

Classificação de Coberturas e Espécies de Árvores em Ambientes Urbanos Tropicais Utilizando Redes Neurais Convolucionais e Conceitos de Conjuntos Fechados e Abertos: Revisão Bibliográfica

Classification of Tree Canopies and Species in Tropical Urban Environments Using Convolutional Neural Networks and Closed and Open Set Concepts: Bibliographic Review

Edvan de Souza Silva¹

1. Bacharel em Ciência da Computação. Mestrando no Programa de Pós-graduação em Sistemas e Computação (PGSC) pelo Instituto Militar de Engenharia – IME. Analista de Desenvolvimento de Sistemas.

silva.edvan@ime.eb.br

Palavras-chave

Classificação de espécies de árvores
Reconhecimento de conjuntos abertos
Redes neurais convolucionais
Sensoriamento remoto
Serviços ecossistêmicos

Keywords

Classification of tree species
Convolutional neural networks
Open set recognition
Remote sensing
Ecosystem services

Resumo:

Este estudo engloba a literatura sobre classificação de coberturas e espécies de árvores em ambientes urbanos tropicais utilizando redes neurais convolucionais e conceitos de conjuntos fechados e abertos com o objetivo de evidenciar a diferença na utilização de conjuntos fechados e abertos e a relevância da utilização de conjuntos abertos para representar com mais fidelidade o espaço geográfico alvo da análise e desta forma diminuir o erro de generalização na predição de espécies de árvores. Realizou-se revisão bibliográfica exploratória com pesquisas científicas contendo as seguintes abordagens centrais “impacto de ambientes arborizados na saúde”, “classificação de espécies de árvores”, “redes neurais convolucionais para classificação de imagens” e “conceitos de conjuntos abertos e fechados”. A partir da revisão bibliográfica foi possível observar a importância da necessidade de utilização de técnicas computacionais que permitam a utilização de conjuntos abertos na classificação automática de espécies de árvores para evitar equívocos na fase de predição de um sistema de reconhecimento de padrões, e desta forma aumentar a eficiência ao analisar dados geográficos de uma região tropical urbana.

Abstract:

This study covers the literature on the classification of tree canopies and species in tropical urban environments using convolutional neural networks and the concepts of closed and open sets with the aim of highlighting the difference in the use of closed and open sets and the relevance of using open sets to represent the geographic space targeted more faithfully by the analysis and thus reduce the generalization error in the prediction of tree species. In order to achieve this goal, an exploratory literature review was carried out, with scientific research containing the following central approaches “impact of wooded environments on health”, “classification of tree species”, “convolutional neural networks for image classification” and “concepts of open and closed sets”. From the literature review, it was possible to observe the importance of the need to use computational techniques that allow the use of open sets in the automatic classification of tree species to avoid mistakes in the prediction phase of a pattern recognition system, and thus increase efficiency when analyzing geographic data from a tropical urban region.

Artigo recebido em: 25.01.2024.

Aprovado para publicação em: 07.02.2024.

INTRODUÇÃO

As iniciativas de arborização urbana são ativamente promovidas como uma ferramenta de planejamento que faz uso de recursos naturais para permitir que espaços públicos reduzam o impacto ambiental causado pela urbanização e se adequem aos efeitos das mudanças climáticas, tendo como um dos objetivos principais, melhorar a saúde e o bem-estar da população (Salmond *et al.*, 2016).

Segundo Gonzalez e Woods (2010), ambientes arborizados possuem a capacidade para mitigar os níveis de poluição, e proporcionar benefícios como a melhoria da qualidade do ar, sequestro de carbono e redução da temperatura de superfície do solo em escalas locais. Portanto, estudar áreas tropicais urbanas é uma estratégia potencial para entender como estes locais podem ser adaptados de maneira eficiente a uma infraestrutura ecológica que traga os benefícios supracitados para a sociedade, e também, funciona como uma ferramenta para controlar as condições da região com o objetivo de monitorar a saúde de cada árvore, identificar o aparecimento de pragas e apoiar decisões para aplicar medidas cabíveis quando uma espécie estiver interferindo negativamente no espaço pavimentado ao bloquear passagens e destruir calçadas devido ao crescimento das raízes.

Imagens de sensoriamento remoto combinadas com algoritmos de aprendizado de máquina têm se mostrado uma forma promissora para mapear e classificar espécies de árvores. Neste contexto, redes neurais convolucionais (CNNs) têm sido utilizadas, e no atual estado da arte, têm alcançado bons resultados no processamento de características morfológicas das espécies, como formato da folhagem, padrões de ramificação e estrutura da copa das árvores (Kattenborn *et al.*, 2021).

Os modelos tradicionais de CNNs utilizam conjuntos fechados (Closed Set) em seu treinamento, onde cada classe é conhecida e rotulada na base de dados utilizada. Ma *et al.* (2021), descrevem que as arquiteturas clássicas de aprendizado profundo supervisionado baseiam-se em estruturas organizadas para lidar com conjuntos fechados de dados. Portanto, em uma abordagem com o objetivo de realizar classificação/segmentação, é assumido que não existem classes desconhecidas na organização dos dados. No entanto, os conjuntos fechados representam apenas uma parcela das classes que existem no mundo real, desta forma, para representar um cenário completo é necessário abranger todas as possibilidades do espaço de características e, a depender da complexidade do problema, um esforço manual teria que ser empregado no procedimento de rotulação o que despenderia muito tempo para ser concluído (Geng; Huang; Chen, 2020).

Para resolver esta questão, a literatura tem apresentado o recurso conhecido como Open Set Recognition (OSR) que pode ser descrito como um conjunto de técnicas capazes de lidar com o problema de identificação de classes não vistas nos conjuntos de treinamento, com o objetivo de diminuir o erro de classificação e promover a chance de um especialista realizar uma posterior identificação das amostras desconhecidas (Oliveira *et al.*, 2021).

MÉTODO

Com o objetivo de refinar os resultados da pesquisa, a metodologia adotada para compor esta revisão foi pautada em realizar análises sobre assuntos pertinentes a arborização urbana em ambientes tropicais e sensoriamento remoto, com o objetivo de adquirir informações relativas à importância e o impacto que ambientes urbanos arborizados causam na sociedade.

Também foram realizadas análises sobre trabalhos que descrevem o sensoriamento remoto na perspectiva computacional, cruzando informações relativas as CNNs e OSR. Para tanto, foi adotada a metodologia PICO (população, intervenção, comparação e outcome/resultado), como uma estratégia para identificação de palavras-chave relevantes na formulação da chave de busca.

Conforme estipulado na metodologia PICO, a seguinte questão que se mostrou mais relevante para o processo de busca foi: Quais evidências e métodos existem no atual estado da arte que demonstram os benefícios e as diferenças na utilização de CNNs para classificar coberturas e espécies arbóreas em ambientes tropicais urbanos, com abordagem de conjuntos abertos e conjuntos fechados, utilizando em seu processamento imagens obtidas por sensoriamento remoto?

Os pontos-chaves extraídos da questão se organizam da seguinte maneira: Como população, consideramos as imagens de ambientes tropicais urbanos obtidas por sensoriamento remoto; como intervenção, temos a relevância e aplicação de CNNs e conjuntos abertos na classificação de espécies de árvores em ambientes tropicais urbanos; para a comparação, analisamos a importância e aplicação de CNNs e conjuntos fechados na classificação de espécies de árvores em ambientes tropicais urbanos e por fim como resultado, estudamos a possibilidade de se obter uma análise qualitativa e quantitativa relacionadas a performance das CNNs em conjuntos fechados e abertos. Este processo originou a chave de busca descrita abaixo.

“CNN” OR “Convolutional Neural Network”) AND (“Semantic Segmentation” OR “Image Classification”) AND (“Remote Sensing” OR “Urban Remote Sensing”) AND (“Tree Species” OR “Individual Tree Crown” OR “ITC”) AND (“Urban Tree”) AND (“Open Set Segmentation” OR “Open Set” OR “OSR” OR “Open Set Recognition”)

A chave de busca originada pela aplicação da metodologia PICO para o levantamento bibliográfico relacionado, foi aplicada nas bases IEEE Xplore Digital Library, Google Scholar, Portal Periódicos Capes e Scopus e os critérios de exclusão e inclusão foram baseados no recorte temporal do ano de 2014 até 2023, porém os resultados mais relevantes se agruparam no recorte temporal de 2016 até 2022. O resumo e as palavras-chave também foram considerados para relacionar a relevância de cada trabalho, assim como os trabalhos citados pelas pesquisas encontradas.

REVISÃO DA LITERATURA

CONJUNTOS FECHADOS

Em “Urban Tree Species Classification Using a WorldView-2/3 And LiDAR Data Fusion Approach and Deep Learning”, a arquitetura de CNN DenseNet foi explorada por Hartling et al. (2019) para classificar espécies arbóreas em ambientes urbanos. O objetivo principal foi pautado em avaliar imagens de alta resolução espacial combinados com dados LiDAR (light detection and ranging), com o propósito de avaliar a performance das DenseNets em relação aos métodos Random Forest (RF) e Support Vector Machines (SVM).

Em “Mapping Urban Trees Within Cadastral Parcels Using an Object-based Convolutional neural network”, Timilsina, Sharma e Aryal (2019), utilizaram uma Object-based CNN para classificar coberturas arbóreas e áreas de gramado em espaços urbanos registrados geograficamente, com o objetivo de estudar se haveria aumento da acurácia. A abordagem Object-based, em contraste a abordagem pixel-wise, que rotula individualmente cada pixel pertencente a uma classe, segmenta a imagem e rotula todos os segmentos de acordo com a classe considerando os atributos espaciais, espectrais, geométricos e texturais.

Timilsina, Aryal e Kirkpatrick (2020), no artigo “Mapping Urban Tree Cover Changes Using Object-based Convolution Neural Network (OB-CNN)”, utilizaram Object-based CNN para identificar coberturas arbóreas em áreas urbanas, com o principal objetivo de estudar a relação temporal entre a mudança na estrutura dessas coberturas e as variáveis socioeconômicas de renda familiar média e ensino superior. Para tal, foram definidos uma série de subobjetivos, dentre os quais, podemos citar o que mais tem relação com o tratamento dos dados de entrada da CNN, como sendo a etapa de processamento de imagens e dados LiDAR para gerar um modelo de cobertura arbórea - Canopy Height Model (CHM) - e índice de vegetação por diferença normalizada – Normalized Difference Vegetation Index (NVDI).

Em “Application and Evaluation of a Deep Learning Architecture to Urban Tree Canopy Mapping”, Wang, Fan e Xian (2021), utilizaram uma U-net para mapear coberturas arbóreas urbanas com o objetivo de avaliar a viabilidade e a eficácia desta arquitetura de CNN ao processar imagens em quatro escalas espaciais distintas, a saber: 16cm, 32cm, 50cm e 100cm. Neste artigo, também foi realizado uma comparação em relação a abordagem Object-based (Object-based image analysis - OBIA).

No artigo “Deep Learning-based Tree Species Mapping in a Highly Diverse Tropical Urban Setting”, Martins et al. (2021), utilizaram uma estrutura única de arquitetura CNN multitarefa de baixo custo computacional para classificar e detectar Individual Tree Crowns (ITCs) em ambientes urbanos: DeepLabv3+ based Multi-Task Encoder-Decoder (MT-EDv3). O MTEDv3 é constituído por um encoder compartilhado — baseado na arquitetura ResNet com 8 blocos residuais e vinte (20) camadas convolucionais (ResNet-20) — que aprende características globais, e dois decoders com funções específicas, produzir as saídas de segmentação semântica e distance map transform.

Martins et al. (2021), em *Semantic Segmentation of Tree-Canopy in Urban Environment with Pixel-Wise Deep Learning*”, realizaram a comparação de cinco arquiteturas de CNNs do estado da arte para classificar coberturas arbóreas em ambiente urbano com o objetivo de descobrir o melhor modelo para esta tarefa, ao medir o desempenho por pixel accuracy, acurácia média, F1-Score, Kappa e Intersection over Union (IoU). As seguintes arquiteturas de CNNs foram comparadas: FCN (Fully Convolutional Networks), U-Net, SegNet, Dynamic Dilated Convolution Network e DeepLabV3+.

No artigo “Tree Species Mapping in The Brussels Capital Region Using Deep Learning and Data Fusion”, Neyns et al. (2023), utilizaram três tipos de imagens para classificar espécies arbóreas: PlanetScope imagery, very-high-resolution orthophotos, e dados LiDAR utilizados para gerar um CHM. No tratamento dessas imagens, foi proposta uma estrutura multimodal de aprendizado profundo, composta por dois recursos que atuam individualmente para processar imagens geradas pela fusão das ortofotos e CHM, e para extrair informações de dados multitemporais utilizando o PlanetScope imagery.

Choi et al. (2022), no artigo “An automatic approach for tree species detection and profile estimation of urban street trees using deep learning and Google Street View Images”, desenvolveram um método para produção de inventário arbóreo, utilizando técnicas de aprendizado profundo para detecção e segmentação de espécies de árvores em ambientes urbanos. Também foram utilizadas informações de geolocalização e características das estruturas das árvores (e.g. altura, diâmetro e tamanho da copa) como metadados geoespaciais, os quais foram adicionados às imagens (Geotagging) obtidas a partir de capturas realizadas pelo Google Street View 360 (GSV 360).

Em “Nationwide urban tree canopy mapping and coverage assessment in Brazil from high-resolution remote sensing images using deep learning”, Guo et al. (2023), desenvolveram um método de aprendizado profundo semi-supervisionado para realizar segmentação semântica em imagens de áreas urbanas, obtidas por

sensoriamento remoto, a fim de identificar coberturas arbóreas. Ao todo, foram utilizadas duas arquiteturas: DeepLabV3+ e uma CNN padrão para classificação binária, com 4 camadas convolucionais, uma camada global average pooling e uma camada totalmente conectada.

O framework foi elaborado com base na estratégia de treinamento adversário. Foram implementadas duas DeepLabV3+: uma para segmentação semântica dos dados rotulados e outra para os não rotulados. Neste contexto, a CNN padrão para classificação binária foi utilizada como uma rede discriminativa, que avalia a qualidade da predição semântica em real ou fake e contribui na retropropagação para ajuste dos pesos da rede destinada para processar as imagens não rotuladas.

CONJUNTOS ABERTOS

Os trabalhos relativos as abordagens de conjuntos abertos não tratam exclusivamente da classificação de coberturas ou espécies de árvores em ambientes urbanos, mas promovem uma sólida base teórica e resultados de experimentações que fundamentam o estudo de conjuntos abertos e a possibilidade de sua aplicação em concomitância com as CNNs para resolver problemas em diversas áreas de aplicação.

Em “Fully Convolutional Open Set Segmentation”, Oliveira et al. (2021), apresentaram dois métodos de aprendizagem profunda para lidar com conjuntos abertos de dados: OpenFCN e o OpenPCS. Neste contexto, o OpenFCN utiliza uma arquitetura FCN, que são normalmente compostas por backbones CNN tradicionais, mas possuem camadas de inferência substituídas por interpolação bilinear e mais convoluções.

O esquema OpenFCN para tarefas de segmentação semântica de conjuntos abertos funciona da seguinte maneira: Durante o treinamento, o OpenFCN se comporta como uma FCN tradicional de conjuntos fechados, com apenas classes conhecidas sendo alimentadas a rede. Neste sentido, o OpenFCN se diferencia das FCNs somente durante as fases de validação e teste, quando o OpenMax, método para aplicação de conjuntos abertos descrito por Bendale e Boulton (2016), é acionado e as probabilidades são limiarizadas com a intenção de prever as classes desconhecidas.

Como segunda abordagem, o OpenPCS é pautado em duas práticas: sendo a primeira, a utilização de análise de componentes principais (PCA), que atua na redução da dimensionalidade dos dados; e a segunda, quando leva em consideração os mapas de características das primeiras camadas, que codificam informações próximas ao espaço de entrada das camadas da CNN, e as combina com ativações provenientes das últimas camadas, fundindo os níveis baixos e altos de informação semântica.

O OpenPCS apresenta duas vantagens em relação ao OpenFCN que são elas: (1) Inferência rápida durante o tempo de teste, pois as implementações do PCA podem ser altamente paralelizadas por meio de operações vetoriais e pontos de probabilidades gaussianas de baixa dimensionalidade podem ser calculados mais rapidamente; e (2) A seleção de recursos do PCA garante que apenas os canais de ativação mais importantes sejam usados para calcular a pontuação da função para detectar amostras fora da distribuição e, conseqüentemente, classes desconhecidas.

Em “Open Set Semantic Segmentation for Multitemporal Crop Recognition”, Martinez et al. (2021), apresentou o OpenPCS++ como uma evolução do OpenPCS, que atua com o objetivo de minimizar as limitações do OpenPCS. Como limitação, o OpenPCS assume que a transformação PCA segue uma distribuição gaussiana com média zero, e atesta um membro de uma classe conhecida apenas se a probabilidade obtida pelo cálculo do PCA ultrapassar um limite dado, desta maneira, o OpenPCS ignora que as representações de

probabilidades obtidas referem-se a diferentes espaços para cada classe conhecida e adota o mesmo limiar para todas as classes.

Neste sentido, OpenPCS++ procura aliviar as limitações do OpenPCS aplicando uma transformação whitening (também conhecida como sphering) que normaliza a distribuição de cada classe em uma gaussiana isotrópica com média zero e matriz de covariância identidade. A transformação whitening permite uma detecção de pixels fora de distribuição de forma simplificada, desta forma a probabilidade de um pixel pertencer a uma determinada classe não depende da sua posição no espaço de características, mas é determinado unicamente pela sua magnitude.

Pode-se então usar a magnitude das representações do OpenPCS++ como um sistema de pontuação que considera como fora de distribuição todos os pixels para os quais a probabilidade é maior que um limite definido para uma classe ser considerada desconhecida. Com esta normalização, OpenPCS++ é melhor que o OpenPCS para reconhecimento de conjuntos abertos multiclasse, pois o limite é definido em um espaço redimensionado para levar em conta a variabilidade inerente para cada classe conhecida.

COMPARAÇÃO ENTRE OS TRABALHOS RELACIONADOS

A Tabela 1 sumariza a extensão de abordagem dos trabalhos relacionados a esta revisão com o intuito de apresentar de forma mais clara os respectivos ambientes e recursos utilizados.

A Tabela 2 apresenta de maneira resumida os recursos utilizados na implementação de cada rede baseada em OSR com o objetivo de mostrar a evolução de cada modelo em relação as melhorias aplicadas.

CONSIDERAÇÕES FINAIS

Ambientes urbanos que possuem infraestrutura planejada contendo áreas arborizadas, proporcionam vantagens a população em relação ao aumento da qualidade de vida, pois vias públicas com área verde contribuem de forma positiva no fornecimento de serviços ecossistêmicos. Diante disso, estudar áreas tropicais urbanas é uma estratégia importante para que os órgãos governamentais relacionados ao meio ambiente, possam entender como adaptar estes locais, de maneira ordenada e eficiente, à uma infraestrutura ecológica adequada a região e que traga benefícios para a sociedade.

Tradicionalmente, o levantamento de informações de uma região é realizado por estudos de campo. Estes estudos levam bastante tempo para serem concluídos, pois demandam que profissionais capacitados se desloquem até o local para analisar e catalogar detalhadamente cada espécie presente. A área de cobertura de análise, é outro ponto impactante no processo de levantamento de dados, pois cobrir áreas extensas demais é uma tarefa que exige um grande esforço humano e investimento de recursos financeiros.

Com o sensoriamento remoto é possível cobrir uma região muito maior, e o processo fotogramétrico tem o poder de gerar imagens georreferenciadas de alta resolução, com tamanho de pixel grande o suficiente para tornar dados da imagem significativos no processo de classificação de espécies de árvores.

A utilização de CNNs no processamento de imagens é uma estratégia poderosa e leva vantagem sobre o aprendizado de máquina tradicional por realizar a engenharia de atributos de maneira automática, em que o aprendizado de informações representativas para detectar e classificar coberturas ou espécies de árvores, é realizado diretamente nos dados de entrada sem intervenção humana.

Tabela 1: Tabela comparativa sobre ambientes e recursos de abordagem dos artigos.

Artigo	Ambiente Urbano	Classificação de Espécies de Árvores	Classificação de Cobertura de Árvores	Conjuntos Fechados	Conjuntos Abertos
Urban Tree Species Classification Using a WorldView-2/3 And LiDAR Data Fusion Approach and Deep Learning.	V	V		V	
Mapping Urban Trees Within Cadastral Parcels Using an Object-Based Convolutional neural network.	V		V	V	
Mapping urban tree cover changes using object-based convolution neural network (OB-CNN).	V		V	V	
Application and evaluation of a deep learning architecture to urban tree canopy mapping.	V	V		V	
Tree Species Mapping in The Brussels Capital Region Using Deep Learning and Data Fusion.	V	V		V	
Deep Learning-based Tree Species Mapping in a Highly Diverse Tropical Urban Setting.	V	V		V	
Semantic Segmentation of Tree-Canopy in Urban Environment with Pixel-Wise Deep Learning.	V		V	V	
Nationwide urban tree canopy mapping and coverage assessment in Brazil from high-resolution remote sensing images using deep learning.	V		V	V	
An automatic approach for tree species detection and profile estimation of urban street trees using deep learning and Google Street View images.	V	V		V	
Fully Convolutional Open Set Segmentation.	V				V
Open Set Semantic Segmentation for Multitemporal Crop Recognition.					V

Tabela 2: Recursos principais utilizados na implementação de CNNs para OSR.

	OpenMax	Análise de Componentes Principais	Whitening
OpenFCN	V		
OpenPCS		V	
OpenPCS++		V	V

Somadas as técnicas de conjuntos abertos, as CNNs podem melhorar sua performance e diminuir sua taxa de erro ao categorizar classes que não foram utilizadas durante a fase de treinamento como classes desconhecidas, não interferindo desta forma em sua eficiência em prever com maior nível de confiabilidade os elementos já conhecidos e cujo modelo foi especificamente treinado para classificar.

Os trabalhos referentes aos conjuntos fechados exemplificaram o poder das CNNs ao identificar e classificar, com alto grau de confiabilidade, coberturas e espécies de árvores, e demonstraram como cenários sociais e demográficos podem mudar ao longo do tempo de acordo com a estrutura arbórea de uma região a partir de análise dos resultados preditos automaticamente pelas redes empregadas.

Os trabalhos que abordaram os conjuntos abertos exemplificaram como um cenário multiclasse pode ser bem delineado mesmo que não possua espécies de árvores, tipos de cobertura arbórea ou outros elementos inseridos no dataset de treinamento das CNNs. Desta forma, uma análise em um ambiente pode descrever a existência de elementos desconhecidos e deixar que especialistas decidam se uma determinada área precisará de uma análise mais detalhada, ao mesmo tempo em que o modelo diminui as taxas de erro ao não classificar elementos desconhecidos como conhecidos.

Esta revisão bibliográfica suscita potenciais direções para pesquisas futuras, uma vez que a análise do corpus documental revelou uma lacuna substancial em termos de estudos dedicados à classificação de espécies arbóreas em ambientes caracterizados por uma considerável diversidade taxonômica. Diante desse contexto desafiador, marcado pela notável similaridade entre as espécies, destaca-se a pertinência da investigação em torno da aplicação de CNNs e conjuntos de dados abertos, emergindo como uma área promissora a ser minuciosamente explorada.

REFERÊNCIAS

- BENDALE, A.; BOULT, T. E. **Towards open set deep networks**. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2016. p. 1563–1572.
- CHOI, K.; LIM, W.; CHANG, B.; JEONG, J.; KIM, I.; PARK, C.-R.; KO, D. W. **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*, Elsevier, v. 190, p. 165–180, 2022.
- GENG, C.; HUANG, S.-j.; CHEN, S. **Recent advances in open set recognition: A survey**. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 43, n. 10, p. 3614–3631, 2020.
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais 3ª Edição**. [S.l.]: Editora Pearson, 2010.
- GUO, J.; XU, Q.; ZENG, Y.; LIU, Z.; ZHU, X. X. **Nationwide urban tree canopy mapping and coverage assessment in brazil from high-resolution remote sensing images using deep learning**. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 198, p. 1–15, 2023.
- HARTLING, S.; SAGAN, V.; SIDIKE, P.; MAIMAITIJANG, M.; CARRON, J. **Urban tree species classification using a worldview-2/3 and lidar data fusion approach and deep learning**. *Sensors*, MDPI, v. 19, n. 6, p. 1284, 2019.
- KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S. **Review on convolutional neural networks (cnn) in vegetation remote sensing**. *ISPRS journal of photogrammetry and remote sensing*, Elsevier, v. 173, p. 24–49, 2021.

- MA, C.; SUN, H.; ZHU, J.; ZHANG, L.; WANG, B.; WU, D.; SUN, J. **Normalized maximal margin loss for open-set image classification.** IEEE Access, IEEE, v. 9, p. 54276–54285, 2021.
- MARTINEZ, J. A. C.; OLIVEIRA, H.; SANTOS, J. A. dos; FEITOSA, R. Q. **Open set semantic segmentation for multitemporal crop recognition.** IEEE Geoscience and Remote Sensing Letters, IEEE, v. 19, p. 1–5, 2021.
- MARTINS, G. B.; ROSA, L. E. C. L.; HAPP, P. N.; FILHO, L. C. T. C.; SANTOS, C. J. F.; FEITOSA, R. Q.; FERREIRA, M. P. **Deep learning-based tree species mapping in a highly diverse tropical urban setting.** Urban Forestry & Urban Greening, Elsevier, v. 64, p. 127241, 2021.
- MARTINS, J. A. C.; NOGUEIRA, K.; OSCO, L. P.; GOMES, F. D. G.; FURUYA, D. E. G.; GONÇALVES, W. N.; SANT'ANA, D. A.; RAMOS, A. P. M.; LIESENBERG, V.; SANTOS, J. A. dos et al. **Semantic segmentation of tree-canopy in urban environment with pixel-wise deep learning.** Remote Sensing, MDPI, v. 13, n. 16, p. 3054, 2021.
- NEYNS, R.; EFTHYMIADIS, K.; LIBIN, P.; CANTERS, F. **Tree species mapping in the Brussels capital region using deep learning and data fusion.** In: 2023 Joint Urban Remote Sensing Event (JURSE). [S.l.: s.n.], 2023. p. 1–4.
- OLIVEIRA, H.; SILVA, C.; MACHADO, G. L.; NOGUEIRA, K.; SANTOS, J. A. dos. **Fully convolutional open set segmentation.** Machine Learning, Springer, p. 1–52, 2021.
- SALMOND, J. A.; TADAKI, M.; VARDOULAKIS, S.; ARBUTHNOTT, K.; COUTTS, A.; DEMUZERE, M.; DIRKS, K. N.; HEAVISIDE, C.; LIM, S.; MACINTYRE, H. et al. **Health and climate related ecosystem services provided by street trees in the urban environment.** Environmental Health, BioMed Central, v. 15, n. 1, p. 95–111, 2016.
- TIMILSINA, S.; SHARMA, S.; ARYAL, J. **Mapping urban trees within cadastral parcels using an object-based convolutional neural network.** University Of Tasmania, 2019.
- TIMILSINA, S.; ARYAL, J.; KIRKPATRICK, J. B. **Mapping urban tree cover changes using object-based convolution neural network (ob-cnn).** Remote Sensing, MDPI, v. 12, n. 18, p. 3017, 2020.
- WANG, Z.; FAN, C.; XIAN, M. **Application and evaluation of a deep learning architecture to urban tree canopy mapping.** Remote Sensing, MDPI, v. 13, n. 9, p. 1749, 2021.

