EVENTO ON-LINE
ConBRepro
XVI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
02 a 04 de dezembro de 2026
Inovação e Transformação Digital como Estratégia Competitiva nas Engenharias

Evolução Científica da Detecção de Árvores Urbanas Utilizando Machine Learning e Deep Learning: Uma Análise Bibliométrica

Vinícius Cauan de Oliveira
Programa de Pós-Graduação em Engenharia de Produção - Universidade Estadual de Maringá
Luis Miguel Trigos Sanches
Programa de Pós-Graduação em Engenharia de Produção - Universidade Estadual de Maringá
Gislaine Camila Lapasine Leal
Programa de Pós-Graduação em Engenharia de Produção - Universidade Estadual de Maringá
Rafael Henrique Palma Lima
Engenharia de Produção - Universidade Tecnológica Federal do Paraná

Resumo: Este artigo apresenta uma análise bibliométrica exploratória da literatura científica sobre detecção de árvores em áreas urbanas por meio de técnicas de aprendizado de máquina. Foram analisados 38 artigos indexados nas bases *Scopus* e *Web of Science*, publicados entre 2014 e fevereiro de 2026, selecionados por meio de critérios de escopo relativos a idioma, tipo de documento e aderência temática à estratégia de busca. A análise contemplou a evolução temporal das publicações, a distribuição geográfica dos estudos de caso, a coocorrência de palavras-chave e a transição entre abordagens tradicionais de *Machine Learning* (ML) e *Deep Learning* (DL). Os resultados mostram que o campo é recente e acelerou a partir de 2021, com a China respondendo pelo maior número de aplicações. Metodologicamente, o DL passou a predominar a partir de 2022, mas métodos híbridos (ML+DL) surgem como alternativa para equilibrar precisão e interpretabilidade. A produção brasileira ainda é recente, porém com "estudos que empregam benchmarking extensivo e transferência de modelos. Dado o tamanho delimitado do corpus, os resultados são interpretados como um panorama exploratório do campo, e não como generalização estatística robusta. O trabalho identifica lacunas geográficas e temáticas, além de apontar direções para futuras pesquisas, especialmente no desenvolvimento de soluções operacionais para gestão ambiental urbana.

Palavras-chave: Cientometria, Inventário Florestal, Redes Neurais Convolucionais, Sensoriamento Remoto, Visão Computacional.

Scientific Advances in the Detection of Urban Trees Using Machine Learning and Deep Learning: A Bibliometric Analysis

Abstract: This article presents an exploratory bibliometric analysis of the scientific literature on tree detection in urban areas using machine learning techniques. We analyzed 38 articles indexed in the Scopus and Web of Science databases, published between 2014 and February 2026, selected based on scope criteria related to language, document type, and thematic alignment with the search strategy. The analysis examined the temporal evolution of publications, the geographic distribution of case studies, the co-occurrence of keywords, and the transition from traditional machine learning (ML) to deep learning (DL) approaches. The results show that the field is recent and has accelerated since 2021, with China accounting for the largest number of applications. Methodologically, DL began to predominate starting in 2022, but hybrid methods (ML+DL) are emerging as an alternative to balance accuracy and interpretability. Brazilian research in this area is still in its early stages,

though the studies are methodologically robust. Given the limited size of the corpus, the results are interpreted as an exploratory overview of the field rather than a robust statistical generalization. The study identifies geographical and thematic gaps and points to directions for future research, particularly in the development of operational solutions for urban environmental management.

Keywords: Scientometrics, Forest Inventory, Convolutional Neural Networks, Remote Sensing, Computer Vision.

1. Introdução

A arborização urbana contribui diretamente para a resiliência das cidades ao oferecer benefícios como sombra, melhoria da qualidade do ar e alívio do calor urbano. No entanto, as cidades enfrentam barreiras estruturais que dificultam a ampliação e a gestão sustentável dos espaços verdes, incluindo planejamento inadequado, governança fragmentada e escassez de recursos financeiros e humanos (PINTO, 2025). A efetivação desses benefícios depende diretamente da existência de inventários arbóreos atualizados e do conhecimento detalhado sobre a localização e distribuição da vegetação no espaço (HE *et al*., 2025; ROSSI *et al*., 2022). Contudo, inventários limitados apenas às áreas públicas não representam adequadamente toda a arborização urbana, comprometendo o planejamento e a avaliação dos benefícios ambientais.

Nos últimos anos, os avanços em inteligência artificial e *machine learning* têm se consolidado como ferramentas essenciais para a detecção automatizada de árvores urbanas. A aplicação de visão computacional ao inventário urbano tem se mostrado uma alternativa eficiente aos levantamentos manuais tradicionais, permitindo extrair automaticamente localização, espécie e atributos estruturais a partir de imagens combinadas com redes neurais profundas (HAN *et al*., 2022; LIU *et al*., 2023).

A literatura científica que combina sensoriamento remoto, *machine learning* e vegetação tem apresentado crescimento acelerado na última década. Estudos bibliométricos indicam uma fase inicial de publicações esparsas até meados da década passada, seguida por uma aceleração significativa a partir de 2018, com aumento expressivo do número de artigos nos anos seguintes (MATYUKIRA; MHANGARA, 2024).

Quando o foco se direciona especificamente ao *Deep Learning*, a expansão é ainda mais notável. Os primeiros trabalhos aplicando *Deep Learning* ao sensoriamento remoto surgiram em meados da década de 2010, e em menos de uma década o campo experimentou um crescimento exponencial, consolidando-se como uma das abordagens mais promissoras (BASTOS *et al*., 2025). No recorte mais restrito de áreas verdes intraurbanas, os primeiros estudos aparecem a partir de 2016, com um crescimento gradual até 2018 e uma clara aceleração nos anos seguintes, refletindo o crescente interesse na aplicação dessas técnicas ao ambiente das cidades.

Apesar do crescimento acelerado das publicações envolvendo *machine learning*, *deep learning* e sensoriamento remoto, observa-se que a literatura carece de uma sistematização específica voltada à detecção de árvores urbanas. Os estudos bibliométricos existentes tratam o tema de forma ampla (mapeamento de vegetação em geral) ou concentram-se apenas em *deep learning*, sem distinguir a evolução das diferentes abordagens de aprendizado de máquina ao longo do tempo. Essa análise permitirá não apenas compreender a evolução temporal e geográfica da produção, mas também identificar lacunas de pesquisa e direcionar esforços futuros, especialmente em países emergentes como o Brasil.

Embora a bibliometria seja tradicionalmente aplicada a corpora extensos, tanto Donthu *et al*. (2021) quanto Zupic e Čater (2015) defendem sua validade em subcampos específicos e delimitados, desde que os resultados sejam interpretados como panorama exploratório e não como generalização estatística robusta.

O presente estudo tem como objetivo realizar uma análise bibliométrica exploratória da literatura científica sobre detecção de árvores urbanas utilizando *Machine Learning* (ML) e *Deep Learning* (DL), mapeando sua evolução temporal, geográfica e temática, com destaque para a transição metodológica de ML para DL e para a produção científica brasileira na área.

Espera-se que os resultados contribuam para uma visão sistêmica do campo, auxiliem pesquisadores na escolha de métodos e orientem políticas de fomento à pesquisa em países com produção ainda emergente.

2. Método de pesquisa

A presente análise bibliométrica foi conduzida com base em critérios de busca, refinamento e extração de dados transparentes e reprodutíveis. A busca pelos estudos foi realizada em fevereiro de 2026, nas bases de dados *Scopus* e *Web of Science.*

O objetivo da busca foi identificar estudos que relacionassem três grandes eixos temáticos: i) o objeto de estudo (árvores em áreas urbanas); ii) as fontes de dados (imagens de sensoriamento remoto); e iii) as técnicas analíticas (aprendizado de máquina e visão computacional).

Para isso, foi elaborada uma estratégia de busca baseada na combinação de palavras-chave aplicadas nos campos título, resumo e palavras-chave dos artigos científicos, conforme apresentado a seguir:

("urban") AND ("tree" OR "canopy" OR "crown") AND ("inventory" OR "detection")

A busca foi realizada sem restrição temporal, com o objetivo de capturar a evolução histórica das metodologias aplicadas à detecção de árvores urbanas, permitindo analisar o desenvolvimento das abordagens baseadas em sensoriamento remoto e aprendizado de máquina ao longo do tempo.

2.1 Critérios de elegibilidade

Foram considerados apenas artigos de periódico com revisão por pares, publicados em língua inglesa. Os filtros de escopo incluíram: tipo de documento (excluindo-se anais de conferência, capítulos de livro, teses, dissertações e revisões bibliográficas), idioma (inglês) e aderência temática ao objeto de estudo, delimitada pela combinação de palavras-chave da estratégia de busca (árvores urbanas, sensoriamento remoto e aprendizado de máquina). Registros sobre temas correlatos, porém fora do escopo — como florestas naturais, plantações homogêneas, áreas rurais ou cobertura vegetal genérica sem individualização de árvores — foram excluídos por não se enquadrarem nos descritores temáticos.

2.2 Processo de seleção

Após a realização das buscas nas bases de dados, todos os registros identificados foram consolidados em um gerenciador de referências, onde as duplicatas foram identificadas e removidas automaticamente. Em seguida, o corpus foi refinado por meio da aplicação dos critérios de escopo predefinidos, relativos ao idioma, ao tipo de documento e à aderência ao objeto de estudo (árvores urbanas detectadas via sensoriamento remoto e aprendizado de máquina).

Na etapa seguinte, os registros remanescentes foram analisados integralmente, com o objetivo de confirmar sua aderência aos critérios de escopo estabelecidos. O processo de refinamento do corpus é sintetizado na Figura 1.

Figura 1 – Fluxograma ilustrando o processo de refinamento do corpus

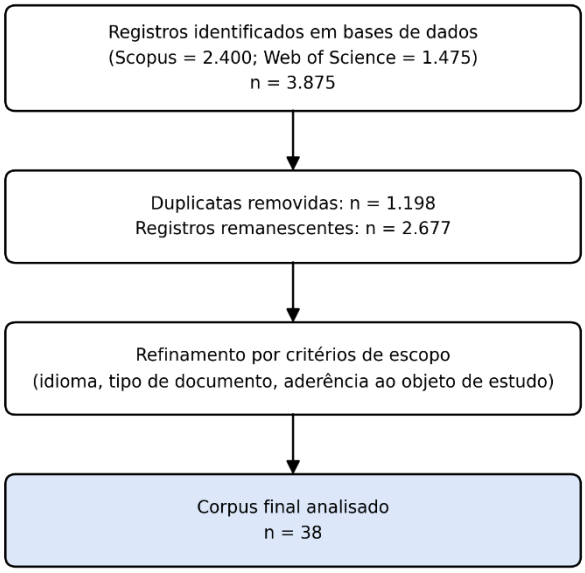

Fonte: AUTORES (2026)

2.3 Extração de dados

Após a seleção final, foram extraídos de cada artigo: ano de publicação, país de realização, palavras-chave e tipo de abordagem computacional (*Machine Learning*, *Deep Learning* ou hibrida). A classificação considerou como Machine Learning algoritmos tradicionais (*Random Forest, Support Vector Machine, k-Nearest Neighbors*) e técnicas de classificação orientada a objetos (OBIA) e como *Deep Learning* métodos baseados em redes neurais profundas (*Convolutional Neural Networks*). Estudos que combinam as duas abordagens — por exemplo, extração de características por DL e classificação por ML tradicional — foram classificados como híbridos.

Para a análise apresentada na Seção 3.4.4, foi extraído também o número de técnicas de ML/DL comparadas em cada estudo, definido como a quantidade de modelos ou arquiteturas distintas testadas: variantes de uma mesma arquitetura-base (por exemplo, diferentes tamanhos do YOLOv5) foram contabilizadas como uma única técnica, e nos casos em que o próprio estudo declarava explicitamente o total de métodos comparados — como em Zamboni *et al.* (2021), que testa 21 métodos — esse valor foi adotado.

3. Resultados e discussão

3.1 Distribuição temporal

A análise da distribuição temporal dos artigos selecionados (Figura 2) revela que as primeiras publicações incluídas nesta revisão começam em 2014, com apenas um estudo identificado neste ano. Nos anos seguintes, observa-se um número reduzido de publicações, sem trabalhos identificados em 2015, 2016 e 2019, indicando que o uso de técnicas automatizadas para detecção de árvores em áreas urbanas ainda era incipiente na primeira metade da década passada. A partir de 2020, verifica-se um crescimento gradual, contudo, é a partir de 2021 que o volume de publicações apresenta um aumento expressivo, com 3 artigos em 2021, 9 em 2022, 6 em 2023, 4 em 2024 e um pico de 9 artigos em 2025.

Esse aumento reflete a consolidação do *deep learning* como ferramenta central, a popularização de drones de baixo custo e a maior disponibilidade de imagens de satélite de alta resolução. A redução para 1 artigo em 2026 deve-se ao fato de a busca ter sido realizada em fevereiro deste ano, capturando apenas os trabalhos publicados nos primeiros

meses. No conjunto, a evolução temporal evidencia que o campo está em expansão, com mais de 80% dos artigos publicados nos últimos seis anos (2021–2026).

Figura 2 – Distribuição dos artigos por ano de publicação

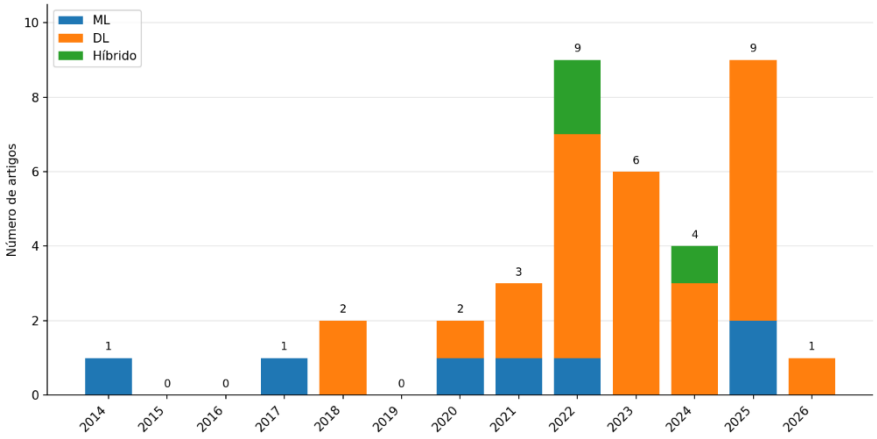

Fonte: AUTORES (2026)

3.2 Distribuição geográfica

Em relação à distribuição geográfica (Figura 3), os estudos abrangem 14 países, demonstrando que há um interesse global no uso de sensoriamento remoto e inteligência artificial para a detecção de árvores em áreas urbanas. A Figura 3 apresenta a frequência de ocorrência dos locais de estudo, sendo importante destacar que alguns artigos foram realizados em mais de um país. Dessa forma, a contagem apresentada reflete o número de vezes em que cada país foi citado entre os estudos analisados. Entre os países identificados, a China apresenta o maior número de ocorrências (10), seguida pelos Estados Unidos (6) e pela Coreia do Sul (5). Brasil e Canadá aparecem com 3 ocorrências cada, enquanto Nova Zelândia, Austrália, Irã, Alemanha e Espanha contribuem com 2 ocorrências cada. Itália, Polônia, Suíça e Países Baixos aparecem com 1 ocorrência cada.

A liderança da China pode estar associada aos elevados investimentos do país em iniciativas voltadas a cidades inteligentes e monitoramento ambiental. Além disso, a presença de países com diferentes condições climáticas e urbanas, como Brasil, Irã e Canadá, mostra que essas metodologias vêm sendo aplicadas em contextos bastante variados. Isso inclui desde cidades com clima tropical e vegetação mais densa até regiões com clima mais seco ou frio, onde a arborização pode ser mais esparsa e exigir estratégias específicas de manejo. De forma geral, a diversidade de países representados indica que essas metodologias vêm sendo testadas em diferentes tipos de cidades, desde grandes centros urbanos até cidades de médio porte com distintos padrões de arborização.

3.3 Análise de palavras-chave

A análise de coocorrência das palavras-chave foi realizada com auxílio do software *VOSviewer*, com o objetivo de identificar os principais temas e relações conceituais presentes na literatura analisada. Para a construção da rede, foram consideradas apenas as palavras-chave com frequência mínima de cinco ocorrências entre os artigos selecionados. A Figura 4 apresenta a rede de coocorrência obtida.

Na rede de coocorrência, o tamanho dos nós indica a frequência dos termos, e as conexões mostram coocorrência. O termo “*deep learning*” ocupa posição central, conectando-se a quase todos os demais (exceto “*imagery*”), confirmando seu papel como eixo metodológico na área. “*Classification*” também se destaca, com forte conexão a todos os grupos, demonstrando que a classificação permanece tarefa fundamental, presente tanto em ML quanto em DL.

Figura 3 – Distribuição dos estudos por país de detecção das árvores

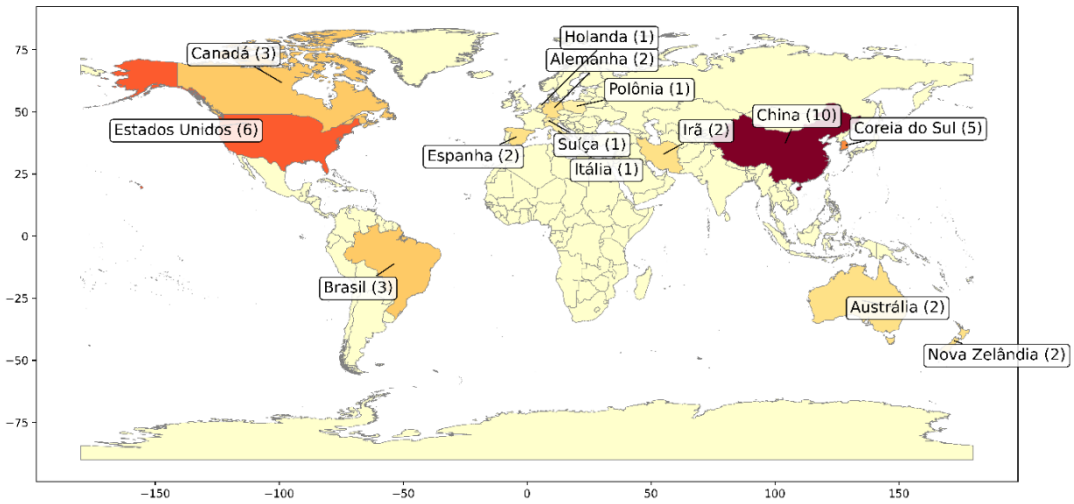

Fonte: AUTORES (2026)

Observa-se ainda a recorrência de variações relacionadas ao LiDAR ("*lidar*", "*airborne lidar*", "*lidar data*"), indicando sua relevância e diversidade de aplicações no contexto urbano. A rede evidencia forte integração entre DL, classificação, segmentação, sensoriamento remoto e dados LiDAR, sugerindo que estudos recentes combinam múltiplas fontes de dados para maior precisão.

Por fim, a presença simultânea de "*classification*", "*segmentation*" e "*object detection*" reflete a evolução das tarefas computacionais: estudos iniciais focaram na classificação de cobertura vegetal, enquanto os mais recentes priorizam detecção individual e segmentação de copas, acompanhando a transição de ML para DL discutida anteriormente.

Figura 4 – Rede de coocorrência das palavras-chave dos estudos analisados

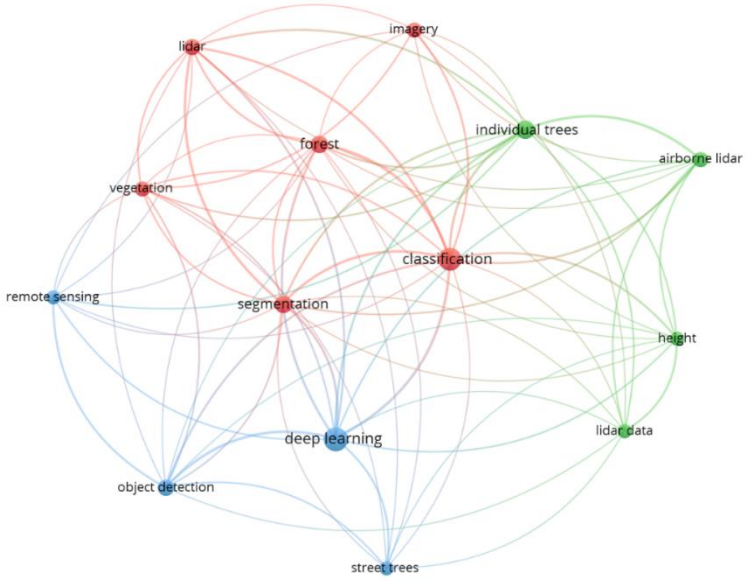

Fonte: AUTORES (2026)

3.4 Evolução temática: machine learning vs deep learning

Para compreender a transformação metodológica na área, os 38 artigos foram classificados em três categorias: *Machine Learning*, *Deep Learning* e abordagens híbridas (que combinam técnicas de ML e DL). A Figura 2 (Seção 3.1) apresenta a distribuição anual dessas categorias ao longo do período analisado.

3.4.1 Fase inicial – Predominância de machine learning (2014–2017)

Essa fase caracteriza o estágio inicial da área, no qual métodos tradicionais eram suficientes para conjuntos de dados menores e imagens com menor complexidade espacial. Nos primeiros anos do período analisado (2014–2017), a detecção de árvores urbanas era realizada quase exclusivamente com algoritmos clássicos de *Machine Learning*, como *Random Forest*, *Support Vector Machine* (SVM) e análise discriminante canônica (CDA). O número de publicações era baixo, no máximo um artigo por ano e nenhum estudo utilizou *Deep Learning* antes de 2018. O trabalho de Alonzo *et al*., (2014) exemplifica essa fase, ao empregar CDA e LDA para mapeamento de espécies arbóreas a partir de dados hiperespectrais e LiDAR.

3.4.2 Fase de transição – Surgimento do deep learning (2018–2021)

O primeiro artigo baseado em *Deep Learning* aparece em 2018 (BRANSON *et al*., 2018, utilizando *Faster R-CNN*). Entre 2018 e 2021, as duas abordagens coexistem e competem. Em 2021, o DL já responde por dois dos três artigos do ano, sinalizando o início da virada, ainda que o ML permaneça presente. Essa fase é marcada pela adoção inicial de redes neurais convolucionais (CNNs) para detecção de copas em imagens de rua e aéreas, mas sem ainda dominar a literatura.

3.4.3 Fase recente – Domínio do *deep learning* (2022–2026)

A partir de 2022, observa-se clara dominância do *Deep Learning*. Em 2022, seis dos nove artigos utilizaram DL (67%); em 2023, todos os seis artigos foram exclusivamente DL; em 2025, sete DL contra dois ML puros. As arquiteturas típicas incluem *YOLO, Mask R-CNN, U-Net* e *transformers*. Essa consolidação deve-se à maior capacidade de extração de características e ao aumento de dados rotulados e recursos computacionais.

Os métodos híbridos (3 artigos no total, a partir de 2022) são minoritários, mas estrategicamente importantes. Eles combinam, por exemplo, a extração automática de características via DL com a classificação por ML tradicional (*Random Forest*). Essa abordagem oferece maior interpretabilidade e eficiência em cenários com dados limitados ou exigência de explicabilidade, aspectos ainda desafiadores para o DL puro.

Essa evolução de ML clássico para DL dominante, com um papel complementar e crescente dos métodos híbridos, está alinhada com a tendência geral das ciências ambientais e da visão computacional, demonstrando a rápida adoção de técnicas avançadas na área de detecção de árvores urbanas.

3.4.4 Aprofundamento metodológico ao longo das fases

Para investigar se a maturidade metodológica do campo acompanha a transição de *Machine Learning* para *Deep Learning*, os 38 estudos foram novamente segmentados nas mesmas três fases utilizadas na seção anterior, desta vez cruzando dados de plataforma, sensor, algoritmo e número de técnicas de ML/DL comparadas, extraídos individualmente de cada estudo. A Tabela 1 sintetiza a composição de abordagens, o uso de múltiplos sensores e o algoritmo predominante em cada fase (o número de técnicas comparadas é analisado no texto que a segue), e a relação completa dos estudos incluídos em cada fase é indicada na nota abaixo da tabela.

Tabela 1 – Evolução do perfil metodológico por fase

Fase	Nº estudos	ML / DL / Híbrido (%)	% que combina >1 sensor	Algoritmo/abordagem mais frequente
Fase 1 (2014–2017)	2	100 / 0 / 0	100%	ML clássico (ex.: CDA, LDA)
Fase 2 (2018–2021)	7	43 / 57 / 0	43%	Detecção via CNNs iniciais (Faster R-CNN)
Fase 3 (2022–2026)	29	10 / 79 / 10	38%	YOLO (31%)

Fonte: Elaborado pelos autores (2026)

Nota: estudos por fase, entre os 38 do corpus (referências completas nas Referências). **Fase 1 (2014–2017):** ALONZO et al., 2014; LIU et al., 2017. **Fase 2 (2018–2021):** BRANSON et al., 2018; LAUMER et al., 2020; LUMNITZ et al., 2021; MAN et al., 2020; MATASCI et al., 2018; WALLACE et al., 2021; ZAMBONI et al., 2021. **Fase 3 (2022–2026):** ALEGBELEYE et al., 2026; AMATI et al., 2023; CAPECCHI et al., 2023; CHOI et al., 2022; DONG et al., 2025; HAN et al., 2022; JIANG et al., 2023; KIM et al., 2025; KWON et al., 2023; LI; YAN, 2024; LIU et al., 2023; MESQUITA et al., 2022; MORADI et al., 2022; NIEDZIELKO et al., 2024; PEDLEY; MORGENROTH, 2025; RICE et al., 2025; RODRÍGUEZ-PUERTA et al., 2022; SCHINDLER et al., 2025; SCHMOHL et al., 2022; SCHÜTTE et al., 2025; SHARIFI et al., 2025; SUN et al., 2022; VELASQUEZ-CAMACHO et al., 2023; VENTURA et al., 2024; WANG et al., 2022; WANG et al., 2025; XU et al., 2025; YANG et al., 2024; ZHANG et al., 2022.

Para além da predominância de DL a partir de 2022, observa-se uma tendência de ampliação do escopo comparativo entre os estudos: o número de técnicas de *Machine Learning*/*Deep Learning* testadas e comparadas por estudo apresenta correlação positiva e estatisticamente significativa com o ano de publicação (ρ de Spearman = 0,43; p = 0,007; n = 38) — tendência que se mantém, e se fortalece (ρ = 0,52; p = 0,001), quando excluído o estudo de Zamboni *et al.* (2021), que compara 21 métodos e constitui um valor atípico isolado. Esse padrão é evidente nos cinco estudos de melhor desempenho identificados na revisão complementar (HAN *et al.*, 2022; KWON *et al.*, 2023; LI; YAN, 2024; MORADI *et al.*, 2022; MAN *et al.*, 2020). Curiosamente, a fusão de múltiplos sensores — combinação de RGB, LiDAR e dados hiperespectrais numa mesma aquisição — foi proporcionalmente mais frequente na fase inicial do que na fase de domínio do DL (100% *versus* 38%, embora a fase inicial conte com apenas dois estudos). Trabalhos pioneiros como os de ALONZO, BOOKHAGEN e ROBERTS (2014) e LIU *et al.* (2017) já integravam dados hiperespectrais e LiDAR para compensar a limitação dos classificadores tradicionais, ao passo que arquiteturas de *deep learning* recentes, como as da família YOLO, vêm alcançando desempenho comparável a partir de fontes de dados mais simples (majoritariamente RGB), sugerindo que parte do ganho de eficiência do DL está em reduzir a dependência de múltiplos sensores, e não apenas em aumentar a acurácia bruta.

Cabe ressalvar que a Fase 1 é composta por apenas dois estudos, de modo que os percentuais associados a ela (0% e 100%) têm caráter ilustrativo e não devem ser interpretados como tendência estatisticamente robusta — limitação já assumida no enquadramento exploratório adotado neste trabalho (DONTHU *et al.*, 2021; ZUPIC; ČATER, 2015).

3.5 Produção científica no Brasil

Foram identificados três artigos com foco no Brasil, todos publicados entre 2021 e 2022, indicando que a aplicação de ML e DL na detecção de árvores urbanas no país é recente. Dois estudos foram realizados em Campo Grande (MS) e um em Teresina (PI). Não foram encontrados artigos nas regiões Sul, Sudeste ou Norte, revelando concentração geográfica restrita e lacuna em grandes centros como São Paulo, Rio de Janeiro, Belo Horizonte e Porto Alegre.

Apesar do número reduzido, as pesquisas brasileiras apresentam diversidade temática e sofisticação metodológica. As principais frentes identificadas são:

a) Detecção individual com DL (ZAMBONI *et al*., 2021; ZHANG *et al*., 2022): utilizaram ortoimagens RGB de alta resolução para detectar árvores individuais, enfrentando desafios típicos de cidades tropicais, como sombras de edifícios, sobreposição de copas e heterogeneidade de fundo); ZAMBONI et al. (2021) compararam ainda 21 métodos de DL, incluindo detectores *anchor-based* e *anchor-free*, um tipo de avaliação raro mesmo na literatura internacional, posicionando o Brasil como um ator relevante em avaliação crítica de métodos;
b) Aprendizado por transferência (ZHANG *et al*., 2022): treinou um modelo *Faster R-CNN + Swin Transformer* com dados de Campo Grande e o aplicou em Guangzhou (China), demonstrando a capacidade de generalização de modelos treinados com dados brasileiros;

c) Classificação taxonômica via OBIA (MESQUITA *et al*., 2022): usou Classificação Orientada a Objetos (OBIA), uma técnica de ML geoespacial, para identificar espécies botânicas (manga, nem e fícus) em Teresina, alcançando acurácia de 69,43%, considerada promissora para inventários urbanos em larga escala;

Os três artigos convergem, ainda, ao justificarem suas pesquisas como contribuições à gestão de serviços ecossistêmicos e ao Objetivo de Desenvolvimento Sustentável 11. Observa-se uma preferência por imagens RGB de alta resolução (ortoimagens aéreas, *WorldView-2* ou drone), devido ao baixo custo em comparação com LiDAR ou dados hiperespectrais. Os algoritmos são escolhidos para serem robustos a sombras, oclusões e sobreposição de copas. Coexistem duas vertentes metodológicas: DL para detecção individual de árvores e ML (OBIA) para classificação taxonômica de espécies.

A partir das seções de trabalhos futuros, as principais recomendações incluem: integração multissensor (RGB + LiDAR), expansão do uso de drones, generalização de modelos para múltiplas cidades, validação de campo mais robusta e aplicação em políticas públicas.

4. Conclusão

Esta análise bibliométrica de 38 artigos publicados entre 2014 e 2026 revelou que a detecção automatizada de árvores urbanas com *Machine Learning* e *Deep Learning* é um campo recente e em franca expansão, com mais de 80% das publicações concentradas nos últimos seis anos (2021–2026). Geograficamente, a China lidera com 10 ocorrências, seguida por Estados Unidos e Coreia do Sul, evidenciando a formação de pólos de pesquisa bem definidos.

Metodologicamente, observou-se uma clara transição do ML tradicional para o DL, que domina a literatura a partir de 2022. Os métodos híbridos (3 artigos), embora minoritários, destacam-se por combinarem a capacidade extrativa do DL com a interpretabilidade e eficiência do ML clássico, representando uma fronteira promissora para aplicações operacionais em gestão urbana. O achado mais original deste trabalho, contudo, é ampliação do escopo comparativo ao longo das fases: o número de técnicas de ML/DL comparadas por estudo cresce de forma estatisticamente significativa ao longo do tempo (ρ de Spearman = 0,43; p = 0,007; n = 38), e a fusão de múltiplos sensores mostrou-se mais comum nos estudos pioneiros do que nos mais recentes — ainda que essa observação se baseie em apenas dois estudos da fase inicial — sugerindo que o DL vem alcançando desempenho robusto com fontes de dados mais simples, e não apenas com maior complexidade de aquisição.

No Brasil, a produção científica é ainda recente (apenas 3 artigos, todos entre 2021 e 2022), concentrada nas regiões Centro-Oeste e Nordeste, com lacunas significativas no Sul, Sudeste e Norte. Apesar do número reduzido, os estudos brasileiros apresentam sofisticação metodológica, incluindo *benchmarking* extensivo, aprendizado por transferência e OBIA, e alinham-se aos Objetivos de Desenvolvimento Sustentável (ODS 11).

Como limitação, destaca-se a busca restrita às bases *Scopus* e *Web of Science* e ao idioma inglês, o que pode ter excluído literatura relevante. Conclui-se que o DL se consolidou como abordagem dominante, enquanto os métodos híbridos ganham espaço como alternativa estratégica. No Brasil, há grande potencial para expansão das pesquisas em centros urbanos ainda não explorados (como São Paulo, Rio de Janeiro e Porto Alegre) e para o desenvolvimento de ferramentas operacionais voltadas à gestão ambiental municipal.

Referências

ALEGBELEYE, O. M., MEDDENS, A. J. H., ROTIMI, Y. O., et al. Urban tree crown detection based on deep learning and high-resolution aerial imagery: PTCNet for Pullman, WA, USA, **Remote**

Sensing Applications: Society and Environment, v. 41, 101818, 2026. DOI: 10.1016/j.rsase.2025.101818.

ALONZO, M., BOOKHAGEN, B., ROBERTS, D. A. Urban tree species mapping using hyperspectral and lidar data fusion, **Remote Sensing of Environment**, v. 148, p. 70–83, 25 maio 2014. DOI: 10.1016/j.rse.2014.03.018.

AMATI, M., TIEDE, J., SUN, Q., et al. Using machine learning to identify urban forest crown bounding boxes (CBB): exploring a new method to develop urban forest policy, **Urban Forestry & Urban Greening**, v. 85, 127943, 2023. DOI: 10.1016/j.ufug.2023.127943.

BASTOS, Rita Maria Cupertino et al. Deep learning e o sensoriamento remoto de áreas verdes urbanas: uma análise da evolução e aplicações. In: **ENCONTRO NACIONAL DE PÓS-GRADUAÇÃO E PESQUISA EM GEOGRAFIA**, 16., 2025, Campina Grande. **Anais [...]**. Campina Grande: Realize Editora, 2025. Disponível em: https://editorarealize.com.br/artigo/visualizar/124621. Acesso em: 31 mai. 2026.

BRANSON, S., WEGNER, J. D., HALL, D., *et al.* From Google Maps to a fine-grained catalog of street trees, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 135, p. 13–30, 1 jan. 2018. DOI: 10.1016/j.isprsjprs.2017.11.008.

CAPECCHI, I., BORGHINI, T., BERNETTI, I. Automated urban tree survey using remote sensing data, Google Street View images, and plant species recognition apps, **European Journal of Remote Sensing**, v. 56, 2162441, 2023. DOI: 10.1080/22797254.2022.2162441.

CHOI, K., LIM, W., CHANG, B., et al. An automatic approach for tree species detection and profile estimation of urban street trees using deep learning and Google Street View images, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 190, p. 165-180, 2022. DOI: 10.1016/j.isprsjprs.2022.06.004.

DONG, Z., SU, Y., ZHANG, Y., et al. Locating and profiling city street trees using Baidu Street View images for carbon storage evaluation, **Ecological Informatics**, v. 91, 103394, 2025. DOI: 10.1016/j.ecoinf.2025.103394.

DONTHU, N., KUMAR, S., MUKHERJEE, D., *et al.* How to Conduct a Bibliometric Analysis: An Overview and Guidelines, **Journal of Business Research**, v. 133, p. 285–296, 2021. DOI: 10.1016/j.jbusres.2021.04.070.

HAN, W., CAO, L., XU, S. A Method of the Coverage Ratio of Street Trees Based on Deep Learning, **International Journal of Interactive Multimedia and Artificial Intelligence**, v. 7, n. 5, p. 23–29, 2022. DOI: 10.9781/ijimai.2022.07.003.

HE, B., ZHANG, H., XU, H., *et al.* CTS-Net: a deep learning network for urban individual tree crown segmentation using high-resolution satellite images. 5 set. 2025. **Anais** [...] [S.l.], SPIE-Intl Soc Optical Eng, 5 set. 2025. p. 52. DOI: 10.1117/12.3067868.

JIANG, T., WANG, Y., LIU, S., et al. Instance recognition of street trees from urban point clouds using a three-stage neural network, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 199, p. 305-334, 2023. DOI: 10.1016/j.isprsjprs.2023.04.010.

KIM, D., SONG, Y., KIM, H., et al. Airborne multi-seasonal LiDAR and hyperspectral data integration for individual tree-level classification in urban green spaces at city scale, **International Journal of Applied Earth Observation and Geoinformation**, v. 136, 104319, 2025. DOI: 10.1016/j.jag.2024.104319.

KWON, R., RYU, Y., YANG, T., et al. Merging multiple sensing platforms and deep learning empowers individual tree mapping and species detection at the city scale, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 206, p. 201-221, 2023. DOI: 10.1016/j.isprsjprs.2023.11.011.

LAUMER, D., LANG, N., VAN DOORN, N., et al. Geocoding of trees from street addresses and street-level images, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 162, p. 125-136, 2020. DOI: 10.1016/j.isprsjprs.2020.02.001.

LI, Q., YAN, Y. Street tree segmentation from mobile laser scanning data using deep learning-based image instance segmentation, **Urban Forestry & Urban Greening**, v. 92, 128200, 2024. DOI: 10.1016/j.ufug.2023.128200.

LIU, D., JIANG, Y., WANG, R., *et al.* Establishing a citywide street tree inventory with street view images and computer vision techniques, **Computers, Environment and Urban Systems**, v. 100, 1 mar. 2023. DOI: 10.1016/j.compenvurbsys.2022.101924.

LIU, L., COOPS, N. C., AVEN, N. W., et al. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data, **Remote Sensing of Environment**, v. 200, p. 170-182, 2017. DOI: 10.1016/j.rse.2017.08.010.

LUMNITZ, S., DEVISSCHER, T., MAYAUD, J. R., et al. Mapping trees along urban street networks with deep learning and street-level imagery, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 175, p. 144-157, 2021. DOI: 10.1016/j.isprsjprs.2021.01.016.

MAN, Q., DONG, P., YANG, X., et al. Automatic extraction of grasses and individual trees in urban areas based on airborne hyperspectral and LiDAR data, **Remote Sensing**, v. 12, 2725, 2020. DOI: 10.3390/rs12172725.

MATASCI, G., COOPS, N. C., WILLIAMS, D. A. R., et al. Mapping tree canopies in urban environments using airborne laser scanning (ALS): a Vancouver case study, **Forest Ecosystems**, v. 5, 14, 2018. DOI: 10.1186/s40663-018-0146-y.

MATYUKIRA, C., MHANGARA, P. Advances in vegetation mapping through remote sensing and machine learning techniques: a scientometric review. **European Journal of Remote Sensing**. [S.l.], Taylor and Francis Ltd. , 2024.

MESQUITA, M. R., AGARWAL, S., DE MORAIS LIMA, L. H. G., *et al.* The use of geotechnologies for the identification of the urban flora in the city of Teresina, Brazil, **Urban Ecosystems**, v. 25, n. 2, p. 523–534, 1 abr. 2022. DOI: 10.1007/s11252-021-01153-z.

MORADI, F., JAVAN, F. D., SAMADZADEGAN, F. Potential evaluation of visible-thermal UAV image fusion for individual tree detection based on convolutional neural network, **International Journal of Applied Earth Observation and Geoinformation**, v. 113, 103011, 2022. DOI: 10.1016/j.jag.2022.103011.

NIEDZIELKO, J., KOPEĆ, D., WYLAZŁOWSKA, J., et al. Airborne data and machine learning for urban tree species mapping: enhancing the legend design to improve the map applicability for city greenery management, **International Journal of Applied Earth Observation and Geoinformation**, v. 128, 103719, 2024. DOI: 10.1016/j.jag.2024.103719.

PEDLEY, D., MORGENROTH, J. Detecting and measuring fine-scale urban tree canopy loss with deep learning and remote sensing, **ISPRS Open Journal of Photogrammetry and Remote Sensing**, v. 15, 100082, 2025. DOI: 10.1016/j.ophoto.2025.100082.

PINTO, L. V. Barriers to Sustainable Urban Green Space Management: A Review of Limitations and Integrative Proposals, **Earth: Environmental Sustainability**, v. 1, n. 2, p. 244–253, 11 nov. 2025. DOI: 10.53941/eesus.2025.100020.

RICE, J. R., FRICKER, G. A., VENTURA, J. An end-to-end deep learning solution for automated LiDAR tree detection in the urban environment, **ISPRS Open Journal of Photogrammetry and Remote Sensing**, v. 17, 100092, 2025. DOI: 10.1016/j.ophoto.2025.100092.

RODRÍGUEZ-PUERTA, F., BARRERA, C., GARCÍA, B., et al. Mapping tree canopy in urban environments using point clouds from airborne laser scanning and street-level imagery, **Sensors**, v. 22, 3269, 2022. DOI: 10.3390/s22093269.

ROSSI, L., MENCONI, M. E., GROHMANN, D., *et al.* Urban Planning Insights from Tree Inventories and Their Regulating Ecosystem Services Assessment, **Sustainability (Switzerland)**, v. 14, n. 3, 1 fev. 2022. DOI: 10.3390/su14031684.

SCHINDLER, J., SUN, Z., XUE, B., et al. Efficient tree mapping through deep distance transform (DDT) learning, **ISPRS Open Journal of Photogrammetry and Remote Sensing**, v. 17, 100095, 2025. DOI: 10.1016/j.ophoto.2025.100095.

SCHMOHL, S., VALLEJO, A. N., SOERGEL, U. Individual tree detection in urban ALS point clouds with 3D convolutional networks, **Remote Sensing**, v. 14, 1317, 2022. DOI: 10.3390/rs14061317.

SCHÜTTE, O., LUCAS, M., WASKE, B. Individual tree crown delineation in heterogeneous urban environments using high-resolution airborne imagery, **IEEE Journal of Selected Topics in Applied**

Earth Observations and Remote Sensing, v. 18, p. 27923-27936, 2025. DOI: 10.1109/JSTARS.2025.3626942.

SHARIFI, A., SHAH-HOSSEINI, R., SHOKRI, D., et al. Multi-sensor AI-based urban tree crown segmentation from high-resolution satellite imagery for smart environmental monitoring, **Smart Cities**, v. 8, 187, 2025. DOI: 10.3390/smartcities8060187.

SUN, Y., LI, Z., HE, H., et al. Counting trees in a subtropical mega city using the instance segmentation method, **International Journal of Applied Earth Observation and Geoinformation**, v. 106, 102662, 2022. DOI: 10.1016/j.jag.2021.102662.

VELASQUEZ-CAMACHO, L., ETXEGARAI, M., DE-MIGUEL, S. Implementing deep learning algorithms for urban tree detection and geolocation with high-resolution aerial, satellite, and ground-level images, **Computers, Environment and Urban Systems**, v. 105, 102025, 2023. DOI: 10.1016/j.compenvurbsys.2023.102025.

VENTURA, J., PAWLAK, C., HONSBERGER, M., et al. Individual tree detection in large-scale urban environments using high-resolution multispectral imagery, **International Journal of Applied Earth Observation and Geoinformation**, v. 130, 103848, 2024. DOI: 10.1016/j.jag.2024.103848.

WALLACE, L., SUN, Q., HALLY, B., et al. Linking urban tree inventories to remote sensing data for individual tree mapping, **Urban Forestry & Urban Greening**, v. 61, 127106, 2021. DOI: 10.1016/j.ufug.2021.127106.

WANG, A., SHI, S., YANG, J., et al. Potential of hyperspectral LiDAR in individual tree segmentation: a comparative study with multispectral LiDAR, **Urban Forestry & Urban Greening**, v. 104, 128658, 2025. DOI: 10.1016/j.ufug.2024.128658.

WANG, Y., YAN, X., BAO, H., et al. Detecting occluded and dense trees in urban terrestrial views with a high-quality tree detection dataset, **IEEE Transactions on Geoscience and Remote Sensing**, v. 60, 5607914, 2022. DOI: 10.1109/TGRS.2022.3184300.

XU, Y., WANG, T., SKIDMORE, A. K. Fusing aerial photographs and airborne LiDAR data to improve the accuracy of detecting individual trees in urban and peri-urban areas, **Urban Forestry & Urban Greening**, v. 105, 128696, 2025. DOI: 10.1016/j.ufug.2025.128696.

YANG, T., ZHOU, S., XU, A., et al. YOLO-SegNet: a method for individual street tree segmentation based on the improved YOLOv8 and the SegFormer network, **Agriculture**, v. 14, 1620, 2024. DOI: 10.3390/agriculture14091620.

ZAMBONI, P., JUNIOR, J. M., SILVA, J. de A., *et al.* Benchmarking anchor-based and anchor-free state-of-the-art deep learning methods for individual tree detection in rgb high-resolution images, **Remote Sensing**, v. 13, n. 13, 1 jul. 2021. DOI: 10.3390/rs13132482.

ZHANG, L., LIN, H., WANG, F. Individual Tree Detection Based on High-Resolution RGB Images for Urban Forestry Applications, **IEEE Access**, v. 10, p. 46589–46598, 2022. DOI: 10.1109/ACCESS.2022.3171585.

ZUPIC, I., ČATER, T. Bibliometric Methods in Management and Organization, **Organizational Research Methods**, v. 18, n. 3, p. 429–472, 2015. DOI: 10.1177/1094428114562629.