



46  
47 **Palavras-chave:** Geotecnologias; Inteligência Artificial; Áreas verdes; Mapeamento;  
48 Planejamento urbano.  
49

## 50 INTRODUÇÃO

51 O mapeamento e monitoramento da vegetação urbana desempenham um papel crucial  
52 no planejamento de cidades sustentáveis, na gestão ambiental e na formulação de políticas  
53 públicas eficazes. As áreas urbanas estão em constante expansão, e a vegetação urbana,  
54 além de oferecer diversos serviços ecossistêmicos, desempenha um papel vital no  
55 combate aos efeitos das mudanças climáticas, como a redução da temperatura, a  
56 mitigação de poluentes e a promoção da saúde mental e física da população (ENDRENY,  
57 2018; LUMNITZ, 2019). Dessa forma, a capacidade de monitorar e mapear de forma  
58 eficiente a vegetação nas cidades tornou-se uma necessidade urgente. Nesse contexto, o  
59 sensoriamento remoto (SR) emergiu como uma geotecnologia de destaque por oferecer  
60 uma forma eficiente de coletar dados sobre grandes áreas de forma rápida, sistemática e  
61 econômica (DEMATTE et al., 2017).

62 Historicamente, o mapeamento de vegetação urbana foi amplamente realizado  
63 utilizando técnicas tradicionais de sensoriamento remoto, como a classificação  
64 supervisionada de imagens orbitais. Mais recentemente, técnicas baseadas em  
65 aprendizagem de máquina (*Machine Learning* - ML), ganharam destaque nesse contexto.  
66 Os algoritmos de ML são classificados em aprendizagem rasa (*shallow learning*) e  
67 aprendizagem profunda (*Deep Learning* – DL). A aprendizagem rasa é amplamente  
68 utilizada no processamento de dados de sensoriamento remoto para estudo da vegetação  
69 devido à sua eficácia na classificação de pixels individuais, e ao fato de exigirem uma  
70 quantidade relativamente pequena de dados de treinamento (PU et al., 2014).  
71 Diferentemente das técnicas convencionais, que dependem da definição explícita de  
72 regras para a classificação, os algoritmos de ML, a exemplo do *Support Vector Machine*  
73 (SVM), do *Decision Tree* (DT), e do *Random Forest* (RF), aprendem automaticamente  
74 com os dados, identificando padrões complexos sem intervenção humana direta. Esses  
75 métodos mostraram-se particularmente úteis em áreas urbanas com vegetação  
76 homogênea, especialmente quando combinados com índices espectrais, como o Índice de  
77 Vegetação da Diferença Normalizada (NDVI), que permite diferenciar vegetação de  
78 outras coberturas do solo (ZHU et al., 2017).

79 No entanto, devido à alta complexidade das paisagens urbanas e maior  
80 disponibilização de imagens de alta resolução espacial, sobretudo, a partir dos anos 2000,  
81 com o lançamento do satélite IKONOS, essas abordagens de aprendizagem rasa  
82 começaram a apresentar limitações, exigindo métodos ainda mais avançados. As áreas  
83 urbanas são caracterizadas por uma diversidade de tipos de vegetação, espécies e  
84 estruturas, o que dificulta a segmentação de elementos individuais, como as copas das  
85 árvores. Além disso, os métodos de classificação baseados em pixels não consideram as  
86 relações espaciais e contextuais entre os objetos na imagem, o que pode resultar em uma  
87 maior taxa de erros em ambientes urbanos densos e heterogêneos (HUANG et al., 2024).

88 Para superar essas limitações, foram desenvolvidas abordagens avançadas baseadas  
89 em uma subárea de ML que é o *deep learning*, permitindo uma análise mais sofisticada  
90 dos dados de sensoriamento remoto para atender a contextos mais desafiadores. Em  
91 particular, modelos baseados em Redes Neurais Convolucionais (CNNs) têm  
92 revolucionado esse campo ao possibilitar a análise de grandes volumes de dados de alta  
93 resolução espacial, espectral e temporal (CHENG et al., 2020). Essas redes não apenas  
94 aprimoram a precisão da classificação de vegetação, como também conseguem segmentar  
95 elementos individuais, como copas de árvores, considerando as relações espaciais entre  
96 eles (SUDHA & AJI, 2021).

97 A aplicação de algoritmos de ML, incluindo DL, no mapeamento da vegetação urbana  
98 oferece vantagens importantes. Essas abordagens são capazes de lidar com a  
99 complexidade dos ambientes urbanos, proporcionando uma precisão superior ao trabalhar  
100 com imagens de alta resolução (ZHANG et al., 2023). Além disso, algoritmos de DL  
101 podem processar imagens multiespectrais e dados Light Detection and Ranging (LiDAR)  
102 simultaneamente, possibilitando uma análise mais detalhada da vegetação, incluindo  
103 informações tridimensionais, como altura e volume das árvores (CHEN et al., 2019).  
104 Outro benefício do aprendizado profundo é a maior capacidade de generalização dos  
105 modelos, fundamental para cenários urbanos dinâmicos e em constante transformação  
106 (ZHU et al., 2017).

107 Diante desse panorama, torna-se essencial a realização de uma revisão de literatura  
108 que permita compreender a evolução das abordagens aplicadas ao mapeamento da  
109 vegetação urbana. Tal revisão possibilita a categorização da produção técnico-científica  
110 existente, a síntese dos avanços mais recentes e a identificação de lacunas e tendências  
111 futuras na área.

112 Nesse contexto, este estudo tem como objetivo caracterizar o estado da arte dos  
 113 trabalhos disponíveis em bases de dados científicas, com ênfase nas principais técnicas  
 114 empregadas, suas limitações e as perspectivas de pesquisa e inovação relacionadas ao uso  
 115 de dados de sensoriamento remoto combinados a métodos de aprendizagem de máquina,  
 116 sejam eles baseados em algoritmos tradicionais (*shallow learning*) ou redes neurais  
 117 profundas (*deep learning*), no mapeamento da vegetação urbana.

## 118 MÉTODO

119 Realizamos uma busca na base de dados *Web of Science* (WOS), que é uma base que  
 120 indexa uma vasta gama de publicações científicas desde 1900 até à atualidade. O recorte  
 121 temporal adotado nesse estudo é de janeiro de 2007 a junho de 2024. Para tanto, preparou-  
 122 se uma chave de busca avançada visando levantar os trabalhos científicos publicados em  
 123 periódicos sobre o uso de dados de sensoriamento remoto no mapeamento da vegetação  
 124 em ambientes urbanos com abordagens de aprendizagem de máquina rasa e aprendizagem  
 125 profunda. Para fins didáticos, nesse trabalho, utilizaremos o termo ‘ML’ para nos  
 126 referirmos aos algoritmos de aprendizagem rasa, e o termo ‘DL’ para a abordagem de  
 127 aprendizagem profunda.

128 A chave de busca avançada foi constituída por três grupos de critérios. No primeiro  
 129 grupo, constam os termos comumente usados no estudo da vegetação urbana (veja o  
 130 destaque na cor amarelo na Figura 1). No segundo grupo de busca foram utilizados termos  
 131 referentes ao uso de dados de sensoriamento remoto (destaque azul na Figura 1), já no  
 132 terceiro e último grupo foram utilizados termos encontrados em estudos baseados em ML  
 133 e DL (destaque cinza na Figura 1).

134 **Figura 1** – Termos de busca utilizados.

(("Urban Forest" OR "Urban Forestry" OR "Urban Vegetation" OR "Urban Tree" OR "Urban  
 Trees" OR "Urban Greenness" OR "Urban Green Spaces") AND ("Remote Sensing" OR "Orbital  
 Image" OR "Aerial Image" OR "Satellite Image" "LIDAR" OR "Unmanned Aerial Vehicle" OR  
 "UAV" OR "Optical Image" OR "RGB Image" OR "Hyperspectral Image" OR "Multispectral  
 Image") AND ("Machine Learning" OR "Random Forest" OR "Decision Tree" OR "Support  
 Vector Machine" OR "Multilayer Perceptron" OR "K-Nearest Neighbors" OR "Artificial Neural  
 Network" OR "Deep Learning" OR "Deep Neural Network" OR "Convolutional Neural Network"  
 OR "Recurrent Neural Network" OR "Long-Short Term Memory" OR "Generative Adversarial  
 Network" OR "Vision Transformer"))

135

136 **Fonte:** Autores (2025).


137 Foram identificados 161 artigos, dos quais 4 correspondem a revisões de literatura. As  
 138 informações desses trabalhos foram extraídas e organizadas em planilha, contemplando

139 os seguintes campos: autores, título, ano de publicação, objetivo, técnicas de pré-  
 140 processamento aplicadas, tipo de algoritmo utilizado, alvo mapeado (por exemplo,  
 141 vegetação geral ou árvores), plataforma de aquisição, tipo de sensor, país do estudo e  
 142 resolução espacial das imagens. Com base nesse levantamento, foi possível caracterizar  
 143 o estado da arte sobre o tema. Os resultados são apresentados e discutidos na seção a  
 144 seguir.

## 145 RESULTADOS E DISCUSSAO

146 Como avaliação inicial, foi gerada uma nuvem de palavras (Figura 2) a partir dos 161  
 147 artigos analisados, destacando os termos mais recorrentes em estudos sobre o  
 148 mapeamento da vegetação urbana com o uso de sensoriamento remoto e algoritmos de  
 149 *machine learning*. Os termos mais frequentes incluem: *remote sensing*, *deep learning*,  
 150 *random forest*, *support vector machine*, *LiDAR*, *machine learning* e *urban forest*,  
 151 refletindo as principais abordagens e tecnologias adotadas na literatura.

152 **Figura 2** - Nuvem de palavras representando os principais termos abordados na literatura sobre  
 153 mapeamento da vegetação em ambientes urbanos por sensoriamento remoto e abordagens de ML e DL.



154

155


**Fonte:** Autores (2025).

156 Dos 161 artigos analisados, cinco não aplicaram qualquer técnica de aprendizagem de  
 157 máquina. O primeiro estudo a empregar algoritmos de *machine learning* no mapeamento  
 158 de áreas verdes urbanas com dados de sensoriamento remoto foi publicado em 2007  
 159 (Figura 3).

160 A Figura 3 também revela que o uso de algoritmos de *deep learning* teve início em  
 161 2017, enquanto a integração entre ML e DL apareceu pela primeira vez em 2019.

162 Observa-se que os estudos que utilizaram exclusivamente ML (n = 94) são  
 163 aproximadamente o dobro daqueles que utilizaram apenas DL (n = 49). Essa diferença se  
 164 deve, em parte, ao fato de que o uso de DL no sensoriamento remoto ganhou relevância  
 165 somente a partir de 2015, especialmente com a adoção de redes neurais convolucionais  
 166 (CNNs) para a classificação de imagens de alta resolução. Assim, considerando o  
 167 intervalo analisado (2007 a 2024), as abordagens baseadas em aprendizagem profunda  
 168 estão presentes em apenas metade do período, o que ajuda a explicar sua frequência menor  
 169 em relação aos métodos de aprendizagem rasa.

170 **Figura 3** - Evolução temporal das publicações científicas em ML, DL e ML/DL (até 06/2024).



171

172

**Fonte:** Autores (2025).

173 A Figura 3 também evidencia um crescimento progressivo no número de publicações  
 174 ao longo dos anos, com destaque para o aumento expressivo a partir de 2020. Embora o  
 175 gráfico indique uma aparente redução no número de trabalhos em 2024, é importante  
 176 considerar que o recorte temporal se limita até junho daquele ano. Como o total de  
 177 publicações já ultrapassa 50% do volume registrado em 2023, é possível inferir a  
 178 continuidade da tendência de alta na produção científica sobre o tema.

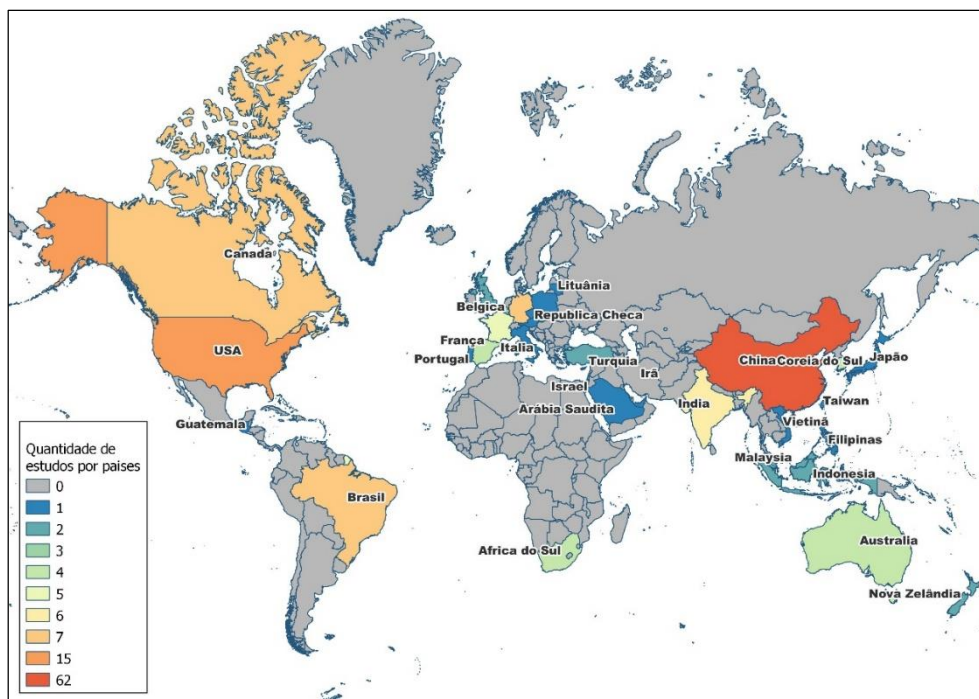
179 Entre os artigos analisados, o trabalho de Feng et al. (2015) apresentou o maior número  
 180 de citações (n = 358). Nesse estudo, os autores propuseram uma abordagem híbrida que  
 181 combina o algoritmo *Random Forest* com análise de texturas, com o objetivo de  
 182 diferenciar áreas de solo exposto e vegetação urbana em cidades chinesas.

183 O aprendizado de máquina é uma área da Inteligência Artificial (IA) que utiliza  
 184 algoritmos para extrair padrões a partir de dados e realizar previsões, sem a necessidade  
 185 de programação explícita para cada situação (GOODFELLOW et al., 2016). A

186 aprendizagem profunda, por sua vez, é uma subárea do aprendizado de máquina,  
 187 caracterizada pelo uso de redes neurais profundas, que possibilitam a modelagem de  
 188 relações complexas e maior capacidade de generalização (KAMILARIS et al., 2018).

189 A Figura 4 indica que a maioria dos estudos analisados foi conduzida na China (n =  
 190 62), seguida pelos Estados Unidos (n = 15), Brasil (n = 7) e Canadá (n = 7). Esses dados  
 191 evidenciam o protagonismo da pesquisa chinesa na área, bem como o crescente interesse  
 192 da comunidade científica internacional no desenvolvimento de técnicas avançadas para o  
 193 mapeamento de áreas verdes urbanas com base em dados de sensoriamento remoto.

194 **Figura 4** - Distribuição geográfica dos artigos científicos publicados de 2007 a junho de 2024 sobre o  
 195 mapeamento da vegetação urbana usando ML e/ou DL e sensoriamento remoto.



196

197

Fonte: Autores (2025).

198

199

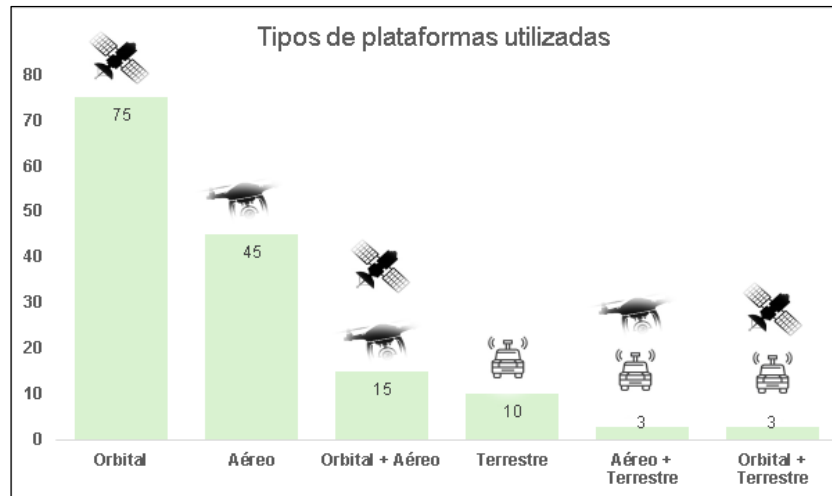
**200 Plataformas de aquisição e algoritmos de aprendizagem de máquina**

201 A análise da relação entre os tipos de plataformas e os tipos de algoritmos de  
202 aprendizado de máquina utilizados no mapeamento da vegetação urbana por  
203 sensoriamento remoto revela tendências interessantes. A Figura 5 demonstra a  
204 predominância no uso de dados orbitais, que aparecem em 75 dos estudos analisados  
205 (total de 161) no período 2007 a junho de 2024. As plataformas aéreas, que incluem  
206 aviões e Veículos Aéreos Não Tripulados (VANTs, popularmente conhecidos como  
207 drones), aparecem como a segunda opção mais utilizada (n=45) nessa tarefa de  
208 mapeamento da vegetação urbana.

209 Embora os sensores embarcados em VANTs geralmente forneçam dados com alta  
210 resolução espacial, essas plataformas apresentam limitações operacionais, como baixa  
211 autonomia de voo, o que demanda maior tempo de campo para cobrir áreas extensas.  
212 Ainda assim, destaca-se o uso de sensores LiDAR acoplados a VANTs, que permitem a  
213 geração de nuvens densas de pontos tridimensionais, viabilizando análises detalhadas da  
214 vegetação, incluindo a extração de variáveis dendrométricas. Parâmetros como o DAP  
215 (Diâmetro à Altura do Peito), altura total, volume e área basal são essenciais para a  
216 caracterização arbórea e podem ser estimados com alta precisão a partir de dados LiDAR  
217 aerotransportado (POPESCU, 2007).

218 Além disso, observa-se um número de estudos que empregam a fusão de diferentes  
219 plataformas, como "Orbital + Aérea" (n = 15), "Aérea + Terrestre" (n = 3) e "Orbital +  
220 Terrestre" (n = 3). Essa combinação de fontes sugere uma tendência crescente na  
221 integração de dados multisensoriais para aprimorar a acurácia e o nível de detalhamento  
222 na análise da vegetação urbana.

223 **Figura 5** - Frequência de uso das plataformas de sensoriamento remoto mapeamento da vegetação urbana  
 224 usando ML e/ou DL e sensoriamento remoto.



225

226

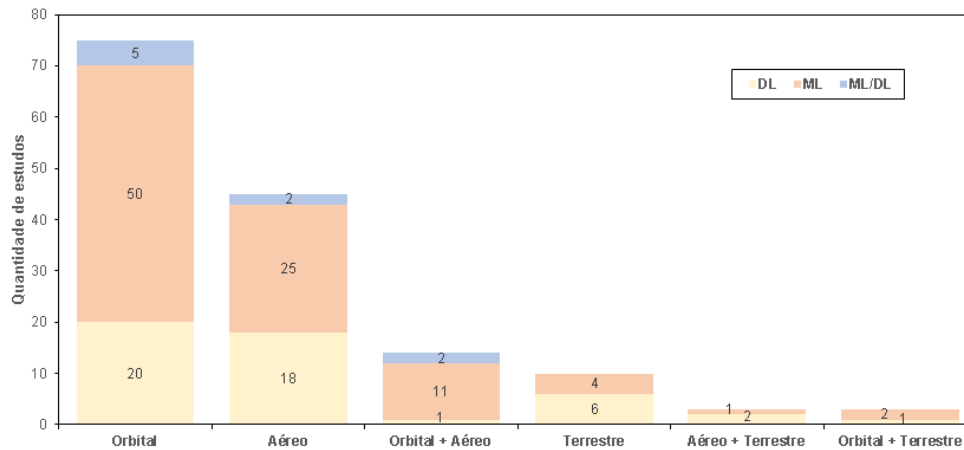
**Fonte:** Autores (2025).

227 A Figura 6 mostra que, entre 2007 e junho de 2024, os algoritmos de *machine learning*  
 228 foram mais frequentemente aplicados a dados orbitais, com 50 ocorrências, enquanto o  
 229 uso de *deep learning* com esse tipo de dado foi identificado em apenas 20 estudos. Em  
 230 contrapartida, observa-se uma crescente adoção de DL na análise de imagens de alta  
 231 resolução espacial e dados LiDAR aerotransportados.

232 Estudos como os de Zhu et al. (2017) e Sudha & Aji (2021) destacam que arquiteturas  
 233 baseadas em redes neurais convolucionais têm se mostrado promissoras na segmentação  
 234 da vegetação urbana, em razão da sua capacidade de extrair automaticamente padrões  
 235 espaciais e espectrais complexos. Isso se reflete nos dados da Figura 6, em que 20 estudos  
 236 aplicaram DL a dados orbitais e outros 18 a dados aerotransportados.

237 O menor número de aplicações de *deep learning*, em comparação aos algoritmos de  
 238 aprendizagem rasa, pode ser atribuído a fatores como o elevado custo computacional e a  
 239 necessidade de grandes volumes de dados rotulados para treinamento (CHENG et al.  
 240 2020). Além disso, como mencionado anteriormente, as aplicações de DL concentram-se  
 241 na segunda metade do período analisado, o que contribui para sua menor  
 242 representatividade em relação aos métodos de ML.

243 **Figura 6** - Relação entre tipo de plataforma de aquisição e técnica de aprendizado de máquina utilizada.



244

245

**Fonte:** Autores (2025).


246 Quando há a combinação de dados orbitais e aerotransportados, os algoritmos de  
 247 *machine learning* (contexto de aprendizagem rasa) continuam sendo a abordagem  
 248 predominante, com 11 das 13 ocorrências identificadas. Essa prevalência pode ser  
 249 atribuída a fatores como o menor custo computacional desses métodos e sua eficácia  
 250 mesmo com conjuntos de dados limitados. Por outro lado, o uso de *deep learning* ainda  
 251 enfrenta barreiras, como a baixa interpretabilidade dos modelos — o que dificulta sua  
 252 adoção em aplicações operacionais — e a escassez de bases de dados rotuladas em  
 253 volume suficiente para o treinamento eficaz das redes profundas (SUDHA & AJI, 2021).

#### 254 **Plataformas de aquisição e tipos de sensores**

255 A análise da relação entre as plataformas utilizadas e os tipos de sensores empregados  
 256 (Figura 7) revela padrões que merecem destaque. As plataformas orbitais são  
 257 majoritariamente associadas a sensores multiespectrais, representando 59 dos estudos  
 258 analisados. Por outro lado, as plataformas aéreas — como aviões e VANTs — apresentam  
 259 maior diversidade de sensores, com destaque para o uso de sensores RGB ( $n = 14$ ) e  
 260 multiespectrais ( $n = 11$ ).

261  
262

**Figura 7** – Relação entre plataformas de aquisição e tipos de sensores utilizados no mapeamento da vegetação urbana usando ML e/ou DL e sensoriamento remoto.



263  
264

Autores (2025).

**Fonte:**

265 Os sensores de radar de abertura sintética (*Synthetic Aperture Radar – SAR*) aparecem  
 266 com menor frequência, sendo utilizados exclusivamente em plataformas orbitais. Isso se  
 267 justifica pela capacidade dessas plataformas de realizar monitoramento contínuo e  
 268 sistemático em escala regional e global. O sensor SAR, por ser ativo, utiliza ondas de  
 269 radar para gerar imagens detalhadas da superfície terrestre, operando independentemente  
 270 das condições de iluminação ou clima — inclusive à noite ou sob cobertura de nuvens,  
 271 chuva e neblina (Jense, 2011).

272 Quanto aos sensores LiDAR, embora seu uso isolado seja relativamente raro (n = 8),  
 273 eles aparecem com frequência em combinação com sensores de imageamento, como  
 274 multiespectrais (n = 17) e RGB (n = 3). Essa combinação evidencia o papel do LiDAR  
 275 na modelagem tridimensional da vegetação, permitindo a extração de informações  
 276 estruturais importantes, como altura e volume das copas.

277 Esses resultados indicam que a escolha da plataforma e do sensor está diretamente  
 278 relacionada à escala e ao nível de detalhe exigido pela aplicação. Sensores multiespectrais  
 279 embarcados em satélites são preferidos para o monitoramento de grandes áreas, enquanto  
 280 sensores RGB e LiDAR, acoplados a VANTs, são mais indicados para estudos locais com  
 281 alta resolução espacial. Além disso, observa-se uma tendência crescente na fusão de


282 dados provenientes de múltiplas plataformas e sensores, com o objetivo de superar  
 283 limitações individuais e aumentar a precisão no mapeamento da vegetação urbana.

#### 284 **Tipos de sensores e algoritmos de aprendizagem de máquina**

285 A análise dos algoritmos de *machine learning* aplicados (Figura 8) revela que o  
 286 *Random Forest* (RF) é a técnica mais utilizada, com 60 ocorrências, seguido pelo Support  
 287 Vector Machine (SVM), com 44 registros. Outros algoritmos, como *Maximum Likelihood*  
 288 *Classification* (MLC), *Artificial Neural Network* (ANN), *K-Nearest Neighbor* (KNN),  
 289 *Decision Tree* (DT), *Support Vector Regression* (SVR), *Multi-Layer Perceptron* (MLP) e  
 290 *Extreme Gradient Boosting* (XGB), apresentam frequência moderada, variando entre 4 e  
 291 8 ocorrências.

292 Algoritmos com baixa frequência ( $n \leq 3$ ) não foram incluídos na Figura 8 para melhor  
 293 clareza na representação gráfica. No entanto, o levantamento identificou um total de 50  
 294 ocorrências envolvendo algoritmos diversos e variações nominais, o que evidencia uma  
 295 diversidade metodológica entre os estudos, embora concentrada em um número reduzido  
 296 de técnicas amplamente consolidadas.

297 **Figura 8** - Algoritmos de ML mais utilizados ( $n \geq 4$ ).



298  
 299


**Fonte:** Autores (2025).

300 A análise da relação entre os tipos de sensores empregados e os algoritmos de  
 301 aprendizado de máquina com mais de quatro ocorrências (Figura 9) revela a  
 302 predominância do uso de sensores multiespectrais nos estudos revisados. Essa preferência  
 303 é especialmente evidente em combinação com os algoritmos RF e SVM, que apresentam  
 304 desempenho robusto mesmo em conjuntos de dados heterogêneos e com classes

305 espectralmente similares. Tais algoritmos também se destacam por demandarem menos  
 306 ajustes paramétricos e oferecerem elevada acurácia em tarefas de classificação (Zhang et  
 307 al., 2020; Khurana et al., 2023).

308 Além do desempenho técnico, a ampla disponibilidade de imagens multiespectrais de  
 309 média e alta resolução, muitas delas de acesso gratuito e com cobertura global, contribui  
 310 para sua adoção em estudos urbanos em larga escala.

311 **Figura 9** - Relação entre algoritmos de ML e tipos de sensores.



312

313


**Fonte:** Autores (2025).

314 A Figura 9 evidencia que os algoritmos RF e SVM foram aplicados a dados  
 315 provenientes de uma maior diversidade de sensores, o que reforça a versatilidade e  
 316 adaptabilidade dessas técnicas em diferentes contextos de sensoriamento remoto. Esses  
 317 algoritmos também predominam nos estudos que utilizam combinações de sensores,  
 318 como *Multiespectral + LiDAR* ou *Hiperspectral + LiDAR*, indicando sua robustez em  
 319 cenários multissensoriais.

320 Em contraste, algoritmos como *Extreme Gradient Boosting (XGB)*, *Multi-Layer*  
 321 *Perceptron (MLP)* e *Support Vector Regression (SVR)* apresentam menor frequência de  
 322 uso e estão associados a um número mais restrito de tipos de sensores, o que pode refletir  
 323 limitações em sua aplicação ou menor consolidação na literatura voltada ao mapeamento  
 324 da vegetação urbana.

325 A análise dos algoritmos de *deep learning* demonstrou a predominância de arquiteturas  
 326 recorrentes em tarefas de segmentação e classificação de imagens, aplicadas a dados de  
 327 sensoriamento remoto voltados ao mapeamento da vegetação urbana. Essa tendência  
 328 pode ser observada na Figura 10, que apresenta os algoritmos de DL mais utilizados ( $n \geq$   
 329 4) nas publicações analisadas.

330 **Figura 10** - Algoritmos de Deep Learning mais utilizados ( $n \geq 4$ ).



331

332 **Fonte:** Autores (2025).

333 As arquiteturas baseadas em *Convolutional Neural Networks* (CNNs), identificadas  
 334 pela presença da sigla "CNN" em seus nomes — como CNN7, 1D-CNN, 3D-CNN, 3D-  
 335 1D-CNN e 3D-2D-CNN — foram observadas em 17 estudos, evidenciando seu papel  
 336 como base estrutural para diversas arquiteturas profundas. Além dessas, outras redes que  
 337 também derivam de CNNs, mas com nomes específicos, como U-Net, YOLO, DeepLab,  
 338 ResNet, FCN e Mask R-CNN, foram amplamente identificadas.

339 A U-Net e suas variantes — U-Net++, ResU-Net e SD-U-Net — foram as mais  
 340 recorrentes ( $n = 19$ ) no mapeamento de vegetação urbana entre 2007 e junho de 2024.  
 341 Essas redes seguem uma arquitetura *encoder-decoder* e destacam-se por sua eficiência  
 342 em tarefas de segmentação semântica, sendo particularmente adequadas para a extração  
 343 de feições vegetais em imagens de alta resolução.

344 Em terceiro lugar, a rede YOLO e suas variantes ( $n = 13$ ) demonstram o crescente  
345 interesse em algoritmos de detecção de objetos em tempo real, especialmente aplicados a  
346 inventários florestais urbanos e contagem de copas arbóreas.

347 A arquitetura DeepLab, incluindo variantes como DeepLabv3+ e DeepLabv2, foi  
348 identificada em 11 estudos. Seu diferencial está no uso de *convoluções dilatadas*, que  
349 permitem segmentar feições mantendo a resolução espacial das imagens. As redes ResNet  
350 e *Fully Convolutional Network* (FCN), cada uma com 8 ocorrências, também foram  
351 empregadas principalmente em tarefas de classificação e segmentação.


352 O algoritmo Mask R-CNN ( $n = 6$ ) representa uma abordagem mais avançada,  
353 combinando detecção de objetos e segmentação de instâncias. Essa técnica tem se  
354 mostrado eficaz para identificar, classificar e delimitar individualmente feições, sendo  
355 especialmente útil em áreas urbanas densamente arborizadas ou edificadas, onde se busca  
356 a identificação de árvores isoladas (He et al., 2017).

357 Adicionalmente, foram identificadas 24 ocorrências de algoritmos com menor  
358 recorrência ou aplicação mais específica, como SegNet, PSPNet, SSL, DCCN, entre  
359 outros. Esses algoritmos não foram incluídos na Figura 10 por motivos de representação  
360 gráfica, mas sua presença indica um campo em constante experimentação e evolução  
361 arquitetural.

362 A Figura 11 apresenta a relação entre algoritmos de *deep learning* e os tipos de  
363 sensores empregados nos estudos analisados. Destaca-se a rede U-Net (e suas variantes),  
364 aplicada majoritariamente a sensores multiespectrais ( $n = 13$ ) e RGB ( $n = 5$ ),  
365 demonstrando sua ampla adoção em segmentação semântica de imagens urbanas (Zhu et  
366 al., 2017; Zhang et al., 2021).

367 As arquiteturas agrupadas na categoria CNN (família) apresentaram a maior  
368 diversidade de aplicação entre os sensores, com ocorrências distribuídas em todas as  
369 categorias identificadas nos estudos — com exceção da categoria "múltiplos", que refere-  
370 se à combinação de mais de dois sensores. Essa diversidade de aplicações reforça a  
371 flexibilidade e adaptabilidade das CNNs em diferentes contextos e tipos de dados no  
372 mapeamento da vegetação urbana.

373

**Figura 11 -** Relação entre algoritmos de DL e tipos de sensores

374

375

**Fonte:** Autores (2025).

376

O uso da rede YOLO (e suas variantes) foi identificado em 13 estudos, sendo aplicada principalmente ao processamento de dados obtidos por sensores RGB ( $n = 6$ ), por combinações de múltiplos sensores (categoria “Múltiplos”,  $n = 6$ ), e, em menor escala, por dados LiDAR ( $n = 1$ ).

380

Já a família DeepLab (incluindo variantes como DeepLabv2 e DeepLabv3+) apresentou 11 ocorrências, com predominância no uso com sensores multiespectrais ( $n = 8$ ). Também foram observadas aplicações em dados RGB ( $n = 2$ ) e em combinação de sensores Multiespectral + LiDAR ( $n = 1$ ).

384

Esses resultados indicam um certo grau de especialização das arquiteturas conforme o tipo de dado de entrada. A família YOLO, por ser voltada à detecção de objetos em tempo real, tem se mostrado mais adequada ao uso com sensores RGB e combinações multissensoriais, especialmente em tarefas como a identificação e contagem de copas arbóreas em áreas urbanas. Por outro lado, a família DeepLab, voltada à segmentação semântica de alta precisão, é preferencialmente aplicada a dados multiespectrais, cuja riqueza espectral favorece a segmentação detalhada de diferentes classes de vegetação. A associação dessas arquiteturas aos respectivos tipos de sensores reflete escolhas metodológicas coerentes com suas capacidades técnicas, demonstrando uma tendência de alinhamento entre o tipo de sensor e a complexidade da tarefa de mapeamento da vegetação urbana.

394

## 395 CONCLUSÃO

396 A presente revisão evidenciou a evolução metodológica no uso de técnicas de  
397 aprendizado de máquina tradicional (*shallow learning*) e aprendizado profundo (*deep*  
398 *learning*) aplicadas ao mapeamento da vegetação urbana por meio de dados de  
399 sensoriamento remoto. Desde o primeiro estudo com ML identificado em 2007 até a  
400 consolidação das técnicas de DL a partir de 2017, observou-se um crescimento constante  
401 no interesse científico pela temática, intensificado com a integração entre ambas as  
402 abordagens a partir de 2019.

403 A maioria dos estudos concentra-se em tarefas de classificação da vegetação urbana,  
404 com ampla predominância dos algoritmos *Random Forest* e *Support Vector Machine*,  
405 especialmente em combinação com sensores multiespectrais embarcados em plataformas  
406 orbitais. Por sua vez, os algoritmos de DL, embora menos frequentes, vêm ganhando  
407 destaque em aplicações que requerem maior detalhamento espacial — como aquelas que  
408 utilizam dados de VANTs ou sensores LiDAR — sendo as arquiteturas U-Net, DeepLab  
409 e Mask R-CNN as mais recorrentes em tarefas de segmentação semântica e de instâncias.

410 A análise também revelou um avanço no uso de estratégias de fusão de dados, que  
411 combinam plataformas orbitais e aerotransportadas para ampliar a acurácia e resolver  
412 limitações específicas de cada sensor. Essa tendência reflete um amadurecimento  
413 metodológico da área, com ênfase crescente em abordagens integradas e adaptáveis.

414 Do ponto de vista geográfico, a liderança da China em número de publicações, seguida  
415 por Estados Unidos, Brasil e Canadá, demonstra o esforço internacional no  
416 aprimoramento das tecnologias de monitoramento da vegetação urbana, com aplicações  
417 que variam desde a simples detecção de cobertura vegetal até análises mais complexas  
418 voltadas à estrutura arbórea, saúde vegetal e serviços ecossistêmicos urbanos.

419 Em síntese, embora os métodos clássicos de ML ainda predominem, o avanço das  
420 arquiteturas de DL — impulsionado pela crescente disponibilidade de dados de alta  
421 resolução e pelo aumento da capacidade computacional — deve intensificar sua adoção  
422 nos próximos anos. Nesse contexto, destaca-se como desafio central o desenvolvimento  
423 de modelos mais explicáveis, generalizáveis e eficientes, capazes de operar em diferentes  
424 realidades geográficas e condições temporais, representando uma das principais fronteiras  
425 de pesquisa no mapeamento urbano por sensoriamento remoto aliado à inteligência  
426 artificial.

427 **Agradecimentos**

428 Agradecemos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)  
429 pela bolsa concedida e incentivo à ciência. Agradecemos ao CNPq (Conselho Nacional  
430 de Desenvolvimento Científico e Tecnológico) pelo apoio financeiro mediante os  
431 processos 305814/2023-0; 403213/2023-1; 135614/2024-4 e 308481/2022-4.

432 **REFERÊNCIAS**

433 CHEN, L. C., e al. Encoder-decoder with atrous separable convolution for semantic image  
434 segmentation. In Proceedings of the European conference on computer vision (ECCV),  
435 801-818. 2018.

436

437 CHENG, G. et al. Remote Sensing Image Scene Classification Meets Deep Learning:  
438 Challenges, Methods, Benchmarks, and Opportunities. arXiv:2005.01094. 2020.

439

440 DEMATTÊ, J. AM et al. Soil class and attribute dynamics and their relationship with  
441 natural vegetation based on satellite remote sensing. *Geoderma*, v. 302, p. 39-51. 2017.

442

443 ENDRENY, T. A. Strategically growing the urban forest will improve our world. *Nature*  
444 *Communications*, 9(1):1–3, ISSN 2041-1723. doi:10.1038/s41467-018-03622-0. 2018.

445

446 GOODFELLOW, I. et al. Deep learning. MIT press, 2016.

447

448 HE, K. et al. Mask R-CNN. Proceedings of the IEEE International Conference on  
449 Computer Vision (ICCV), 2961–2969. 2017.

450

451 HUANG, Y. et al. Deep learning in urban green space extraction in remote sensing: a  
452 comprehensive systematic review. *International Journal of Remote Sensing*, 46(3), 1117-  
453 1150. 2024.

454

455 KAMILARIS, A. et al. Deep learning in agriculture: A survey. *Computers and electronics*  
456 *in agriculture*, v. 147, p. 70-90, 2018.

457

458 KHURANA, M. et al. Urban land cover classification using Sentinel-2 data and SVM  
459 approach. *Earth Science Informatics*, 16, 1015–1029. 2023.

460

461 LUMNITZ, S. Mapping Urban Trees With Deep Learning And Streetlevel Imagery.  
462 Thesis for Master of Science in Forestry, The University of British Columbia, Vancouver,  
463 149p. 2019.

464

465 PU, R. et al. Assessing the Impact of Training Sample Size on Urban Land Cover  
466 Classification Accuracy Using Remotely Sensed Imagery. *Remote Sensing*, 6(2), 964–  
467 983. 2014.

468

469 POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar.  
470 *Biomass and Bioenergy*, 31(9), 646–655. 2007.

- 471  
472 SUDHA, S. K., & AJI, S. An analysis on deep learning approaches: addressing the  
473 challenges in remote sensing image retrieval. *International Journal of Remote Sensing*,  
474 42(24), 9405-9441. 2021.
- 475  
476 ZHANG, C., et al. Urban vegetation mapping using high-resolution satellite imagery and  
477 deep learning approaches. *Remote Sensing*, 13(3), 550. 2021.
- 478  
479 ZHANG, X. et al. Comparison of machine learning algorithms for vegetation mapping  
480 using Sentinel-2 and Landsat-8 data. *Remote Sensing*. 2020.
- 481  
482 ZHANG, X. et al. Individual tree detection and classification in urban areas using high-  
483 resolution imagery and deep learning. *Computers, Environment and Urban Systems*.  
484 2023.
- 485  
486 ZHU, X. X. et al. Deep learning in remote sensing: a review. arXiv preprint  
487 arXiv:1710.03959. 2017.