta-se que, por meio de instrumentos, estratégias e mecanismos financeiros, o capital tem capturado a propriedade fundiária e imobiliária, convertendo-a em ativo mobiliário e aproximando-a da lógica de funcionamento dos ativos financeiros. Nesse percurso, retoma-se a noção de “circuito secundário da acumulação”, formulada por Lefebvre (1999; 2000) e Harvey (1974; 1982), destacando sua importância para compreender a reprodução do capitalismo. Ao mesmo tempo, dialoga-se com a literatura que tem apontado os limites dessa concepção diante das transformações recentes, particularmente no que se refere à crescente interdependência entre o setor imobiliário e as finanças. Nesse sentido, adota-se o conceito de “circuito imobiliário financeirizado” como ferramenta analítica que permite iluminar a autonomização e a centralidade cada vez maiores do setor imobiliário na atual conjuntura econômica.

Palavras-chave: uso e ocupação; mapeamento; CTM.

// ABSTRACT

This study explored the automated classification of point clouds to map urban land use and land cover in Viçosa, MG, Brazil, using *LiDAR* and photogrammetric data. The data were processed with ArcGIS and Global Mapper for the insertion of geometric parameters and determination of land use classes. Validation achieved an accuracy of 81% and a Kappa index of 72%. Distortions in the information generated by *LiDAR* and photogrammetry were identified, highlighting the importance of the initial data quality. The insertion of geometric parameters was effective in classification, emphasizing its methodological relevance. Validation metrics were crucial for assessing the quality of the generated products. It is concluded that automated point cloud classification can significantly contribute to the Cadastro Territorial Multifinalitário (CTM) and territorial management in Viçosa, MG, being a valuable tool for urban planning and the development of local strategies.

Keywords: land use and land cover; mapping; CTM.

// RESUMEN

Este estudio exploró la clasificación automatizada de nubes de puntos para mapear el uso y ocupación del suelo urbano en Viçosa, MG, utilizando datos LiDAR y fotogramétricos. Los datos fueron procesados con ArcGIS y Global Mapper para la inserción de parámetros geométricos y la determinación de clases de uso del suelo. La validación alcanzó una precisión del 81% y un índice Kappa del 72%. Se identificaron distorsiones en la información generada por el LiDAR y la fotogrametría, destacando la importancia de la calidad de los datos iniciales. La inserción de parámetros geométricos fue eficaz en la clasificación, resaltando su relevancia metodológica. Las métricas de validación fueron fundamentales para evaluar la calidad de los productos generados. Se concluye que la clasificación automatizada de nubes de puntos puede contribuir significativamente al Catastro Territorial Multifinalitario (CTM) y a la gestión territorial en Viçosa, MG, constituyendo una herramienta valiosa para la planificación urbana y el desarrollo de estrategias locales.

Palabra Clave: Uso y Ocupación; Mapeo; CTM.

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).

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 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, consequentemente, 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.

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.

Guiada por iniciativas dos trabalhos de Lin et al. (2014) abordando a descrição de imagens, Russakovsky et al. (2015) realizam a detecção de vários objetos e na sequência Caelles et al. (2018) propõem 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, que 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, tem-se a problemática em relação à classificação do uso e ocupação do solo em áreas urbanas com a inserção de parâmetros espectrais provenientes das imagens, porém não sendo considerados os parâmetros geométricos característicos da área classificada.

Logo, neste trabalho, tem-se como hipótese que a classificação automatizada embasada em dados provenientes do sensor *LiDAR* e imagens da fotogrametria, tende em proporcionar

diferencial na utilização quando integradas com os parâmetros geométricos presentes na área. E com isso, podem desempenhar avanços no desenvolvimento na Gestão Territorial, à medida que a classificação da nuvem de pontos e imagens podem subsidiar dados para elaboração do CTM.

DESENVOLVIMENTO

Para o presente estudo, foi escolhida uma região da área urbana do Município de Viçosa – Minas Gerais (Figura 1). 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 1. Mapa da área de estudo



Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_LOCALIZACAO_HF.pdf. Acesso em: 26 fev. 2024.

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

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*; *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)* (GESTÃO ENGENHARIA, 2022).

Segundo a Gestão Engenharia (2022), com as imagens georreferenciadas foi elaborado o ortomosaico (Figura 2) 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 ortomosaíco 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 2. Ortomosaico da área de estudos



Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_ORTO_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.


METODOLOGIA

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

Pré-Processamento

Um fluxograma de atividades para etapa de pré-processamento é apresentado na Figura 3.

Figura 3. Fluxograma - pré-processamento



Fonte: Autora, 2023.

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.


Processamento

Com a calibração da nuvem de pontos realizada, procedeu-se à etapa de processamento, conforme fluxograma apresentado na Figura 4.

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*.

Figura 4. Fluxograma - pós-processamento



Fonte: Autora, 2023.

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; desvio máximo (metros), é um filtro usado para modelar uma superfície curva do solo, onde valores pequenos removerão a vegetação rasteira da classificação do solo; diferença máxima de altura (metros), permite aos usuários controlarem os valores para a remoção dos pontos que provavelmente não são pontos de terreno; declividade máxima do terreno (graus); e 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. Ressalta-se que para maiores esclarecimentos sugere-se o tutorial do programa *Global Mapper Pro*, (Global Mapper, 2023).

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 (m²): 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).

Análise dos Dados de Referência

Foi realizado uma análise visual no ortomosaico (Figura 2) onde foram identificadas diversas distorções, destacando-se no sentido Sul e Nordeste na imagem, notavelmente sobre os telhados e nas extremidades (Figuras 5 e 6).


Figura 5. Distorção no ortomosaico na região Sul da cena



Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_DISTORCAO_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

Figura 6. Distorção no ortomosaico – telhados




Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_DISTORCAO_2_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

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.

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 7), 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 7. Mapa da nuvem de pontos


Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_NUVEM_DE_PONTOS_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

É importante destacar que a nuvem de pontos apresentou características de não penetração do *LiDAR* em áreas submersas (Figura 8). 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 resolução vertical, configuração do equipamento e distância entre a água e o *LiDAR* (Bertão, 2018).

Adicionalmente, foram 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.

Figura 8. Mapa da nuvem de pontos - córrego




Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CORREGO_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

As razões para esses "buracos" (Figura 9) 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.

Figura 9. Mapa da nuvem de pontos com falhas de registro




Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_NUVEM_FALHAS_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

Análise de Perfil de Rota

Nos resultados da fase de análise, foi possível perceber na visualização 3D (Figura 10), 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 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. Ressalta-se que esse intervalo foi definido tendo como fundamentação análise do perfil de rota.

Figura 10. Mapa com ortomosaico e nuvem de pontos 3D




Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_ORTO_NUVEM_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

Ao realizar a análise dos perfis de rota nas árvores, conforme representado na Figura 11, observou-se a ausência de penetração do *LiDAR* na vegetação, evidenciando que a maioria estão concentrados na altura das árvores, sem praticamente alcançar o solo.

Figura 11. Perfil de rota - vegetação



Fonte: Autora, 2023.

Vale salientar que a estrutura do dossel arbóreo, geralmente heterogênea e com variações de folhagem e espaçamento entre ramos, influencia diretamente essa penetração, fazendo com que algumas áreas recebam menor incidência de retornos. No que se refere à densidade da nuvem de pontos, conforme já detalhado na etapa de classificação de edificações e vegetação, considerou-se uma densidade média de 123,77 pontos/m², valor que fornece resolução adequada para a análise da cobertura vegetal e permite discriminar diferentes classes de superfície, mesmo em locais com dossel mais fechado.

Essa limitação na capacidade de penetração pode ter implicações significativas na obtenção de informações detalhadas sobre a estrutura vertical da vegetação e, consequentemente, na precisão dos resultados relacionados à cobertura vegetal e a determinação da classe solo.

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.

Expressa-se que, a escolha por 15 pontos de controle se deu de forma empírica, mas fundamentada em critérios técnicos relacionados às condições da área de estudo e ao objetivo da calibração da nuvem de pontos. Cabe destacar ainda que houve um intervalo temporal entre o levantamento aéreo (2022) e a coleta dos pontos de controle (2024), período em que a área urbana de Viçosa/MG passou por transformações territoriais relevantes. Essa defasagem impactou diretamente a seleção de alvos estáveis, restringindo a amostra final a 15 pontos confiáveis.

Quanto à espacialização dos pontos de controle, busca-se sempre uma distribuição dos pontos de controle de maneira esparsa em toda a área de interesse, a fim de reduzir possíveis tendências e aumentar a robustez da calibração. No entanto, para o caso em questão, essa distribuição foi limitada por fatores práticos e técnicos: parte significativa da região central


correspondia a áreas privadas, sem acesso público, o que restringiu a coleta. Além disso, a expansão urbana marcada tanto por novas construções quanto por obras em andamento, reduziu as opções de alvos naturais estáveis.

Soma-se a isso o fato de que, na etapa de calibração da nuvem de pontos, foram identificadas distorções em setores específicos da imagem, o que também influenciou a escolha e a posição dos pontos de controle, privilegiando áreas com maior estabilidade geométrica. Dessa forma, a concentração dos pontos no setor norte não decorre de uma decisão metodológica ideal, mas sim das restrições de campo, do processo de expansão urbana e das condições técnicas impostas durante a calibração.

Mesmo com a concentração dos pontos de controle no setor norte, os resultados da calibração se mantiveram consistentes. As restrições de campo e as condições técnicas, que influenciaram a distribuição dos pontos, não comprometeram a qualidade geral da calibração. A análise final demonstrou que a precisão e a acurácia dos dados foram mantidas dentro dos padrões aceitáveis para o projeto.

Ressalta-se que para a calibração o referencial altimétrico foi elipsoidal. Para melhor entendimento, produziu-se o mapa com os pontos de controle representados na área de estudo (Figura 12) e o Gráfico 1 com a discrepância posicionais altimétricas. 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 12. Mapa com os pontos de controle



Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_GCPS_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

Gráfico 1. Métricas do GCPs - Discrepância Posicional Altimétrica dos Pontos de Controle e do LiDAR



Fonte: Autora, 2023.

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.

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°, 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 8); e largura máxima de edificação: recorre-se aos atributos dos dados vetoriais além da análise geométrica das edificações atingindo 25 metros. Desse modo, foi classificada a nuvem de pontos de solo (Figuras 13 e 14), 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, 2023.

Figura 12. Mapa classificação solo e não solo




Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CLASS_SOLO.pdf. Acesso em: 26 fev. 2024.

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 13).

Figura 13. Mapa classificação solo e não solo com o ortomosaico



Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CLASS_ORTO_HF.pdf. Acesso em: 26 fev. 2024.


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°, ao contrário dos demais parâmetros, como a diferença de altura e largura das edificações.

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 14).

Figura 14. Mapa referencial



Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_REFERENCIAL_HF.pdf. Acesso em: 26 fev. 2024.


Fonte: Autora, 2024.

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.

Nessa abordagem comparativa, os pontos críticos e eficazes foram analisados, como evidenciados nas Figuras 15 e 16. Este procedimento permitiu uma compreensão mais profunda


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

Figura 15. Pontos críticos - solo



Fonte: Autora, 2023.

Figura 16. Pontos eficazes - solo



Fonte: Autora, 2023.

Acrescido disto, segue o antes e depois da classificação de solo e não solo comparada com o ortomosaico (Figura 17), com objetivo de relatar os pontos eficazes da classificação.

Figura 17. Antes x depois - classificação solo e não solo



Fonte: Autora, 2023.

Nota-se que, mesmo com os parâmetros de classificação, ainda é possível perceber algumas falhas (Figura 15), 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 18), 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.

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, 2023.

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 *pixels*/m², 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 deve 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 18, 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 18. Parâmetros de filtragem - vegetação




Fonte: Global Mapper, 2023.

A Determinação do limite de vegetação média e máxima dessa área é respaldada 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 m^2 , tendo em consideração a presença de automóveis na região, ressalta-se que a área do automóvel é de $\cong 6 \text{ m}^2$.

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 19). Com isso, gerou-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 19. Árvores extraídas e polígonos de cobertura




Fonte: Autora, 2023.

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 20.

Com o modelo classificado (Figura 20) 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 20. Mapa classificação final da nuvem de pontos




Disponível em: https://github.com/hannafraga/mapas/blob/main/MAPA_CLASS_FINAL_HF.pdf. Acesso em: 26 fev. 2024.

Fonte: Autora, 2024.

Nota-se no modelo classificado a presença de *pixels* de vegetação na classe espectral de construção e vice e versa (Figura 21).

Figura 21. Pontos críticos - edificações x vegetação




Fonte: Autora, 2023.

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.

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 21. 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 22.

Figura 22. Pontos eficazes - edificações e vegetação.




Fonte: Autora, 2023.

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 23.

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 23. Antes x depois - classificação edificação e vegetação



Fonte: Autora, 2023.

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.

Em relação a classe solo, nota-se o percentual menor da classe construção, o que é coerente ao analisarmos a área (Figura 2), 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.

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.

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 1), 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.

Validação da Classificação

Para a etapa de validação da classificação, utilizou-se o mapa referencial (Figura 14) 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 (teste)	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.

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% do modelo classificado está mais próximo da realidade encontrada com as observações precisas.

Por conseguinte, foi obtido o índice *Kappa* de 0.72 e a variância do *Kappa* (VAR_k) de $\cong 0.0004$, 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 24).

Figura 24. Modelo 3D classificado

Fonte: Autora, 2024

CONSIDERAÇÕES FINAIS

A análise temática foi fundamental para a análise espacial do modelo classificado, considerando as características antrópicas e naturais da região obtidas por visitas *in loco*, ortomosaico e mapa referencial. A compreensão da realidade espacial da área de estudo é crucial para a análise temática da classificação, sendo importante o conhecimento técnico para interpretação das respostas do algoritmo. A interpretação qualitativa é essencial para compreender as respostas de classificação, e a identificação de registro e calibração altimétrica contribuem para a melhoria da qualidade dos dados geoespaciais. A classificação automatizada oferece eficiência e velocidade, processando grandes conjuntos de dados de forma rápida e consistente, minimizando o viés humano e a subjetividade na classificação e proporcionando resultados mais objetivos e consistentes, especialmente em projetos de Gestão Territorial.

Na avaliação métrica desse trabalho, tem-se a validação de forma quantitativa dos resultados, sendo que o produto foi avaliado de acordo com ET-CQDG/2016, adotando com avaliador exatidão global, coeficiente *Kappa* e variância. Com isso, 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 34).

De acordo com ET-PCDG (2016, p. 62), 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 se 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. A tecnologia *LiDAR* e outras tecnologias de sensoriamento remoto estão cada vez mais sendo utilizadas para fornecer informações precisas e atualizadas para o cadastro territorial e para o planejamento urbano.

A avaliação da qualidade dos produtos gerados é importante para a tomada de decisões em projetos de planejamento urbano, zoneamento, gestão ambiental e recursos hídricos, entre

outros. A abordagem adotada neste estudo tem implicações significativas na Gestão Territorial, permitindo aos gestores municipais tomar decisões precisas e detalhadas com base nas características geográficas do município. Sugere-se para futuros estudos a obtenção de mapeamento fotogramétrico com bandas visíveis e no NIR, criação de novas classes *LiDAR* para melhor diferenciação de edificações e pavimentação, uso de técnicas de filtragem em raster, inserção integrada de parâmetros espectrais e geométricos na classificação, e uso de algoritmos de Inteligência Artificial. Além disso, recomenda-se adotar uma distribuição de pontos de controle mais espaçada. Em conclusão, a aplicação prática do *LiDAR* e da classificação de nuvem de pontos pode subsidiar estudos geográficos na Gestão Territorial, sendo importante para o planejamento urbano e a promoção de uma Gestão Territorial mais sustentável e eficaz.

AGRADECIMENTOS

Agradecimentos aos parceiros e instituições que contribuíram significativamente para o desenvolvimento do projeto, destacando a importância de cada apoio e colaboração para o sucesso do trabalho. O estudo recebeu apoio da CAPES e da FAPEMIG, cujo financiamento foi essencial para viabilizar as etapas e a realização das pesquisas. Agradece também à Global Mapper, representada pela ENGESAT e *Blue Marble Geographics*, pelo incentivo científico e suporte tecnológico fornecidos, reconhecendo a eficácia do software na análise de dados espaciais. Além disso, destaca o apoio do Grupo de Engenharia Para Gestão Territorial (GENTE) e da Gestão Engenharia pela colaboração dos dados e *insights* valiosos para o estudo.

REFERÊNCIAS

- ANJOS, Camila S. **Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não paramétricos**. 2016. Tese (Doutorado em Engenharia Agrícola) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2016.
- ARIZA, F. J. **Qualidade na Produção Cartográfica**. Madrid: RA-MA, 2002.
- CAELLES, S. et al. The 2018 davis challenge on video object segmentation. **arXiv preprint arXiv:1803.00557**, 2018.
- CARRILHO, A. C. **Extração e refinamento de contornos de telhados utilizando descritores geométricos e integração de dados LiDAR e imagens aéreas**. 2021. Dissertação (Mestrado em Ciências Cartográficas) – Universidade Estadual Paulista, Presidente Prudente, 2021.
- CARRILHO, A. C. et al. Avaliação da extração automática de edificações a partir de dados LiDAR aerotransportado. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 28., 2018, Rio de Janeiro. **Anais...** Rio de Janeiro: SBC, 2018.
- CHURCH, R. L.; MURRAY, A. T. **Business Site Selection, Location Analysis, and GIS**. Hoboken: John Wiley & Sons, 2009.
- COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46, 1960.
- CPE. **Drone DJI Matrice 300 + Laser Scanner AlphaAir 450**. [S. l.], [2023?]. 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.
- FRAGA, H. A. da F. **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 em

Engenharia de Agrimensura e Cartográfica) - Departamento de Engenharia, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2021.

GIACOMINI, Q. DE R.; VUELMA, A. L. A importância do Planejamento Urbano. In: Seminário de Iniciação Científica e Seminário Integrado de Ensino, Pesquisa e Extensão, 2., 2020. **Anais...** UFFS, 2020. p. e24927-e24927.

GIACCOM-RIBEIRO, B. M. Sensoriamento remoto para mapeamento urbano: classificação de cobertura, uso e ocupação do solo. In: Simpósio Brasileiro de Sensoriamento Remoto, 19., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. p. 1811-1814.

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

GESTÃO ENGENHARIA. [Página inicial]. **Gestão Engenharia**, Ponte Nova, 2022.

GHILANI, C. D.; WOLF, P. R. **Adjustment computations: spatial data analysis**. 4. ed. Nova Iorque: John Wiley & Sons, 2006.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective**. 2. ed. Nova Delhi: Pearson Education India, 2009.

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, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation**. Nova Iorque: John Wiley & Sons, 2015.

LIN, T.-Y. et al. Microsoft coco: Common objects in context. In: European Conference On Computer Vision, 13., 2014, Zurique. **Proceedings...** Cham: Springer, 2014. p. 740-755.

MENDES, T. S. G. et al. Filtragem de Nuvem de Pontos de Dados de Vant: Aplicação em Área Íngreme. In: Simpósio Brasileiro de Sensoriamento Remoto, 20., 2023, Florianópolis. **Anais...** Florianópolis: INPE, 2023.

MESSIAS, C. G.; COBRA, R. L. Classificação de Imagens LANDSAT e Mudanças no Uso do Solo de uma Área da Represa de Furnas, entre os Anos de 2004 e 2014. In: Simpósio Nacional de Geografia e Gestão Territorial e Semana Acadêmica de Geografia da Universidade Estadual de Londrina, 1., 2018, Londrina. **Anais...** Londrina: Universidade Estadual de Londrina, 2018. v. 1, p. 674-687.

PESSOA, G. G. et al. Classificação de nuvem de pontos obtida por RPAs: uma fonte de dados para a atualização de documentos cartográficos. In: Congresso Brasileiro de Cartografia, 28., 2018, Rio de Janeiro. **Anais...** Rio de Janeiro: SBC, 2018.

RODRIGUES, D. D. **Topografia**: Planimetria para engenheiros agrimensores e cartógrafos. [S. l.: s. n.], 2008. Apostila. (Em desenvolvimento).

RUSSAKOVSKY, O. et al. Imagenet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211-252, 2015.

SANTOS, A. P. dos. **Avaliação da acurácia posicional em dados espaciais com o uso da estatística espacial**. 2010. Tese (Doutorado em Engenharia Agrícola) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2010.

SANTOS JUNIOR, F. M. **Análise de nuvem de pontos obtida por meio de imagens coletadas através de ARP**. 2019. Monografia (Especialização em Georreferenciamento de Imóveis Rurais) – Instituto de Educação, Ciência e Tecnologia do Espírito Santo, Colatina, 2019.

SCHADE, G. **Machine learning**: Métricas para Modelos de Classificação. Medium, 2020. Disponível em: <https://gabrielSchade.github.io/2019/03/12/ml-classificacao-metricas.html>. Acesso em: 1 dez. 2022.

SHAN, J.; TOTH, C. K. (ed.). **Topographic laser ranging and scanning**: principles and processing. Boca Raton: CRC Press, 2018.

SOUSA, L. A. S. et al. Detecção e Quantificação de Alterações em Área Urbana por Meio da Comparação de Nuvens de Pontos Lidar via Terrascan. In: Ssimpósio Srasileiro de Sensoriamento Semoto, 19., 2019, Santos. **Anais...** Santos: Galoá Proceedings, 2019. p. 1-4.