

## EVOLUÇÃO E EFICÁCIA DE ALGORITMOS DE *MACHINE LEARNING* NA CLASSIFICAÇÃO DO USO E COBERTURA DO SOLO URBANO

EVOLUTION AND EFFECTIVENESS OF *MACHINE LEARNING* ALGORITHMS IN  
URBAN LAND USE AND LAND COVER CLASSIFICATION

EVOLUCIÓN Y EFICACIA DE LOS ALGORITMOS DE *MACHINE LEARNING* EN  
LA CLASIFICACIÓN DEL USO Y COBERTURA DEL SUELO URBANO

Mariana Rodrigues Pereira<sup>1</sup>, Max Hiroito Tieti<sup>2</sup>

DOI: 10.54899/dcs.v23i87.4565

Recibido: 11/02/2026 | Aceptado: 13/02/2026 | Publicación en línea: 20/02/2026.

### RESUMO

A ciência da geoinformação atravessa uma transição paradigmática dos métodos estatísticos clássicos para abordagens de Aprendizado de Máquina (Machine Learning - ML) e Aprendizado Profundo (Deep Learning - DL), motivada pela complexidade espectral dos ambientes urbanos. Diante desse cenário, o presente estudo teve como objetivo analisar a eficácia e o desempenho comparativo desses algoritmos na classificação da cobertura da terra e infraestrutura verde. A metodologia consistiu em uma revisão bibliográfica sistemática e integrativa, com buscas nas bases BDTD e no periódico Remote Sensing, utilizando operadores booleanos para selecionar estudos que empregaram sensores ópticos, SAR e LiDAR. Os resultados demonstraram que, embora o DL (arquiteturas U-Net e PSPNet) apresente acurácia superior (F1-Score > 92%) na segmentação de objetos biologicamente complexos, algoritmos de ML como Random Forest e SVM permanecem como padrões de eficácia devido à robustez em dados multissensoriais e menor custo computacional. Conclui-se que o trabalho alcançou os objetivos propostos ao validar ferramentas que transformam dados brutos de satélite em informações rigorosas, essenciais para o planejamento de cidades inteligentes e resilientes.

**Palavras-chave:** *Deep Learning*. Monitoramento Ambiental. Infraestrutura Verde Urbana. Sensoriamento Remoto Urbano.

### ABSTRACT

Geoinformation science is undergoing a paradigmatic transition from classical statistical methods to Machine Learning (ML) and Deep Learning (DL) approaches, driven by the spectral complexity of urban environments. Given this scenario, the present study aimed to analyze the effectiveness and comparative performance of these algorithms in land cover and green infrastructure classification. The methodology consisted of a systematic and integrative literature review, with searches in the BDTD database and the Remote Sensing journal, using Boolean

<sup>1</sup> Bacharela em Arquitetura e Urbanismo, Universidade Federal de Mato Grosso do Sul (UFMS), Campo Grande, Mato Grosso do Sul, Brasil. E-mail: mariana.pereira@ufms.br Orcid: <https://orcid.org/0009-0002-7083-8186>

<sup>2</sup> Doutorando em Desenvolvimento Local, Universidade Católica Dom Bosco, Campo Grande, Mato Grosso do Sul, Brasil. E-mail: max\_hiroito@ufms.br Orcid: <https://orcid.org/0009-0006-5607-2953>

operators to select studies that employed optical, SAR, and LiDAR sensors. The results demonstrated that although DL (U-Net and PSPNet architectures) presents superior accuracy (F1-Score > 92%) in the segmentation of biologically complex objects, ML algorithms such as Random Forest and SVM remain as standards of effectiveness due to their robustness in multisensory data and lower computational cost. It is concluded that the work achieved its proposed objectives by validating tools that transform raw satellite data into rigorous information, essential for the planning of smart and resilient cities.

**Keywords:** Deep Learning. Environmental Monitoring. Green Urban Infrastructure. Urban Remote Sensing.

## RESUMEN

La ciencia de la geoinformación atraviesa una transición paradigmática de los métodos estadísticos clásicos a enfoques de Aprendizaje Automático (Machine Learning - ML) y Aprendizaje Profundo (Deep Learning - DL), motivada por la complejidad espectral de los entornos urbanos. Ante este escenario, el presente estudio tuvo como objetivo analizar la eficacia y el desempeño comparativo de estos algoritmos en la clasificación de la cobertura del suelo e infraestructura verde. La metodología consistió en una revisión bibliográfica sistemática e integrativa, con búsquedas en las bases BDTD y en la revista Remote Sensing, utilizando operadores booleanos para seleccionar estudios que emplearon sensores ópticos, SAR y LiDAR. Los resultados demostraron que, aunque el DL (arquitecturas U-Net y PSPNet) presenta una precisión superior (F1-Score > 92%) en la segmentación de objetos biológicamente complejos, los algoritmos de ML como Random Forest y SVM permanecen como estándares de eficacia debido a su robustez en datos multisensoriales y menor costo computacional. Se concluye que el trabajo alcanzó los objetivos propuestos al validar herramientas que transforman datos brutos de satélite en información rigurosa, esencial para la planificación de ciudades inteligentes y resilientes.

**Palabras clave:** *Deep Learning*. Monitoreo Ambiental. Infraestructura Verde Urbana. Sensoriamento Remoto Urbano.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

---

## INTRODUÇÃO

A ciência da geoinformação atravessa um período de transição paradigmática, migrando de métodos de classificação fundamentados em estatística clássica e análise por pixels para abordagens robustas de Aprendizado de Máquina (*Machine Learning* – ML) e Aprendizado Profundo (*Deep Learning* – DL).

Esse avanço é impulsionado pela necessidade de processar volumes massivos de dados

multissensoriais e responder à crescente complexidade dos ambientes urbanos. As cidades, definidas como sistemas biológicos e abióticos integrados em múltiplas escalas (Blaschke, 2011), impõem desafios significativos ao mapeamento remoto devido à sua heterogeneidade espacial e à similaridade espectral entre diferentes materiais, como asfalto, concreto e tipos variados de vegetação.

Tradicionalmente, a classificação por pixel apresentava limitações na captura da diversidade morfológica das áreas densas, o que fomentou o desenvolvimento da Análise de Imagem Baseada em Objeto (GEOBIA). Nesse cenário, algoritmos de ML, como *Random Forest* (RF) e *Support Vector Machine* (SVM), estabeleceram-se como padrões de eficácia pela capacidade de integrar variáveis de forma, textura e contexto. Contudo, a ascensão das Redes Neurais Convolucionais (CNNs) introduziu uma nova fronteira de precisão, permitindo a extração automática de atributos semânticos de alto nível e a segmentação detalhada de alvos urbanos complexos em imagens de altíssima resolução.

Diante desse panorama de evolução tecnológica e metodológica, este trabalho teve como objetivo geral analisar a eficácia e o desempenho comparativo de algoritmos de *Machine Learning* e *Deep Learning* na classificação da cobertura da terra e infraestrutura verde em ambientes urbanos.

Especificamente, o estudo buscou: 1) Avaliar a robustez dos algoritmos RF e SVM no processamento de dados ruidosos e multissensoriais (SAR e ópticos); 2) Verificar o ganho de acurácia proporcionado pelas arquiteturas de *Deep Learning* (U-Net e PSPNet) na identificação de componentes biologicamente complexos, como o dossel arbóreo; 3) Hierarquizar a aplicabilidade desses métodos em função do custo computacional, volume de dados de treinamento e precisão estatística, fornecendo subsídios técnicos para o planejamento de cidades inteligentes e resilientes.

## REFERENCIAL TEÓRICO

Na ciência da geoinformação ocorre a transição de métodos de classificação baseados em pixels e estatística clássica para abordagens robustas de Aprendizado de Máquina (*Machine Learning* - ML) e, mais recentemente, para a predominância de Aprendizado Profundo (*Deep Learning* - DL). A partir disso, o ambiente urbano, caracterizado por sua heterogeneidade espacial e complexidade espectral, tem sido o principal laboratório para testar a eficácia desses algoritmos.

As cidades são sistemas complexos compostos por componentes biológicos e não biológicos que interagem em múltiplas escalas espaço-temporais (Blaschke, 2011). O planejamento urbano exige conhecimento espacialmente explícito, mas os métodos tradicionais de mapeamento muitas vezes falham em capturar a dinâmica rápida e a diversidade de materiais (concreto, asfalto, vegetação, água) em áreas densas (Barbosa, 2021).

Historicamente, a classificação de imagens baseava-se em análises "per-pixel" (por pixel). No entanto, com o aumento da resolução espacial das imagens, surgiu o problema onde pixels individuais não capturam as características dos alvos de classificação, levando ao desenvolvimento da Análise de Imagem Baseada em Objeto (GEOBIA).

Esta abordagem segmenta a imagem em objetos homogêneos antes da classificação, permitindo o uso de forma, textura e contexto, além da resposta espectral, conforme Blaschke (2011). É neste cenário de dados complexos (SAR, LiDAR, Óptico de alta resolução) e novas abordagens de segmentação que os algoritmos de ML ganharam destaque.

Barbosa (2021) e Kranjčić *et al.* (2019) demonstraram que algoritmos como *Random Forest* (RF) e *Support Vector Machine* (SVM) se estabeleceram como o padrão de eficácia para classificação supervisionada antes da popularização massiva do *Deep Learning*. O algoritmo Random Forest é amplamente citado por sua robustez e facilidade de parametrização. Ele opera criando múltiplas árvores de decisão aleatórias e votando na classe mais provável.

Na tese de Barbosa (2021), o RF foi utilizado para classificar o uso do solo no Distrito Federal usando imagens de radar Sentinel-1. O estudo provou que o RF é capaz de lidar com a complexidade dos dados de radar (amplitude e fase). A eficácia do RF aumentou significativamente quando alimentado com séries temporais de coerência interferométrica, elevando o índice Kappa de 0,50 para 0,75 e o F1-Score de 0,54 para 0,79.

Desse modo, o RF mostrou-se excelente para distinguir classes vegetacionais (campo, savana, floresta), com o F1-Score para floresta saltando de 0,47 para 0,93 ao integrar dados de coerência (Barbosa, 2021). Contudo, uma limitação foi observada: a inserção de métricas de coerência prejudicou a identificação de "edificações" puras devido à suavização dos dados, sugerindo que o RF funciona melhor para objetos urbanos rígidos usando apenas a intensidade do sinal.

Nesse panorama, na dissertação de Cano (2022), o RF foi usado como baseline para mapear áreas permeáveis e florestas urbanas usando imagens do *Google Earth Pro*. O algoritmo

atingiu uma acurácia global de 91,80% e F1-Score superior a 90%, provando ser uma ferramenta eficiente e de baixo custo computacional comparado ao *Deep Learning*.

Kranjčić *et al.* (2019) forneceram uma comparação direta entre quatro métodos (SVM, RF, Redes Neurais Artificiais - ANN, e *Naïve Bayes*) usando imagens Sentinel-2 para mapear infraestrutura verde em cidades croatas (Varaždin e Osijek). O SVM superou os outros métodos em termos de acurácia e tempo de execução. Para a cidade de Varaždin, o SVM obteve um Kappa de 0.87, enquanto o RF obteve 0.78 e a ANN apenas 0.52.

O SVM demonstrou ser menos consumidor de tempo (14,53 segundos contra 18,33 do RF na melhor configuração) e mais preciso na separação de classes complexas em ambientes urbanos. O estudo concluiu que, para mapeamento de infraestrutura verde com dados Sentinel-2, o SVM é a escolha recomendada devido à sua alta precisão e eficiência (Kranjčić *et al.*, 2019).

Nesse cenário, a evolução mais recente, detalhada nos trabalhos de Cano (2022) e Huerta *et al.* (2021), foi a transição para Redes Neurais Convolucionais (CNNs). A análise cienciométrica mostrou que as publicações sobre *Deep Learning* em sensoriamento remoto começaram timidamente em 2014 e explodiram exponencialmente até 2020, lideradas por pesquisadores na China.

Diferente do ML tradicional, que exige a extração manual de atributos (feature engineering), o *Deep Learning* extrai automaticamente características de baixo a alto nível (bordas, texturas, semântica). A arquitetura U-Net provou ser a mais consistente para mapeamento urbano (Cano, 2022; Huerta *et al.*, 2021).

Na dissertação de Cano (2022), a U-Net (com *batchsize* 4) atingiu o melhor desempenho para mapear florestas urbanas (F1-Score de 92,56%), superando modelos mais complexos como o PSPNet para esta tarefa específica (Cano, 2022). Sua estrutura de codificador-decodificador simétrico permitiu capturar detalhes finos, essenciais para delinear copas de árvores em ambientes urbanos densos (Huerta *et al.*, 2021).

O modelo PSPNet (*Pyramid Scene Parsing Network*) destacou-se no mapeamento de áreas permeáveis (gramados, solo exposto), atingindo um F1-Score de 94,69% no estudo de Cano. Ele foi superior na identificação de solo exposto, contexto no qual outros modelos falharam (Cano, 2022). Segundo Cano (2022), embora tenha apresentado métricas altas de precisão em alguns testes, o DeepLabV3 mostrou problemas com especificidade (classificação correta de negativos) e sensibilidade em comparação à U-Net para objetos pequenos.

Nessa perspectiva, o estudo de Huerta *et al.* (2021) aprofunda a eficácia do DL ao testar diferentes codificadores (encoders) dentro da arquitetura U-Net para segmentação de espaços verdes no México. Quando comparados, ResNet-34 versus ResNet-50, o uso de codificadores pré-treinados (Transfer Learning) é crucial. O modelo com ResNet-34 e a composição de bandas NDVI-Vermelho-Infravermelho Próximo (NIR) obteve o melhor resultado (Coeficiente Dice de 0.57 e Acurácia de 0.95).

Huerta *et al.* (2021) destaca que, embora a acurácia global seja alta (devido ao desequilíbrio de classes onde "não-verde" é majoritário), o Coeficiente Dice é uma métrica mais honesta. O valor de 0,57, embora pareça baixo comparado a estudos de cobertura do solo simples, é considerado robusto dada a complexidade de segmentar polígonos com geometrias variadas (rotatórias, canteiros centrais, parques) e não apenas pixels.

A evolução dos algoritmos é inseparável da evolução dos dados. A eficácia do ML/DL depende intrinsecamente do tipo de sensor utilizado. Nesse âmbito, a tese de Barbosa (2021) ilumina o papel do SAR, o qual não sofre influência de nuvens, fator vital para monitoramento temporal.

A eficácia do algoritmo muda conforme o *input*. Para objetos urbanos (prédios), a intensidade (backscatter) é mais eficaz devido ao efeito de "duplo rebote" (double-bounce). Para vegetação e áreas naturais, a coerência interferométrica (estabilidade da fase do sinal ao longo do tempo) é superior. A fusão desses dados em "cubos temporais" processados por Random Forest permitiu distinguir classes que se confundem no espectro óptico (Barbosa, 2021).

O LiDAR fornece a estrutura vertical, essencial para cidades. O LiDAR Aerotransportado (ALS), permite gerar Modelos Digitais de Elevação (MDE) de altíssima precisão. Barbosa (2021) demonstrou que, em áreas urbanas, o LiDAR revela a microtopografia e artefatos (muros, prédios) que influenciam a drenagem urbana e o cálculo de Índices Topográficos de Umidade (ITU).

Sobre o LiDAR Orbital (GEDI), uma inovação recente analisada por Barbosa é o uso do sensor GEDI da NASA. Foi proposto um método estatístico (teste Kolmogorov-Smirnov) para remover ruídos (outliers) dos dados GEDI, melhorando o RMSE de 8.91m para 1.33m, tornando esses dados viáveis para estudos urbanos em escala local/regional.

Em se tratando de Imagens de Altíssima Resolução e Índices Espectrais, Huerta *et al.* (2021) e Cano (2022) mostram que para DL, a resolução espacial é crítica. O uso de imagens WorldView-2 (0.5m) e Google Earth Pro permitiu a identificação de objetos pequenos. Além

disso, a engenharia de inputs (usar NDVI, EVI2 e NDWI como bandas adicionais) aumentou significativamente a capacidade da rede neural de distinguir vegetação de áreas impermeáveis.

A revisão de Blaschke (2011) apontou para o futuro da classificação urbana: a Senciência Coletiva (Collective Sensing). A eficácia não reside mais apenas no algoritmo de classificação de imagem, mas na integração de Sensoriamento Remoto com Redes de Sensores (Sensor Webs) e Sistemas de Informação Geográfica (SIG).

Enquanto o sensoriamento remoto fornece a visão sinóptica ("de cima"), sensores in situ fornecem dados em tempo real sobre qualidade do ar, tráfego e microclima. A integração desses dados via padrões OGC (Open Geospatial Consortium) permite passar do monitoramento da "infraestrutura física" para o monitoramento da "qualidade de vida" e interações humano-ambiente (Blaschke, 2011).

Desse modo, conforme Blaschke (2011), a eficácia dos algoritmos será medida pela sua capacidade de alimentar sistemas de "Cidades Inteligentes", onde dados de satélite são cruzados com dados sociais e sensores móveis para gestão em tempo real.

Dessa maneira, com base nos autores citados, podemos hierarquizar a eficácia dos métodos para aplicações urbanas atuais:

*Deep Learning* (U-Net/ResNet/PSPNet):

- Eficácia: Altíssima (F1-Score > 92%).
- Melhor uso: Segmentação semântica detalhada de objetos complexos (copas de árvores individuais, polígonos de parques) em imagens de alta resolução (RGB/Aéreas).
- Custo: Exige alto poder computacional (GPU) e grandes conjuntos de dados rotulados.

*Support Vector Machine* (SVM):

- Eficácia: Alta (Kappa ~0.89).
- Melhor uso: Classificação geral de uso do solo com imagens multiespectrais (Sentinel-2), especialmente quando o tempo de processamento é crítico e o dataset de treino é limitado. Supera o RF em alguns contextos urbanos europeus.

*Random Forest* (RF):

- Eficácia: Alta a Muito Alta (Kappa ~0.75 - 0.90).
- Melhor uso: Processamento de dados ruidosos ou complexos como Radar (SAR) e fusão de dados (SAR + Óptico). Excelente para lidar com séries temporais e evitar overfitting. É o "cavalo de batalha" confiável da classificação urbana.

Métodos Tradicionais (ANN simples, *Naïve Bayes*):

- Eficácia: Moderada a Baixa.
- Limitação: Tendem a falhar na complexidade espectral das cidades ou exigem tempos de treinamento proibitivos para a precisão que entregam.

Assim sendo, entendemos que a evolução dos algoritmos de classificação urbana migrou de uma abordagem puramente espectral para uma abordagem contextual e semântica. A eficácia não é mais uma métrica isolada, mas depende da combinação correta entre Dado (SAR para estrutura/tempo, Óptico para detalhe), Algoritmo (DL para segmentação complexa, RF/SVM para classificação temática rápida) e Integração (fusão com dados in situ e LiDAR).

Portanto, para atingir níveis elevados de acurácia na identificação de alvos complexos, como a distinção entre dosséis arbóreos, arbustos ou gramados, o *Deep Learning* (DL) apresenta desempenho superior, embora demande dados de alta resolução espacial. Contudo, isso não torna os métodos tradicionais obsoletos; ao contrário, tais abordagens demonstram-se frequentemente mais eficientes sob o ponto de vista computacional, apresentando maior celeridade no processamento e menor exigência quanto ao volume de dados de treinamento.

## METODOLOGIA

A presente pesquisa caracteriza-se como uma revisão bibliográfica de natureza qualitativa e descritiva, conduzida com o objetivo de analisar a evolução e a eficácia de algoritmos de *Machine Learning* e *Deep Learning* no sensoriamento remoto urbano.

A seleção do *corpus* documental baseou-se em buscas realizadas em bases de dados científicas de referência, especificamente na Biblioteca Digital de Teses e Dissertações (BDTD), visando o panorama acadêmico nacional, e no periódico internacional *Remote Sensing*, devido ao seu alto impacto e especialização na temática. A estratégia de busca foi estruturada mediante a combinação de termos controlados e palavras-chave em língua inglesa, utilizando-se o operador booleano AND para o refinamento do recorte temático: *Deep Learning* AND *Environmental Monitoring* AND *Green Urban Infrastructure* AND *Urban Remote Sensing*.

O critério de seleção dos estudos incluiu teses, dissertações e artigos originais que abordassem comparativos de acurácia entre algoritmos tradicionais e modernos (RF, SVM, CNN) e o uso de múltiplos sensores (SAR, LiDAR e ópticos de alta resolução). Foram priorizados trabalhos que fornecessem métricas de desempenho estatístico explícitas, como Índice Kappa, F1-Score e *Intersection over Union* (IoU).

A análise dos dados foi realizada por meio de uma síntese integrativa, em que os achados foram categorizados em quatro eixos temáticos de entendimento: (1) Evolução e Superioridade do ML/DL; (2) Eficácia de Algoritmos Específicos; (3) Aplicações na Classificação do Solo Urbano e Áreas Verdes; e (4) Resultados e Métricas de Desempenho.

## RESULTADOS E DISCUSSÃO

Ao analisar a evolução e superioridade do Machine Learning (ML), percebemos que “as metodologias envolvendo novos sensores orbitais junto ao potencial oferecido pelo aprendizado de máquinas apresentam-se como uma oportunidade em se lidar com objetos terrestres que envolvam uma ampla complexidade de materiais artificiais” (Barbosa, 2021, p. 2).

Essa perspectiva é reforçada pelo fato de que, "devido a sua superioridade frente aos tradicionais algoritmos de classificação, as soluções *machine learning* foram bem-sucedidas em várias abordagens de reconhecimento visual, tais como classificação de objetos de superfície" (Barbosa, 2021, p. 2). Nesse sentido, tais "abordagens de aprendizado de máquina tornaram-se amplamente aceitas e eficazes para classificar imagens de sensoriamento remoto, particularmente evidenciadas para o mapeamento da cobertura da terra" (Cano, 2022, p. 6).

A eficácia desses métodos reside na sua versatilidade, uma vez que "os algoritmos de aprendizado de máquina são capazes de modelar dados de classes complexas para identificar padrões e aceitar uma variedade de conjuntos de dados de entrada" (Cano, 2022, p. 6). Corroborando essa visão, Kranjčić *et al.* (2019, p. 1) afirmam que "a maneira mais eficaz é aplicar métodos de aprendizado de máquina a imagens de satélite" (Kranjčić *et al.*, 2019, p. 1, tradução nossa).

Além disso, a literatura destaca que "as soluções de machine learning têm obtido sucesso em diversas abordagens de reconhecimento visual, tais como a classificação de objetos de superfície, a detecção de objetos e o registro de mudanças temporais" (Barbosa, 2021, p. 14).

Mais recentemente, "a evolução tecnológica e o desenvolvimento do *deep learning* permitiram otimizar a aquisição de inventários de áreas verdes urbanas (UGS) através da detecção de padrões geométricos" (Huerta *et al.*, 2021, p. 1, tradução nossa), demonstrando que "avanços recentes em *Deep Learning* (DL) proporcionaram melhorias significativas na classificação da cobertura da terra a partir de imagens de alta resolução" (Huerta *et al.*, 2021, p. 2, tradução nossa).

No que tange à eficácia de algoritmos específicos, o *Random Forest* (RF) destacou-se por

sua estrutura operacional, pois o método “consiste em um processo de predição de resultados tendo por base o desenvolvimento e a utilização de um conjunto de árvores de decisão criadas aleatoriamente” (Barbosa, 2021, p. 16). Sob essa perspectiva, observamos que “o uso de imagens do Google Earth Pro submetidas à classificação com o algoritmo Random Forest apresenta um bom desempenho para mapeamento de árvores e áreas permeáveis em um ambiente urbano” (Cano, 2022, p. 23). Tal eficiência foi justificada pela natureza do algoritmo, dado que o “*Random Forest* é robusto contra sobreajuste (*overfitting*) e lida bem com grandes volumes de dados de alta dimensionalidade” (Cano, 2022, p. 17).

Contudo, ao comparar diferentes modelos, notamos que as *Support Vector Machine* (SVM) podem apresentar vantagens competitivas. Segundo Kranjčić *et al.* (2019, p. 1, tradução nossa), “as máquinas de vetores de suporte (SVM) superam as florestas aleatórias, as redes neurais artificiais e o classificador Naïve Bayes em termos de acurácia de classificação”. Os autores reforçaram essa superioridade ao afirmar que o “SVM oferece uma acurácia global ligeiramente superior em comparação ao RF e ANN para o mapeamento de áreas verdes urbanas” (Kranjčić *et al.*, 2019, p. 11, tradução nossa). Por outro lado, as Redes Neurais Artificiais (ANN) também demonstraram relevância, sendo consideradas “poderosas para o mapeamento não linear e eficazes na classificação da cobertura urbana quando as amostras de treinamento são suficientes” (Kranjčić *et al.*, 2019, p. 3, tradução nossa).

Em uma perspectiva de evolução para métodos de *Deep Learning*, as arquiteturas de redes neurais convolucionais têm redefinido os padrões de precisão. Nesse contexto, “técnicas de *deep learning*, especificamente as arquiteturas U-Net, têm demonstrado um desempenho notável na segmentação semântica de áreas urbanas” (Huerta *et al.*, 2021, p. 4, tradução nossa). A eficácia dessas redes foi potencializada por integrações estruturais, uma vez que “a arquitetura ResNet combinada com U-Net permite uma extração de características mais profunda, melhorando a precisão na classificação de solos urbanos complexos” (Huerta *et al.*, 2021, p. 5, tradução nossa).

A aplicação prática dessas tecnologias é fundamental para a gestão pública, pois “o mapeamento de áreas permeáveis é essencial para a gestão de águas pluviais e mitigação de inundações em centros urbanos” (Cano, 2022, p. 14). Nesse contexto, a literatura destacou que “o mapeamento de Espaços Verdes Urbanos (UGS) é essencial para o monitoramento da qualidade ambiental e do bem-estar humano nas cidades” (Huerta *et al.*, 2021, p. 1, tradução nossa).

Para viabilizar esse monitoramento, a integração de dados é uma estratégia central, pois

“a integração de tecnologias geoespaciais é fundamental para a compreensão da complexidade dos sistemas urbanos e sua evolução” (Blaschke *et al.*, 2011, p. 1744, tradução nossa). Complementarmente, notamos que “dados de sensoriamento remoto, integrados ao aprendizado de máquina, proporcionam uma maneira econômica de atualizar mapas de cobertura do solo urbano frequentemente” (Blaschke *et al.*, 2011, p. 1745, tradução nossa). Um exemplo dessa integração foi observado quando “a classificação de imagens SAR utilizando solução *machine learning* contribui no processo de elaboração do mapa de uso e ocupação da terra em ambiente urbano” (Barbosa, 2021, p. 2).

Entretanto, a complexidade das cidades impõe desafios técnicos, uma vez que “as estruturas urbanas são altamente heterogêneas, exigindo algoritmos que possam lidar com a similaridade espectral entre diferentes classes de cobertura da terra” (Huerta *et al.*, 2021, p. 2, tradução nossa). Para superar tais obstáculos, o uso de modelos robustos tem se mostrado eficiente; por exemplo, “a precisão na classificação de 'solo exposto' e 'áreas construídas' é significativamente aumentada com o uso de classificadores não-paramétricos como SVM” (Kranjčić *et al.*, 2019, p. 10, tradução nossa). De maneira análoga, “a aplicação de *Random Forest* permitiu identificar áreas de 'pavimento' com maior clareza do que métodos estatísticos tradicionais” (Cano, 2022, p. 45).

A análise dos resultados evidencia o alto desempenho das técnicas modernas. No estudo de Cano (2022, p. 3), “os resultados obtidos [...] indicaram alta precisão, com F1-Score superior a 90% para mapeamento de áreas permeáveis usando métodos tradicionais de aprendizado de máquina”. Além disso, verificamos que “acurácia global superior a 85% foi alcançada na classificação de uso do solo urbano no Distrito Federal utilizando algoritmos de aprendizado supervisionado” (Barbosa, 2021, p. 40).

A eficácia também foi observada no uso de dados orbitais específicos, em que “os resultados da classificação demonstraram que as imagens do Sentinel-2, combinadas com algoritmos de aprendizado de máquina, fornecem mapas confiáveis para o planejamento urbano” (Kranjčić *et al.*, 2019, p. 12, tradução nossa). Isso ocorreu porque “o uso de múltiplas bandas espectrais do Sentinel-2 aumenta a eficácia dos algoritmos de Machine Learning na distinção entre solo nu e áreas urbanas consolidadas” (Kranjčić *et al.*, 2019, p. 14, tradução nossa).

Por fim, métricas mais específicas detalharam o comportamento dos modelos em classes distintas. Por exemplo, “a matriz de confusão revelou que o algoritmo RF teve menor erro de omissão para classes de vegetação urbana densa” (Cano, 2022, p. 50). Em paralelo, no campo do

aprendizado profundo, os “modelos de *Deep Learning* alcançaram uma Interseção sobre União (IoU) superior a 0,80 para a classe 'árvores' em ambientes urbanos complexos” (Huerta *et al.*, 2021, p. 10, tradução nossa), consolidando a precisão dessas ferramentas no cenário acadêmico atual.

## CONCLUSÃO

Compreendemos que a transição dos métodos de classificação baseados em pixels para abordagens de *Machine Learning* e *Deep Learning* representou um avanço disruptivo na ciência da geoinformação aplicada ao ambiente urbano. Este estudo sintetizou como algoritmos como *Random Forest* e SVM se consolidaram como padrões de eficácia para mapeamentos temáticos rápidos e robustos, enquanto as Redes Neurais Convolucionais, especialmente a arquitetura U-Net, redefiniram os patamares de precisão na segmentação semântica de objetos complexos. Desse modo, a pesquisa atingiu seu objetivo ao demonstrar que a escolha do método deve ser criteriosamente alinhada à heterogeneidade dos alvos urbanos e à resolução dos dados de entrada.

As evidências apresentadas reiteraram que a eficácia desses algoritmos é intrinsecamente dependente da integração multissensorial. A fusão de dados ópticos de alta resolução com tecnologias como SAR e LiDAR provou ser a estratégia mais eficiente para superar a similaridade espectral e capturar tanto a estrutura vertical quanto a dinâmica temporal das cidades. Ficou demonstrado que, embora o *Deep Learning* ofereça acurácia superior para detalhes finos como o dossel arbóreo, os métodos tradicionais de ML permanecem relevantes devido ao seu baixo custo computacional e eficiência operacional em cenários de dados limitados.

Portanto, a relevância deste estudo residiu na validação de ferramentas capazes de converter fluxos de dados de satélite em informações rigorosas para o suporte ao planejamento urbano e à resiliência ambiental. Nesse cenário, a evolução da classificação urbana apontou para a integração sistêmica e a senciência coletiva, em que os avanços nos algoritmos de aprendizado deixam de ser métricas isoladas de desempenho e passam a atuar como mecanismos viabilizadores de estratégias governamentais focadas na preservação ecológica e no bem-estar social.

## REFERÊNCIAS

- BARBOSA, Felipe Lima Ramos. **Potencialidades e limitações das novas tecnologias de sensoriamento remoto aplicado no ambiente urbano do Distrito Federal**. 2021. 69 f. Tese (Doutorado em Gestão Ambiental e Territorial) – Departamento de Geografia, Universidade de Brasília, Brasília, 2021.
- BLASCHKE, Thomas; HAY, Geoffrey J.; WENG, Qihao; RESCH, Bernd. Collective Sensing: Integrating Geospatial Technologies to Understand Urban Systems — An Overview. **Remote Sensing**, v. 3, n. 8, p. 1743-1776, 2011.
- CANO, P. L. G. **Mapping of permeable areas using machine learning techniques and remote sensing data**. 2022. 66 f. Dissertação (Mestrado em Recursos Naturais) – Universidade Federal de Mato Grosso do Sul, Campo Grande, 2022.
- HUERTA, E.; FIGUEROA, R.; MIRAZA, M.; CALZADA, A. Mapping Urban Green Spaces at the Metropolitan Level Using Very High Resolution Satellite Imagery and Deep Learning Techniques for Semantic Segmentation. **Remote Sensing**, v. 13, n. 11, p. 2031, 2021.
- KRANJČIĆ, Nikola; MEDAK, Damir; ŽUPAN, Robert; REZO, Milan. Machine Learning Methods for Classification of the Green Infrastructure in City Areas. **ISPRS International Journal of Geo-Information**, v. 8, n. 10, p. 463, 2019.