

Influência da amostragem na classificação de uso e cobertura da terra em ambientes urbanos complexos com aprendizado profundo e imagens RPA: um estudo de caso do Conjunto Paulo VI (Belo Horizonte, MG)

The influence of sampling on deep learning for complex urban land use and land cover classification using RPA imagery: a case study of Conjunto Paulo VI (Belo Horizonte, MG)

Danilo Roberto Fioramonte

Prog. de Pós-Graduação em Geografia, Universidade Estadual Paulista - UNESP
danilo.fioramonte@unesp.br

Danilo Marques de Magalhães

Dep. de Geografia e Planejamento Ambiental, Universidade Estadual Paulista - UNESP
danilo.magalhaes@unesp.br

Resumo

O presente trabalho avaliou a eficiência do aprendizado profundo para a classificação de uso e cobertura da terra utilizando imagens de altíssima resolução espacial do bairro Conjunto Paulo VI, em Belo Horizonte (MG). A partir de um ortomosaico gerado por aeronave remotamente pilotada (RPA), realizou-se a vetorização manual de 48% da área do bairro, definindo-se 15 classes, sendo 70% para treinamento e 30% para verificação da acurácia. Foram testados cenários com diferentes proporções amostrais, de 10% a 70% dos dados de treinamento. A classificação empregou segmentação semântica com a arquitetura U-Net (backbone ResNet34) no ArcGIS Pro, e o desempenho foi avaliado por matrizes de confusão e pelas métricas Overall Accuracy, Kappa, F1-Score e IoU. Os modelos com menor taxa amostral tiveram menor desempenho na identificação de classes menos presentes, enquanto em modelos treinados com maior quantidade amostral ocorreu sobreajuste, prejudicando a acurácia. O modelo treinado com 50% das amostras teve o melhor desempenho em métricas gerais e por classe, considerando o esforço humano de vetorização e a eficiência das épocas de treinamento. Este resultado indica ser possível otimizar a rotulagem de amostras em ambientes urbanos, demonstrando que um volume intermediário de dados pode garantir elevada acurácia, evitando redundância e sobreajuste.

Palavras-chave: aprendizagem profunda, sensoriamento remoto, imagens de altíssima resolução espacial, uso e cobertura da terra.

Abstract

This study evaluated the efficiency of deep learning for land use and land cover classification using very high spatial resolution imagery of the Conjunto Paulo VI neighborhood, in Belo Horizonte (MG), Brazil. From an orthomosaic acquired by a remotely piloted aircraft (RPA), 48% of the neighborhood area was manually vectorized, defining 15 classes, of which 70% of the samples were used for training and 30% for accuracy assessment. Several scenarios with different sampling proportions were tested, ranging from 10% to 70% of the training data. Classification was performed through semantic segmentation with the U-Net architecture (ResNet34 backbone) in ArcGIS Pro, and performance was assessed using confusion matrices and the Overall Accuracy, Kappa, F1-Score, and IoU metrics. Models with lower sampling rates showed lower performance in identifying less represented classes, whereas those trained with larger sample sizes overfitted, compromising accuracy. The model trained with 50% of the samples achieved the best performance across general and per-class metrics, considering the human effort of vectorization and the efficiency of the training epochs. These results indicate that it is possible to optimize sample labeling in urban environments, showing that an intermediate data volume can ensure high accuracy while avoiding redundancy and overfitting.

Keywords: deep learning, remote sensing, very high spatial resolution imagery, land use and land cover.

Introdução

Desde a década de 1960, o Sensoriamento Remoto vem sendo considerado como uma ferramenta indispensável para a observação das características e dos fenômenos terrestres (Silva *et al*, 2022). E, desde então, os constantes avanços tecnológicos têm proporcionado um aumento exponencial no número de sensores e satélites disponíveis, bem como na melhoria das resoluções espacial, espectral, radiométrica e temporal dos sensores embarcados (Cracknell, 2018). Tal processo tem levado à produção de enormes volumes de dados espaciais que demandam, por sua vez, sofisticados recursos computacionais para a extração de informações e o seu aproveitamento para processos de interpretação e de análise do espaço terrestre (Zhao *et al*, 2023).

Nesse contexto, emergem as aplicações derivadas de algoritmos de Aprendizagem Profunda (*Deep Learning* - DL) para extração de informações a partir de imagens de sensores remotos (Ma *et al*, 2019; Zhao *et al*, 2023). Sua capacidade de aprender a reconhecer padrões de forma, textura e contexto das imagens, indo além da capacidade tradicional dos algoritmos predecessores, que utilizam, sobretudo, informações espectrais das imagens para classificar os objetos, abriu novas possibilidades para a identificação de alvos contidos em cenas complexas, como as imagens de alta resolução (Sertel *et al*, 2022). Exemplos recentes de aplicações demonstram mapeamentos para finalidades diversas, incluindo a produção de mapas de uso e cobertura da terra em escala nacional com resolução de 1 m a partir de dados abertos (Li *et al*, 2023), o delineamento, em larga escala, de espaços urbanos abertos com imagens PlanetScope e Sentinel-1 (Verde; Patias; Mallinis, 2022) e a detecção de espécies arbóreas específicas em imagens GeoEye de 0,5 m (Wagner *et al*, 2020).

Magalhães, Souza e França (2025) demonstraram que o modelo U-Net obteve acurácia superior aos algoritmos de *Machine Learning Random Forest* e *Support Vector Machine* para o mapeamento de uso e cobertura do solo a partir de imagens de alta resolução de uma área urbana. A boa performance dos modelos de DL, medida por um conjunto de métricas de avaliação de acurácia também vem sendo relatada na literatura especializada, como nos trabalhos de Nigar *et al*. (2024) e Wang, Mountrakis e Pastick (2025).

Para o mapeamento de uso e cobertura da terra, que envolve processos de segmentação semântica das imagens, o modelo U-Net tem sido o mais frequente, as "conexões de salto" (*skip connections*) que propagam detalhes finos do codificador para o decodificador têm contribuído positivamente para a delimitação precisa de limites

(Farhadpour; Maxwell, 2025; Li *et al*, 2021). Dentre as vantagens desse e de outros modelos de DL, citam-se a possibilidade de customizar a rede neural conforme o conjunto de dados que será utilizado para o treinamento (Li *et al*, 2024; Farhadpour; Maxwell, 2025). Alguns autores apresentam, também, adaptações dessa rede neural, como modelos híbridos com Transformers (Cheng *et al*, 2023; Wang *et al*, 2024), bem como a combinação de imagens multisensores (Gong; Chen; Zheng, 2025; Irfan *et al*, 2025). Tais métodos reforçam a noção da adaptabilidade dos modelos de DL para as tarefas de classificação de imagens de sensoriamento remoto.

Dentre os diversos desafios relacionados à extração de informações de imagens de sensoriamento remoto, destaca-se a classificação supervisionada de imagens de altíssima resolução espacial coletadas em ambientes urbanos (Moran, 2010; Vasavi *et al*, 2023). Isso, pois trata-se de um ambiente com alta heterogeneidade espectral e espacial, em função dos elementos que a compõem, como os diferentes materiais construtivos, tipos de uso e tipos de vegetações. Além disso, nessas áreas, normalmente há um grande desequilíbrio de classes a serem mapeadas (Leichtle *et al*, 2017; Johnson; Khoshgoftaar, 2019) e muita semelhança espectral entre classes distintas, por exemplos solos expostos e talhados de cerâmica (Magalhães; Souza; França, 2025). Tal situação faz com que um grande volume de amostras para o treinamento dos modelos classificadores seja necessário, resultando em um processo exaustivo do ponto de vista humano e computacional.

Fruto disso, um desafio comumente relatado é a criação da verdade terrestre (*ground truth*) que será utilizada para o treinamento e a verificação da acurácia. Em função da atual variabilidade de sensores e resoluções de imagens disponíveis, há, portanto, uma importante lacuna na disponibilidade de dados de verdade terrestre que possam ser utilizados para classificação de imagens de sensoriamento remoto (Kvile *et al*, 2024; Li *et al*, 2024; Magalhães; Souza e França, 2025). Sobretudo quando se trata de imagens de altíssima resolução espacial que podem ser coletadas por Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft* - RPA). Como essas aeronaves possuem diferentes sensores e podem voar a distâncias variadas em relação ao terreno, não há uma padronização da resolução espacial gerada para essas imagens, o que complexifica a tarefa de criação de um modelo de inteligência artificial global que seja capaz de classificar ou, ao menos, pré-treinar outras imagens semelhantes (Ait Moulay *et al*, 2025).

De um modo geral, percebe-se uma correlação positiva entre o volume de dados de treinamento e a acurácia e robustez dos modelos de DL em Sensoriamento Remoto. No

entanto, essa relação não é linear e apresenta um fenômeno conhecido como curva de saturação de dados, onde a taxa de aumento do desempenho gradualmente diminui e se estabiliza à medida que o tamanho do conjunto de treinamento aumenta (Ning *et al*, 2020). Percebe-se, ainda, que a introdução ilimitada de novas amostras de treinamento pode levar ao sobreajuste (*overfitting*) do modelo, que passa a classificar, também, os ruídos causando uma redução da acurácia (Krizhevsky; Sutskever; Hinton, 2017; Gütter *et al*, 2022; Genderingen *et al*, 2024). Isso implica que, a partir de um certo ponto, o esforço e o custo de coletar mais dados de treinamento superam os ganhos marginais de desempenho.

Entretanto, ainda não é possível se estabelecer um volume ideal de amostras de treinamento para mapeamentos de uso e cobertura da terra, pois são diversas as variáveis que podem impactar nessa decisão, como resolução espacial e espectral da imagem, variabilidade espacial e espectral dos alvos presentes na imagem, estrutura da paisagem representada, iluminação da cena, dentre outros fatores. A partir da literatura especializada, entende-se que a característica mais relevante é que as amostras sejam diversificadas o suficiente para capturar a variabilidade da paisagem (Leichtle *et al*, 2017; Naushad; Kaur; Ghaderpour, 2021; Yilmaz; Kavzoglu, 2021; Gütter *et al*, 2022; Kavzoglu; Yilmaz, 2022). E, nesse sentido, acredita-se que são relevantes as iniciativas que buscam compreender o impacto do volume de amostras de treinamento na acurácia do modelo classificador, pois podem colaborar para evitar a sobrecarga humana no processo de rotulagem de amostras e garantir a melhor acurácia do modelo classificador.


Diante do exposto, este trabalho teve como objetivo analisar o impacto que o volume de amostras de treinamento exerce sobre a acurácia de um modelo classificador de imagem baseado em DL. Para essa análise, foram testadas diferentes classificações supervisionadas de uma imagem de altíssima resolução espacial, coletada por uma RPA, de uma área urbanizada. As imagens foram classificadas a partir de diferentes volumes de amostras de treinamento e avaliadas por métricas de verificação de acurácia amplamente utilizadas no campo do Sensoriamento Remoto.

Caracterização da Área de Estudo

O bairro Conjunto Paulo VI está situado na porção nordeste de Belo Horizonte (MG), em uma área periférica que faz divisa com bairros como Paulo VI, Ribeiro de Abreu, Capitão Eduardo e Montes Claros. A maioria das edificações são de alvenaria, porém com materiais construtivos, em geral, mais simples. Além disso, assentamentos informais, áreas

de solo exposto e edificações em construção são comuns no bairro. Tais características estão expressas na Figura 1.

Figura 1. Localização da área de estudo



Fonte: Elaboração dos autores

Dados do último censo demográfico classificam o Conjunto Paulo VI como Favela e Comunidade Urbana (FCU), caracterizada por ausência ou precariedade de direitos e serviços essenciais. Parte dos domicílios vem sendo regularizada pela Companhia Urbanizadora e de Habitação de Belo Horizonte (URBEL), evidenciando um processo em curso de transição entre informalidade e formalização parcial (URBEL, 2025).

Implantado em terreno montanhoso, com declividades acentuadas e solos instáveis, às margens do Ribeirão do Onça e do Rio das Velhas, o bairro apresenta elevado risco geotécnico, com registros de deslizamentos e desabamentos, além de alta vulnerabilidade às mudanças climáticas, acentuada pela verticalização das moradias e pela redução da circulação de ventos (PRODABEL, 2022; Magalhães, 2021). As deficiências de infraestrutura incluem ausência de rede de esgoto em parte do território, vias íngremes sem pavimentação adequada, problemas no abastecimento de água, fornecimentos de energia, esgoto a céu aberto e barreiras à mobilidade de pessoas com deficiência, refletindo a marginalização histórica das comunidades informais nas políticas de urbanização (IBGE, 2025; Rede Record, 2025).

A ocupação do Conjunto Paulo VI é dinâmica, com mudanças rápidas na paisagem e verticalização crescente, o que dificulta o monitoramento pelo poder público e exige atualização frequente das bases cartográficas (Magalhães, 2021). A insuficiência da infraestrutura de drenagem, somada ao acúmulo de resíduos sólidos, favorece a ocorrência de enchentes e inundações, reforçando a necessidade de métodos de coleta e processamento de dados espaciais de alta resolução para apoiar o planejamento e a gestão territorial em grandes cidades brasileiras, especialmente em áreas socialmente vulneráveis.

Materiais e Métodos

O mapeamento do uso e cobertura da terra foi realizado sobre o ortomosaico produzido por Magalhães (2021), o qual foi gerado por meio da captura de imagens aéreas com uma RPA da marca DJI, modelo Phantom 4 Pro. O voo foi planejado no aplicativo Map Pilot, para o sistema iOS, utilizando a função *Terrain Aware*, que ajusta a altitude do voo conforme as variações do terreno. A altura de voo foi de 150 m em relação ao solo, com sobreposições frontal e lateral de 75%. Foram obtidas 261 imagens, com *Ground Sample Distance* (GSD) de 4,1 cm. Para garantir a acurácia posicional das imagens, o autor utilizou nove pontos de controle em solo (*Ground Control Points* – GCP) que foram coletados por meio de receptores GNSS de dupla frequência operados no método estático (Monico, 2000), de forma dispersa e de modo a amostrar as variações do terreno, conforme Santos et al. (2016) e Zanetti, Gripp Júnior e Santos (2017). Os pontos foram levantados com receptores GNSS de dupla frequência Topcon Hiper SR, pelo método relativo estático, conforme IBGE (2008) e Monico (2000). O receptor utilizado como base realizou observações durante 4h30min, enquanto os demais pontos foram coletados durante 20 minutos cada.

As coordenadas foram pós-processadas no software Topcon Tools, utilizando os dados da Rede Brasileira de Monitoramento Contínuo do IBGE. A conversão das altitudes geométricas em altitudes ortométricas foi realizada com o modelo MapGeo 2015. Os pontos apresentaram erro médio de 3 mm para as coordenadas planimétricas e de 4 mm para as coordenadas altimétricas.

O processamento fotogramétrico foi realizado no Agisoft PhotoScan, versão 1.4.2, utilizando o método *Structure from Motion* (SfM). O processamento incluiu o alinhamento prévio das imagens, a geração dos pontos de amarração, o georreferenciamento com base nos GCPs, um novo alinhamento e a geração da nuvem de pontos densa, do modelo digital de superfície e do ortomosaico. O modelo digital de superfície foi gerado a partir da

nuvem densa e utilizado como superfície para a ortorretificação do mosaico (Magalhães, 2021).

De posse do ortomosaico, elaborou-se a verdade terrestre por vetorização manual exaustiva de polígonos em toda a área de estudo, definindo-se as classes de uso e cobertura da terra por inspeção visual e conhecimento prévio do local. Foram mapeadas as classes: telhado de cerâmica, telhado de fibrocimento, cimento (calçamentos e lajes), telhado de cimento, asfalto, caixas d'água, água solo (sobre o asfalto/escoamento superficial), vegetação arbórea, vegetação rasteira (gramíneas e similares), veículos (carros, motos, caminhões e vans), objetos antrópicos verdes, azuis e vermelhos, solo exposto marrom e areia (Figura 2).

Para avaliar o impacto do volume de amostras de treinamento sobre a acurácia do classificador, foram definidos sete cenários experimentais com 10%, 20%, 30%, 40%, 50%, 60% e 70% da verdade terrestre para treinamento, mantendo-se fixos os 30% restantes para validação. As amostras foram selecionadas aleatoriamente por meio de um script elaborado no ambiente ArcPy do ArcGIS Pro. O Conjunto Paulo VI possui área total de 226.806 m² (URBEL, 2025), dos quais 109.752 m² (3.262 polígonos) foram vetorizados como verdade terrestre, correspondendo a 48,39% da área do bairro. Desse conjunto, 70% (2.283 polígonos) foram destinados ao treinamento e 30% (979 polígonos) à validação. A Tabela 1 apresenta, para cada cenário, o número de polígonos de treinamento e a respectiva área em metros quadrados.

Figura 2. Verdade terrestre da área de estudo



Fonte: Elaboração dos autores

Tabela 1. Síntese dos dados de entrada para treinamento dos modelos.

Amostras para Treinamento	Polígonos	Área total (m ²)	Porcentual em relação ao bairro
10%	352	10.657	4,69%
20%	652	21.345	9,41%
30%	978	32.980	14,54%
40%	1.304	40.817	17,99%
50%	1.631	54.679	24,10%
60%	1.957	63.264	27,89%
70%	2.283	74.080	32,66%
30% (validação)	979	35.671	15,72%

Fonte: Elaborado pelos autores

Para a classificação da imagem, foi utilizado o modelo de segmentação semântica U-Net disponível no ArcGIS Pro, o qual utiliza a ResNet34 como *backbone*, atuando como a base do *encoder* da rede neural. Sua função é extrair, em diferentes níveis de profundidade, características espectrais e espaciais da imagem que serão decodificadas para gerar a classificação. Por se tratar de uma rede pré-treinada, quando utilizada como *backbone* da U-Net, ele aprimora a representação dos dados de entrada e torna o aprendizado mais eficiente mesmo com conjuntos amostrais reduzidos (ESRI, 2024).

Para o treinamento, definiu-se um máximo de 200 épocas e empregou-se a função de parada precoce (*early stopping*) para evitar sobreajuste; a Tabela 2 apresenta o número efetivo de épocas executadas por cada modelo.

Tabela 2. Quantidade de épocas de treinamento realizadas por cada modelo de treinamento

Modelo	Épocas realizadas
10% de amostras	37
20% de amostras	26
30% de amostras	30
40% de amostras	46
50% de amostras	28
60% de amostras	71
70% de amostras	41

Fonte: Elaborado pelos autores

A acurácia foi verificada pela comparação entre a verdade terrestre (30% das amostras) e os resultados de classificação para cada cenário de treinamento (10% a 70%), por meio de script em ArcPy que calculou, por classe, as métricas *Precision*, *Recall*, *F1-Score* e *Intersect over Union* (IoU), e, globalmente, *Overall Accuracy*, *Mean Precision*, *Mean Recall*, *Mean F1-Score*, *Mean IoU* e coeficiente Kappa (Maxwell, Warner e Guillén, 2021a; 2021b). As matrizes de confusão, representadas também de forma gráfica,

subsidiaram a comparação da performance entre os cenários, considerando métricas globais e por classe.

Resultados e Discussões

A análise comparativa entre os diferentes percentuais de amostragem testados revela comportamentos distintos em relação à acurácia e à estabilidade das métricas. Os resultados apontam que há um ganho consistente de desempenho entre os cenários com 50%, 60% e 70% de amostras, com melhora progressiva, se comparadas aos cenários com menores amostragens, em todas as métricas analisadas. A *Overall Accuracy* (OA), por exemplo, evolui de 0,85 (10%) para 0,90 (50%), enquanto o *Mean F1 Score* passa de 0,49 para 0,69 no mesmo intervalo. Os índices *Mean Recall*, *Mean F1-Score* e *Mean IoU* apresentam significativas melhoras com o aumento do número de amostragem, apontando que as classes menos representativas em números de amostras desempenham melhor com maior amostragem no treinamento (Tabela 3).

Tabela 3. Acurácia dos modelos treinados com diferentes níveis amostrais.

Modelo	OA	<i>Mean Precision</i>	<i>Mean Recall</i>	<i>Mean F1 Score</i>	<i>Mean IoU</i>
10%	0.85	0.60	0.49	0.49	0.39
20%	0.81	0.52	0.45	0.43	0.35
30%	0.89	0.62	0.54	0.56	0.46
40%	0.88	0.74	0.56	0.59	0.48
50%	0.90	0.76	0.65	0.69	0.57
60%	0.90	0.72	0.69	0.68	0.57
70%	0.90	0.73	0.57	0.69	0.57

Fonte: Elaborado pelos autores

Vale observar que a OA corresponde à razão entre o número total de classificações corretas - soma dos Verdadeiros Positivos (VP) e Verdadeiros Negativos (VN) - e o total de amostras avaliadas e, portanto, é utilizada para expressar a proporção geral de acertos do modelo. Embora forneça uma medida sintética e intuitiva do desempenho global da classificação, essa métrica apresenta limitações importantes em contextos de desbalanceamento de classes, como neste estudo de caso. Nesses cenários, categorias majoritárias podem exercer influência desproporcional sobre o resultado final e essa métrica pode superestimar a qualidade do modelo, mascarando deficiências na identificação de classes minoritárias (Morales-Barquero *et al*, 2019).

A análise conjunta das métricas permite interpretar que, ao utilizar 50% das amostras para treinamento, o classificador tornou-se mais sensível para a detecção, também,

de classes minoritárias. Isso é interpretado pela significativa melhora nos resultados de *Mean Recall* (0,65), *Mean F1 Score* (0,69) e *Mean IoU* (0,57).

A *Precision* expressa a proporção de acertos entre os elementos atribuídos a uma classe, sendo definida pela razão entre os VP e o total de predições positivas (VP + FP). A *Recall* é definida pela razão entre o número de VP e o total de elementos pertencentes a uma determinada classe no conjunto de referência VP + Falsos Negativos (FN). Essa métrica expressa a taxa de detecção do modelo, indicando sua capacidade de identificar corretamente os elementos de uma classe em relação à verdade terrestre. O *F1-Score* corresponde à média harmônica entre as métricas *Precision* e *Recall*, sintetizando-as em uma única medida de desempenho. Trata-se de um indicador especialmente relevante em cenários de desbalanceamento entre classes, pois busca equilibrar erros de omissão e de comissão. Já o *IoU* quantifica a sobreposição espacial entre as predições e o conjunto de referência, sendo obtido pela razão entre a área de interseção (VP) e a soma das áreas predita e observada (VP + FN + FP) (Morales-Barquero *et al.*, 2019; Maxwell; Warner; Guillén, 2021a, 2021b).

As fórmulas matemáticas que representam as métricas de avaliação utilizadas estão apresentadas nas equações a seguir, sendo (1) *Precision*, (2) *Recall*, (3) *F1-Score*, (4) *IoU*, (5) *Overall Accuracy* e (6) Coeficiente Kappa.

$$Precision = \frac{VP}{VP + FP} \quad (1)$$

$$Recall = \frac{VP}{VP + FN} \quad (2)$$

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3)$$

$$IoU = \frac{VP}{VP + FP + FN} \quad (4)$$

$$OA = \frac{\sum_{i=1}^n VP_i}{N} \quad (5)$$

em que N corresponde ao total de amostras avaliadas e n ao número total de classes.

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (6)$$

O coeficiente Kappa mede a concordância entre a classificação e a referência, descontada a concordância esperada ao acaso, sendo definido pela Equação (6), em que p_o corresponde à concordância observada (equivalente à OA) e p_e à concordância esperada, obtida a partir dos totais marginais da matriz de confusão, conforme a Equação (7):

$$p_e = \frac{\sum_{i=1}^n n_{i+} \cdot n_{+i}}{N^2} \quad (7)$$

em que n_{i+} e n_{+i} representam, respectivamente, os totais da linha e da coluna referentes à classe i .

Por fim, as métricas globais *Mean Precision*, *Mean Recall*, *Mean F1-Score* e *Mean IoU* correspondem à média aritmética (macro-média) dos valores obtidos por classe, atribuindo peso igual a todas as classes, conforme a Equação (8):

$$M = \frac{\sum_{i=1}^n M_i}{n} \quad (8)$$

em que $\bar{M}$ representa a média global de cada métrica; e M_i , o valor da métrica (*Precision*, *Recall*, *F1-Score* ou *IoU*) para a classe i .


Com base no exposto e na observação dos resultados, a evolução positiva das métricas de *Mean Recall*, *F1 Score* e *IoU* indica que o modelo está se tornando mais abrangente e equilibrado entre acertos e erros, sobretudo nas classes menos representadas. No entanto, a redução da *Mean Precision* é um indicativo de que o modelo está errando mais na classificação positiva das amostras, o que pode comprometer a qualidade final do mapa gerado, especialmente em aplicações que exigem elevado grau de confiabilidade, como no caso do mapeamento do uso e cobertura da terra em áreas urbanizadas e com altíssima resolução espacial.

A análise por classe confirma essa tendência. Classes com baixa representação, como “Objetos antrópicos verdes”, “Objetos antrópicos azuis” e “Água solo”, apresentaram melhorias nas métricas de *F1 Score* e *IoU* ao longo do aumento da amostragem, mas ainda com valores inferiores às demais classes. Em contrapartida, classes dominantes como “Telhado Cerâmica” e “Telhado Fibrocimento” mantiveram desempenho elevado e estável em todos os cenários, com valores superiores a 0,80 em todas as métricas, com exceção do *IoU* que variou de 0,7 a 0,9. Isso sugere que o aumento das amostras beneficiou principalmente as classes com comportamento espectral ambíguo ou com pouca representação inicial (Figura 3).

Embora o cenário com 60% de amostras apresente ligeira melhora em *Recall*, *F1-Score* e *IoU*, o conjunto de métricas indica que 50% de amostras oferece melhor equilíbrio entre acurácia, precisão e capacidade de generalização, além de demandar menos épocas de treinamento (28, contra 71 e 41 nos cenários de 60% e 70%, respectivamente). Os resultados do cenário de 60% sugerem tendência de saturação ou declínio em métricas-

chave, de modo que o cenário de 50% se mostra mais adequado em termos de esforço amostral e computacional, o que é corroborado pelas matrizes de confusão apresentadas na Figura 4.


Figura 3. Métricas de acurácia por classe. As barras verticais representam a acurácia do classificador para os diferentes cenários testados. (a) *Precision*. (b) *Recall*. (c) *F1-Score*. (d) *IoU*.



Fonte: Elaborado pelos autores

A análise comparativa das matrizes de confusão reforça que o uso de 50% e 60% das amostras (Figura 4e e 4f) tiveram os melhores desempenhos entre os cenários avaliados. Esse resultado é notado na maior concentração de valores na diagonal principal, indicando elevada correspondência entre as classes preditas e a verdade terrestre, além de menor dispersão de erros nas células fora da diagonal. Tal característica reflete maior consistência na discriminação das classes e menor ocorrência de confusões sistemáticas, aspecto essencial em classificações de uso e cobertura da terra que envolvem múltiplas categorias com potenciais sobreposições espectrais. Embora os demais cenários revelem acertos relevantes, a presença de erros mais distribuídos e desequilíbrios entre classes compromete a confiabilidade dos resultados. Dessa forma, os cenários de 50% e 60% se destacam nas matrizes como as melhores opções para o mapeamento desejado, assegurando maior equilíbrio entre precisão e generalização no contexto analisado.

Figura 4. Matrizes de confusão dos modelos treinados, sendo (a) modelo com 10% das amostras; (b) 20% de amostras; (c) 30% de amostras; (d) 40% de amostras; (e) 50% de amostras; (f) 60% de amostras; (g) 70% de amostras.




Fonte: Elaborado pelos autores

As Figuras 4a e 4b representam os modelos com as menores porcentagens amostrais (10% e 20%, respectivamente), que apresentam padrões de confusão distintos entre si. A confusão entre as classes "Asfalto" e "Cimento" (superfícies impermeáveis, espectralmente semelhantes) é sistemática em todos os cenários, tornando-se crítica no sentido Asfalto->Cimento nos modelos de menor amostragem: 258.081 pixels no cenário de 10% e 1.232.697 no de 20%, valor que quase iguala aos 1.397.407 acertos de asfalto, contra uma faixa bem menor de erro a partir de 30% de amostras. As classes de menor representatividade amostral (objetos antrópicos verde, azul e vermelho) apresentam comportamento instável entre os cenários: o modelo de 20% deixou de prever qualquer pixel das classes "objetos antrópicos verde" e "vermelho" (diagonais nulas). O vermelho só passa a ser identificado de forma consistente a partir de 30% de amostras e o azul apresenta apenas ganho discreto. Já em uma classe mais representativa, como "Vegetação Rasteira", a Figura 4a evidencia forte confusão com "Vegetação Arbórea" (415.608 pixels classificados incorretamente, contra apenas 55.073 corretos), confusão que praticamente desaparece no cenário de 50% de amostras (21.149 de erro contra 473.046 acertos). Esses elementos reforçam que, em cenários com amostras de treinamento limitadas, o modelo tende ao subajuste (*underfitting*), apresentando menor poder de discriminação entre alvos espectralmente semelhantes e classes menos representativas, gerando, consequentemente, maiores erros de classificação.

A Figura 5 apresenta o mapa de uso e cobertura da terra resultante da classificação supervisionada da ortoimagem gerada pela RPA, a partir do emprego do modelo U-Net utilizando 50% das amostras para o treinamento.

Figura 5. Mapa de uso e cobertura da terra gerado a partir da classificação supervisionada utilizando o modelo U-Net treinado com 50% de amostras.



Fonte: Elaborado pelos autores.

Considerações finais

O presente estudo avaliou o impacto da quantidade de amostras de treinamento na acurácia da classificação supervisionada realizada pelo modelo U-Net, disponível no software ArcGIS Pro, visando ao mapeamento do uso e cobertura da terra a partir de uma ortoimagem de altíssima resolução espacial gerada por aerolevantamento com RPA. Foram testados sete cenários amostrais que utilizaram de 10% a 70% de amostras vetorizadas para o treinamento do modelo. Em todos eles, 30% do dado foi utilizado para a verificação da acurácia, feita por meio das métricas *OA*, *Precision*, *Recall*, *F1 Score* e *IoU*.

Considerando as métricas centradas na avaliação global do classificador (*OA* e *Precision*), o melhor desempenho foi observado no modelo treinado com 50% de amostras, tendo resultados bem similares no modelo com 60% de amostras. Sendo observada uma leve redução na acurácia do modelo treinado com 70% das amostras. Tal resultado pode indicar o efeito de sobreajuste do modelo, que ocorre quando há um treinamento excessivo. Já as métricas *Recall*, *F1 Score* e *IoU* demonstraram uma melhoria constante da acurácia, com resultados bem parecidos entre os modelos com maior volume amostral. Acredita-se que a explicação para essa mudança de padrão de comportamento do modelo esteja no

desbalanceamento das classes, o que é sustentado pela análise das métricas por classes. Notou-se que as classes menos representativas obtiveram acurácia ínfima nos modelos de 10% a 30%, tendo resultados mais elevados nos modelos treinados com 50%, 60% e 70%. Já as classes predominantes foram menos sensíveis à redução das amostras.

O desequilíbrio de classes é inerente ao tipo de imagem utilizada, pois o excesso de detalhes possibilita observar pequenos elementos presentes na superfície, o que gera um grande desafio na classificação supervisionada das imagens. No contexto avaliado neste estudo, ressalta-se que a área possui uma infraestrutura urbana diversa e precária, que se torna complexa para a interpretação do usuário. Nesse sentido, diversos elementos que foram analisados, por exemplo “Água solo”, em um segundo momento, precisariam ser agrupados em macro classes para um aproveitamento mais efetivo em ações de planejamento e gestão urbana. Dessa forma, é natural que elementos com uma menor presença na área de estudo tenham uma acurácia menor, conforme observado nas matrizes de confusão apresentadas.

Os resultados indicam que, embora o aumento da amostragem para 60% produza melhorias pontuais em algumas métricas, o modelo com 50% se mostra mais vantajoso por conciliar bom desempenho com menor esforço de coleta de amostras e menor tempo de processamento computacional. Ressalta-se que 50% das amostras correspondem a 24,10% da área total do bairro. Esses achados podem orientar estudos futuros na definição de estratégias de rotulagem de dados para classificação de imagens de alta e altíssima resolução espacial. Recomenda-se, entretanto, a realização de testes semelhantes em outras áreas e com diferentes conjuntos de imagens, de modo a verificar se a proporção de aproximadamente 25% da área a ser classificada é suficiente para atingir acurácia próxima do máximo, como observado neste estudo. Tal discussão é particularmente relevante em sensoriamento remoto, dado que frequentemente não há dados previamente rotulados e a construção da verdade terrestre demanda extenso trabalho manual e detalhada interpretação de imagens.

Por fim, destaca-se que a relação entre o volume estipulado de amostras e desempenho esperado para o modelo classificador deve levar em consideração as características espectrais das classes, a distribuição espacial das amostras e o tipo de arquitetura utilizada. Em contextos de elevada heterogeneidade espacial, como ambientes urbanos, a seleção de uma proporção intermediária de amostras pode ser suficiente para garantir boa acurácia, evitando redundância e potenciais problemas de sobreajuste.

Referências Bibliográficas

- AIT MOULAY, M.; AARABI, A.; SALBI, A.; BOUGANSSA, I.; LASFAR, A. Image Processing of Unmanned Aerial Vehicle and Drone Imagery Using Artificial Intelligence: A Systematic Literature Review. *Springer Nature*, Switzerland, vol 1403, p. 547–561, 10 jun. 2025. Disponível em: https://doi.org/10.1007/978-3-031-91337-2_52. Acesso em: 22 set. 2025.
- CHENG, Y.; WANG, W.; REN, Z.; ZHAO, Y.; LIAO, Y.; GE, Y.; WANG, J.; HE, J.; GU, Y.; WANG, Y.; ZHANG, W.; ZHANG, C. Multi-scale Feature Fusion and Transformer Network for urban green space segmentation from high-resolution remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, v. 124, 1 nov. 2023. Disponível em: <https://doi.org/10.1016/j.jag.2023.103514>. Acesso em: 29 jun. 2025.
- CRACKNELL, A. P. The development of remote sensing in the last 40 years. *International Journal of Remote Sensing Taylor and Francis Ltd.*, 2 dez. 2018. Disponível em: <https://doi.org/10.1080/01431161.2018.1550919>. Acesso em: 13 jun. 2025.
- ESRI. Train Deep Learning Model (Image Analyst). ArcGIS Pro: tool reference. 2024. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/train-deep-learning-model.htm>. Acesso em: 18 ago. 2025.
- FARHADPOUR, S.; MAXWELL, A. E. Comparing UNet configurations for anthropogenic geomorphic feature extraction from land surface parameters. *PLOS ONE*, v. 20, n. 6 June, 10 jun. 2025. Disponível em: <https://doi.org/10.1371/journal.pone.0325904>. Acesso em: 20 set. 2025.
- GENDERINGEN, J. VAN; NGUYEN, D.; KNUTH, F.; NOMER, H.; INCROCCI, L.; SHARFO, A.; OELFKE, U.; JIANG, S.; ROSSI, L.; HEIJMEN, B.; BREEDVELD, S. The impact of training dataset size and model size on the accuracy of deep learning dose prediction. *XXth International Conference on the use of Computers in Radiation therapy*, Lyon, France, 8-11 jul. 2024. Disponível em: <https://www.iccr2024.org/papers/526134.pdf>. Acesso em: 18 set. 2025.
- GONG, Y.; CHEN, C.; ZHENG, Y. Hybrid Deep Learning Model for Multi-Source Remote Sensing Data Fusion: Integrating DenseNet and Swin Transformer for Spatial Alignment and Feature Extraction. *Informatica*, Slovenia, v. 49, n. 24, p. 197–208, 2025. Disponível em: <https://doi.org/10.31449/inf.v49i24.8395>. Acesso em: 23 set. 2025.
- GÜTTER, J.; KRUSPE, A.; ZHU, X. X.; NIEBLING, J. Impact of Training Set Size on the Ability of Deep Neural Networks to Deal with Omission Noise. *Frontiers in Remote Sensing*, v. 3, 2022. Disponível em: <https://doi.org/10.3389/frsen.2022.932431>. Acesso em: 10 ago. 2025.
- IBGE. Instituto Brasileiro de Geografia e Estatística. Panorama do Censo 2022: domicílios em favelas e comunidades urbanas. 2025. Disponível em: https://censo2022.ibge.gov.br/panorama/mapas.html?recorte=N170&tema=dom_em_favelas&localidade=3106200. Acesso em: 17 ago. 2025.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Recomendações para levantamentos relativos estáticos – GPS. Brasília, DF: IBGE, 2008. 35 p. Relatório técnico.
- IRFAN, A.; LI, Y.; E, X.; SUN, G. Land Use and Land Cover Classification with Deep Learning-Based Fusion of SAR and Optical Data. *Remote Sensing*, Basel, v. 17, n. 7, 4 abr. 2025. Disponível em: <https://doi.org/10.3390/rs17071298>. Acesso em: 28 set. 2025.
- JOHNSON, J. M.; KHOSHGOFTAAR, T. M. Survey on deep learning with class imbalance. *Journal of Big Data*, v. 6, n. 1, 1 dez. 2019. Disponível em: <https://doi.org/10.1186/s40537-019-0192-5>. Acesso em: 18 ago. 2025.

- KAVZOGLU, T.; YILMAZ, E. O. Analysis of patch and sample size effects for 2D-3D CNN models using multiplatform dataset: hyperspectral image classification of ROSIS and Jilin-1 GP01 imagery. *Turkish Journal of Electrical Engineering and Computer Sciences*, v. 30, n. 6, p. 2124–2144, 2022. Disponível em: <https://doi.org/10.55730/1300-0632.3929>. Acesso em: 03 ago. 2025.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, New York, v. 60, n. 6, p. 84–90, jun. 2017. Disponível em: <https://doi.org/10.1145/3065386>. Acesso em: 18 set. 2025.
- KVILE, K. Ø.; GUNDERSEN, H.; POULSEN, R. N.; SAMPLE, J. E.; SALBERG, A. B.; GHAREEB, M. E.; BULS, T.; BEKKBY, T.; HANCKE, K. Drone and ground-truth data collection, image annotation and machine learning: A protocol for coastal habitat mapping and classification. *MethodsX*, v. 13, dez. 2024. Disponível em: <https://doi.org/10.1016/j.mex.2024.102935>. Acesso em: 20 set. 2025.
- LEICHTLE, T.; GEISS, C.; LAKES, T.; TAUBENBÖCK, H. Class imbalance in unsupervised change detection – A diagnostic analysis from urban remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, v. 60, p. 83–98, 2017. Disponível em: <https://doi.org/10.1016/j.jag.2017.04.002>. Acesso em: 29 set. 2025.
- LI, X.; LIU, B.; ZHENG, G.; REN, Y.; ZHANG, S.; LIU, Y.; GAO, L.; LIU, Y.; ZHANG, B.; WANG, F. Deep-learning-based information mining from ocean remote-sensing imagery. *National Science Review*, v. 7, n. 10, p. 1584–1605, 2021. Disponível em: <https://doi.org/10.1093/nsr/nwaa047>. Acesso em: 5 dez. 2025.
- LI, Z.; CHEN, B.; WU, S.; SU, M.; CHEN, J. M.; XU, B. Deep learning for urban land use category classification: A review and experimental assessment. *Remote Sensing of Environment*, v. 311, 2024. Disponível em: <https://doi.org/10.1016/j.rse.2024.114290>. Acesso em 07 jun. 2025.
- LI, Z.; HE, W.; CHENG, M.; HU, J.; YANG, G.; ZHANG, H. SinoLC-1: The first 1m resolution national-scale land-cover map of China created with a deep learning framework and open-Access data. *Earth System Science Data*, v. 15, n. 11, p. 4749–4780, 30 out. 2023. Disponível em: <https://doi.org/10.5194/essd-15-4749-2023>. Acesso em: 05 set. 2025.
- MA, L.; LIU, Y.; ZHANG, X.; YE, Y.; YIN, G.; JOHNSON, B. A. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 152, p. 166–177, 2019. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2019.04.015>. Acesso em: 5 dez. 2025.
- MAGALHÃES, D. M. Uso de drones como suporte ao planejamento territorial: da coleta de dados à geovisualização. Orientadora: Ana Clara Mourão Moura. 2021. 257 f. Tese (Doutorado em Geografia) – Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2021. Disponível em: <https://hdl.handle.net/1843/36455>. Acesso em: 16 out. 2026.
- MAGALHÃES, D. M.; DE SOUZA, J. P.; DE FRANÇA, E. A. G. Deep Learning para Classificação Supervisionada de Imagens CBERS-4A da Área Urbana de Rio Claro (SP). *Revista Brasileira de Cartografia*, Uberlândia, v. 77, 2025. DOI: [10.14393/rbcv77n0a-75495](https://doi.org/10.14393/rbcv77n0a-75495). Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/75495>. Acesso em: 29 jul. 2026.
- MAXWELL, A. E.; WARNER, T. A.; GUILLÉN, L. A. Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review. *Remote Sensing*, v. 13, n. 13, art. 2450, 2021a. DOI: [10.3390/rs13132450](https://doi.org/10.3390/rs13132450). Disponível em: <https://doi.org/10.3390/rs13132450>. Acesso em: 18 ago. 2025.

- MAXWELL, A. E.; WARNER, T. A.; GUILLÉN, L. A. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 2: Recommendations and Best Practices. *Remote Sensing*, v. 13, n. 13, art. 2591, 2021b. DOI: 10.3390/rs13132591. Disponível em: <https://doi.org/10.3390/rs13132591>. Acesso em: 18 ago. 2025.
- MONICO, J. F. G. *Posicionamento pelo NAVSTAR-GPS: Descrição, Fundamentos e Aplicações*. 1ª ed. São Paulo: Unesp, 2000. 287 p.
- MORALES-BARQUERO, L.; LYONS, M. B.; PHINN, S. R.; ROELFSEMA, C. M. Trends in remote sensing accuracy assessment approaches in the context of natural resources. *Remote Sensing*, v. 11, n. 19, art. 2305, 2019. DOI: 10.3390/rs11192305. Disponível em: <https://doi.org/10.3390/rs11192305>. Acesso em: 7 set. 2025.
- MORAN, E. F. Land Cover Classification in a Complex Urban-Rural Landscape with Quickbird Imagery. *Photogramm Eng Remote Sensing*, v. 76, n. 10, p. 1159–1168, 2010. Disponível em: <https://doi.org/10.14358/pers.76.10.1159>. Acesso em: 08 jun. 2025.
- NAUSHAD, R.; KAUR, T.; GHADERPOUR, E. Deep transfer learning for land use and land cover classification: A comparative study. *Sensors*, v. 21, n. 23, 1 dez. 2021. Disponível em: <https://doi.org/10.3390/s21238083>. Acesso em: 08 ago. 2025.
- NIGAR, A.; LI, Y.; JAT BALOCH, M. Y.; ALREFAEI, A. F.; ALMUTAIRI, M. H. Comparison of machine and deep learning algorithms using Google Earth Engine and Python for land classifications. *Frontiers in Environmental Science*, v. 12, 2024. Disponível em: <https://doi.org/10.3389/fenvs.2024.1378443>. Acesso em: 06 jun. 2025.
- NING, H.; LI, Z.; WANG, C.; YANG, L. Choosing an appropriate training set size when using existing data to train neural networks for land cover segmentation. *Annals of GIS*, v. 26, n. 4, p. 329–342, 2020. Disponível em: <https://doi.org/10.1080/19475683.2020.1803402>. Acesso em: 10 ago. 2025.
- PRODABEL - EMPRESA DE INFORMÁTICA E INFORMAÇÃO DO MUNICÍPIO DE BELO HORIZONTE. Mapa de Declividade em Graus: Município de Belo Horizonte. Disponível em: https://prefeitura.pbh.gov.br/sites/default/files/estrutura-de-governo/bhgeo/galeria-de-mapas/bh_declividade_graus_a0_150dpi_30112022.pdf. Acesso em: 16 ago. 2025.
- REDE RECORD. Balanço Geral MG. 2025. Disponível em: <https://noticias.r7.com/minas-gerais/balanco-geral-mg/video/bairro-a-bairro-rua-ingreme-e-sem-pavimentacao-prejudica-moradores-em-belo-horizonte-26062025/>. Acesso em: 16 ago. 2025.
- SANTOS, A. P.; RODRIGUES, D. D.; SANTOS, N. T.; GRIPP JUNIOR, J. Avaliação da acurácia posicional em dados espaciais utilizando estatística espacial: proposta de método e exemplo utilizando a norma brasileira. *Boletim de Ciências Geodésicas*, v. 22, n. 4, p. 630–650, 2016.
- SERTEL, E.; EKIM, B.; OSGOUEI, P. E.; KABADAYI, M. E. Land Use and Land Cover Mapping Using Deep Learning Based Segmentation Approaches and VHR Worldview-3 Images. *Remote Sensing*, v. 14, n. 18, 1 set. 2022. Disponível em: <https://doi.org/10.3390/rs14184558>. Acesso em: 05 mai. 2025.
- SILVA, José Gustavo Santos da; SUTIL, Thaise; MENEGASSO, Juliana Debiassi; LADWIG, Nilzo Ivo. Briefing geohistórico dos estudos de cobertura e uso da terra no planejamento e na gestão territorial. In: LADWIG, Nilzo Ivo (org.). *Planejamento e gestão do território e da paisagem*. Ponta Grossa: Atena Editora, 2022. cap. 1, p. 1-13. DOI: 10.22533/at.ed.2382219091. Disponível em: <https://atenaeditora.com.br/catalogo/ebook/planejamento-e-gestao-do-territorio-e-da-paisagem>. Acesso em: 31 jul. 2026.

URBEL - COMPANHIA URBANIZADORA E DE HABITAÇÃO DE BELO HORIZONTE. Prefeitura de Belo Horizonte. Disponível em: <https://prefeitura.pbh.gov.br/urbel/regularizacao-fundiaria>. Acesso em: 16 ago. 2025.

VASAVI, S.; SRI SOMAGANI, H.; SAI, Y. Classification of buildings from VHR satellite images using ensemble of U-Net and ResNet. *Egyptian Journal of Remote Sensing and Space Science*, v. 26, n. 4, p. 937–953, 1 dez. 2023. Disponível em: <https://doi.org/10.1016/j.ejrs.2023.11.008>. Acesso em: 14 jun. 2025.

VERDE, N.; PATIAS, P.; MALLINIS, G. A Cloud-Based Mapping Approach Using Deep Learning and Very-High Spatial Resolution Earth Observation Data to Facilitate the SDG 11.7.1 Indicator Computation. *Remote Sensing*, v. 14, n. 4, 1 fev. 2022. Disponível em: <https://doi.org/10.3390/rs14041011>. Acesso em: 13 mai. 2025.

WAGNER, F. H.; DALAGNOL, R.; CASAPIA, X. T.; STREHER, A. S.; PHILLIPS, O. L.; GLOOR, E.; ARAGÃO, L. E. O. C. Regional mapping and spatial distribution analysis of Canopy palms in an Amazon forest using deep learning and VHR images. *Remote Sensing*, v. 12, n. 14, 1 jul. 2020. Disponível em: <https://doi.org/10.3390/rs12142225>. Acesso em: 19 jun. 2025.

WANG, R.; MA, L.; HE, G.; JOHNSON, B. A.; YAN, Z.; CHANG, M.; LIANG, Y. Transformers for Remote Sensing: A Systematic Review and Analysis. *Sensors*, v. 24, n. 11, p. 3495, 2024. Disponível em: <https://doi.org/10.3390/s24113495>. Acesso em: 3 mar. 2025.

WANG, Z.; MOUNTRAKIS, G.; PASTICK, N. J. Deep learning approaches on Landsat observations: a review and meta-analysis. *International Journal of Remote Sensing*, v. 46, n. 15, p. 5601–5627, 3 jul. 2025. Disponível em: <https://doi.org/10.1080/01431161.2025.2520050>. Acesso em: 10 out. 2025.

YILMAZ, E. O.; KAVZOGLU, T. Analysis of the effect of training sample size on the performance of 2D CNN models. *2nd Intercontinental Geoinformation Days*, Turkey, 5 maio 2021. Disponível em: <https://www.researchgate.net/publication/351778378>. Acesso em: 20 out. 2025.

ZANETTI, J.; GRIPP JUNIOR, J.; SANTOS, A. P. Influência do número de pontos de controle em ortofotos geradas a partir de um levantamento por VANT. *Revista Brasileira de Cartografia*, v. 69, n. 2, p. 263–277, 2017.

ZHAO, S.; TU, K.; YE, S.; TANG, H.; HU, Y.; XIE, C. Land Use and Land Cover Classification Meets Deep Learning: A Review. *Sensors*, v. 23, n. 21, p. 8966, 2023. Disponível em: <https://doi.org/10.3390/s23218966>. Acesso em: 11 jan. 2025.