

# MAPEAMENTO DE FRAGMENTOS ARBÓREOS URBANOS COM IMAGENS ORBITAIS E APRENDIZAGEM PROFUNDA

*MAPPING URBAN TREE FRAGMENTS WITH ORBITAL IMAGES AND DEEP LEARNING.*

 Lucas Antônio Silva <sup>A</sup>  
 Felipe David Georges Gomes <sup>A</sup>  
 Lucas Yuri Oliveira <sup>B</sup>  
 Vagner Souza Machado <sup>A</sup>  
 José Marcato Júnior <sup>B</sup>  
 Wesley Gonçalves <sup>B</sup>  
 Lucas Prado Osco <sup>A</sup>  
 Ana Paula Marques Ramos <sup>C</sup>

<sup>A</sup> Universidade do Oeste Paulista (UNOESTE), Presidente Prudente, SP, Brasil

<sup>B</sup> Universidade Federal de Mato Grosso do Sul (UFMS), Campina Grande, MS, Brasil

<sup>C</sup> Universidade Estadual Paulista (UNESP), Presidente Prudente, SP, Brasil

Recebido em: 16/08/2024 | 18/07/2025    DOI: 10.12957/tamoios.2025.86644

Correspondência para: Lucas Antônio Silva (lucas198antonio@gmail.com)

## Resumo

A vegetação arbórea é um dos principais componentes do meio ambiente, pois exerce grande influência na qualidade ambiental, sobretudo dos espaços urbanos. O uso de dados de sensoriamento remoto é uma das melhores opções para se mapear o comportamento espacial e espectral da vegetação arbórea, mas cria uma demanda adicional, que é a aplicação de técnicas eficientes de processamento de imagens. Nesse contexto, a aplicação de métodos baseados em inteligência artificial representa o estado da arte para se transformar dados em informações úteis de forma rápida. Nesse trabalho foi realizado o mapeamento de fragmentos arbóreos urbano em imagens orbitais multiespectrais por redes de aprendizagem profunda e algoritmo de aprendizagem de máquina. As redes testadas foram a U-Net e DeepLabV3+, e o algoritmo de aprendizagem rasa, o Random Forest. As imagens correspondem à PlanetScope (~3m de resolução espacial). Um protocolo robusto de três experimentos, composto por dados de diferentes datas, foi definido para o treinamento, validação e teste dos modelos. Um conjunto de métricas foi utilizado para caracterizar o desempenho dos algoritmos em cada experimento desenvolvido. De modo geral, o modelo DeepLabV3+ alcançou resultados superiores comparado aos demais modelos, com valor de acurácia em aproximadamente 94%. Conclui-se que a abordagem de mapeamento arbóreo urbano em imagem orbital com resolução métrica por redes de aprendizagem profunda é a estratégia mais adequada devido a heterogeneidade espacial e espectral característica do ambiente urbano, e a similaridade espectral entre graminha e cobertura arbórea. Ao treinar os modelos em uma data e testar em outras datas, pode-se caracterizar a capacidade de adaptação de domínio dos algoritmos, reforçando que a aprendizagem profunda é a estratégia que melhor atende a complexidade da tarefa em questão.

**Palavras-chave:** Vegetação, Áreas urbanas, Redes de segmentação semântica, Mapeamento, Sensoriamento Remoto.

## Abstract

Tree vegetation is a key component of the environment, playing a significant role in shaping environmental quality, particularly within urban spaces. Remote sensing data stands out as one of the most effective means of mapping the spatial and spectral behavior of tree vegetation. However, its use introduces a critical demand: the need for efficient image processing techniques. In this context, artificial intelligence methods represent the state of the art in transforming data into useful information quickly and effectively. This study aimed to map urban tree fragments using multispectral orbital images through deep learning networks and a traditional machine learning algorithm. The models evaluated included two convolutional neural networks—U-Net and DeepLabV3+—as well as the Random Forest algorithm, representing a shallow learning approach. The input data consisted of PlanetScope imagery (~3-meter spatial resolution). A robust experimental protocol was established, comprising three experiments with data from different acquisition dates for training, validation, and testing purposes. A set of performance metrics was used to evaluate each model across the experiments. Overall, the DeepLabV3+ model outperformed the other approaches, achieving an accuracy of approximately 94%. The results indicate that deep learning-based mapping of urban tree vegetation using high-resolution





orbital imagery is the most suitable strategy, particularly due to the spatial and spectral heterogeneity of urban environments and the spectral similarity between grassland and tree cover. Training the models on one date and testing them on others also enabled the assessment of domain adaptation capabilities, reinforcing that deep learning is the most effective approach for addressing the complexity of this task.

**Keywords:** Vegetation, Urban areas, Semantic segmentation networks, Mapping, Remote Sensing.

## INTRODUÇÃO

A vegetação desempenha um papel fundamental na regulação do microclima, reduzindo a temperatura do solo e do ar, além de controlar a umidade relativa do ambiente (BARBOZA; ALENCAR; ALENCAR, 2020). Estudos científicos comprovam sua importância na manutenção do equilíbrio ambiental e na mitigação dos impactos causados pela ocupação territorial (COSTA; FRANCO; MARTORANO, 2022; DONATO et al., 2019; GARUANA et al., 2020). Apesar da relevância da vegetação tanto em ambientes urbanos quanto rurais, este estudo se concentra na análise do contexto urbano.

Uma das principais consequências da urbanização é a formação de ilhas de calor, fenômeno diretamente relacionado à ocupação do território (TAKASHIMA-OLIVEIRA et al., 2018). Com a intensificação do processo de urbanização de uma região é comum que ocorra algumas ações antrópicas que acabam elevando a temperatura da superfície, como: a supressão da vegetação, impermeabilização do solo e aumento de densidade de construções. Como consequência, inicia-se uma alteração no microclima da região, podendo gerar uma ilha de calor. Essas destacam-se pela diferença do clima em comparação as regiões ao seu entorno, onde é possível perceber que nas regiões urbanizadas as temperaturas são maiores, a velocidade do vento e a umidade do ar são menores, além de outros parâmetros que são alterados pela mesma causa (OKE, 2009).

A deterioração do conforto térmico afeta a qualidade de vida da população. Em casos extremos isso pode levar ao aumento do índice de mortalidade durante períodos de calor intenso, principalmente de pessoas do sexo feminino, e pessoas com idade igual ou maior a 55 anos nessas localidades (FAYE et al., 2021). Projeções futuras para os anos de 2030 a 2050 apontam que esse índice irá aumentar ainda mais, principalmente caso não ocorra uma adaptação às mudanças climáticas por parte da sociedade. Dentro dessa previsão o índice de mortalidade pode chegar a 587 mortes a cada 100.000 habitantes por ano (DINIZ; GONÇALVES; SHERIDAN, 2020).

A literatura aponta que a vegetação pode diminuir significativamente a temperatura dos ambientes urbanos (FERRINI et al., 2020; GATTO et al., 2020; WANG et al., 2020). Estudos mostram uma diminuição da temperatura da superfície em até 40% (WANG et al., 2020). A influência da vegetação para a regulação do microclima também pode ser observada por Bordim (BORDIM; LONGO; BORDIM, 2022) que, ao comparar parâmetros entre uma área urbana pavimentada e uma área de bosque, constatou que as temperaturas do ar e do solo são mais baixas no bosque, além de uma maior umidade relativa do ar. Outro estudo, que também denota a influência da vegetação sobre o microclima, é apresentado em (CRISTAL DE ARAÚJO ALMEIDA; SILVA BIZZO LIMA; ALEXANDRE CARDOSO CANTUÁRIA, 2021).



Além da diminuição da temperatura, a vegetação é capaz de promover outras melhorias para o ambiente que são de grande importância principalmente no contexto urbano. A vegetação promove uma melhoria da qualidade do ar por meio da retenção de poluição (partículas) em suas folhas, a diminuição da concentração dessas partículas no ar diminui o impacto na saúde humana (BECKETT; FREER-SMITH; TAYLOR, 2000).

Uma vez que os motivos para a formação das ilhas de calor e alterações do microclima urbano são delimitados, nota-se que a vegetação deve ser entendida como uma forma de minimizar essas alterações climáticas. Essa ideia é defendida por Solecki (SOLECKI et al., 2005) que afirma que a arborização das ruas, implementação de áreas verdes nas cidades por meio de bosques parques ou jardins, deve ser adotada como uma estratégia para mitigação das ilhas de calor.

O contexto apresentado evidencia a demanda de se realizar o mapeamento contínuo da vegetação arbórea, visando acompanhar espaço-temporalmente as mudanças que ocorrem nas regiões, sobretudo, urbana, devido às ações antrópicas. Em geral, estudos voltados para analisar a cobertura da superfície de uma região demandam dados que precisam cumprir alguns requisitos, como apresentar uma resolução espacial que permita a identificação do alvo a ser mapeado e uma resolução temporal adequada ao recorte temporal de interesse. Todavia, se por um lado, os avanços nas geotecnologias, como nos sensores de aquisição de imagens por sensoriamento remoto, permitem o acesso a dados em variadas escalas temporais e cartográficas; por outro, técnicas de processamento de imagens cada vez mais sofisticadas são exigidas para lidar com o volume e a qualidade espacial desses dados.

O estado da arte na extração de informações em imagens de sensoriamento remoto encontra-se no uso de redes de aprendizagem profunda (Deep Learning - DL) (OSCO et al., 2021). Aprendizagem profunda é uma subárea de aprendizagem de máquina que se destaca pelo uso de redes neurais profundas para aprender e representar informações complexas. Essas redes são capazes de extrair informações acuradas de volumosos conjuntos de dados, incluindo aqueles relacionados ao estudo da cobertura da superfície terrestre. Uma rede de DL são redes neurais formadas por neurônios que constituem certos parâmetros, esses neurônios são capazes de transformar os dados de entrada, e gerar como saída informações refinadas. Durante o treinamento, esses parâmetros são ajustados para que a rede seja capaz de transformar os dados de entrada em informações refinadas.

As redes de DL são empregadas em diversas áreas do conhecimento, e uma das áreas onde se destacam é no sensoriamento remoto. Essas redes podem processar grandes volumes de dados provenientes de imagens de satélite e gerar mapas detalhados de características da superfície terrestre, como categorias de uso do solo, detecção de mudanças, identificação de objetos e muito mais. Esses mapas e resultados similares têm a vantagem de facilitar a interpretação para os especialistas e tomadores de decisão, fornecendo informações visuais claras e compreensíveis.

As redes de aprendizagem profunda associadas ao sensoriamento remoto são aplicadas em dois grandes setores, sendo eles na agricultura, onde as redes a partir de imagens obtidas por VANT (veículo aéreo não tripulado) permitem a detecção de doenças, espécies invasoras



e falhas de plantio. Já as aplicações das redes de DL em contexto urbano estão cada vez mais sendo aplicada principalmente na detecção de vegetação, mapeamento do uso e cobertura do solo, monitoramento de tráfego de veículos, detecção de construções, até mesmo na detecção de fissuras em pavimentos (OSCO et al., 2021).

Estudos mostram (FRANCIS; SIDIROPOULOS; MULLER, 2019a; KUSSUL et al., 2017; LÓPEZ-PUIGDOLLERS; MATEO-GARCÍA; GÓMEZ-CHOVA, 2021; SHENDRYK et al., 2019; WAGNER et al., 2022) que as redes de segmentação semântica de aprendizagem profunda seguem sendo aplicadas para a mapear feições de interesse em imagens de diferentes resoluções. Todavia, nota-se a lacuna de se avaliar o potencial das redes de DL em segmentar vegetação arbórea em contexto urbano em imagens orbitais PlanetScope Scope. Estas imagens são de alta resolução espacial (3 metros) e podem auxiliar em estudos de planejamento urbano, assim como em recuperação de áreas degradadas, os quais exigem mapas acurados de distribuição da vegetação arbórea.

Dessa forma o objetivo desse trabalho foi realizar o mapeamento de fragmentos de vegetação arbórea em área urbana utilizando diferentes técnicas de inteligência artificial. Foram utilizadas duas redes de aprendizagem profunda e um algoritmo de aprendizagem de máquina. Assim foram realizados três experimentos caracterizando o desempenho dessas abordagens (rasa e profunda) na tarefa proposta.

## **METODOLOGIA**

O comportamento espectral da vegetação sofre alterações ao decorrer do ano, tornando-se mais ou menos verde conforme a disponibilidade de água no ambiente onde está inserida (THOMA et al., 2016), essa alteração também pode ser notada pela variação do NDVI (Índice de Vegetação de Diferença Normalizada) durante o ano (NIU et al., 2021; PAIVA ALCOFORADO REBELLO et al., 2020). Uma vez sabendo que o comportamento espectral da vegetação varia no decorrer do ano, a hipótese levantada nesse trabalho é que o uso de imagens de diferentes datas no treinamento das redes proporciona maior aprendizado, portanto, melhor desempenho do modelo na segmentação das regiões arbóreas em imagens orbitais. Para tanto, no primeiro experimento (Experimento 1 - Segmentação de fragmentos de vegetação arbórea com redes de aprendizagem profunda) foi realizado o treinamento e teste de duas redes profundas utilizando um conjunto de imagens PlanetScope de quatro datas distintas. Assim, imagens de diferentes datas foram misturadas no treinamento das redes, e imagens de diferentes datas compuseram o conjunto de teste.

Para verificar se o uso de um conjunto de dados de diferentes datas traz maior capacidade de generalização das redes foi realizado um segundo experimento, denominado “Experimento 2 - Segmentação de fragmento de vegetação arbórea com a rede DeepLabV3+”. Nesse experimento, a rede que teve melhor desempenho no experimento 1 foi retreinada, mas dessa vez foram realizados quatro treinamentos. Em cada treino e teste, utilizaram-se imagens de apenas uma data. Assim, como se tem dados de quatro datas, fez-se necessário quatro treinamentos independentes.

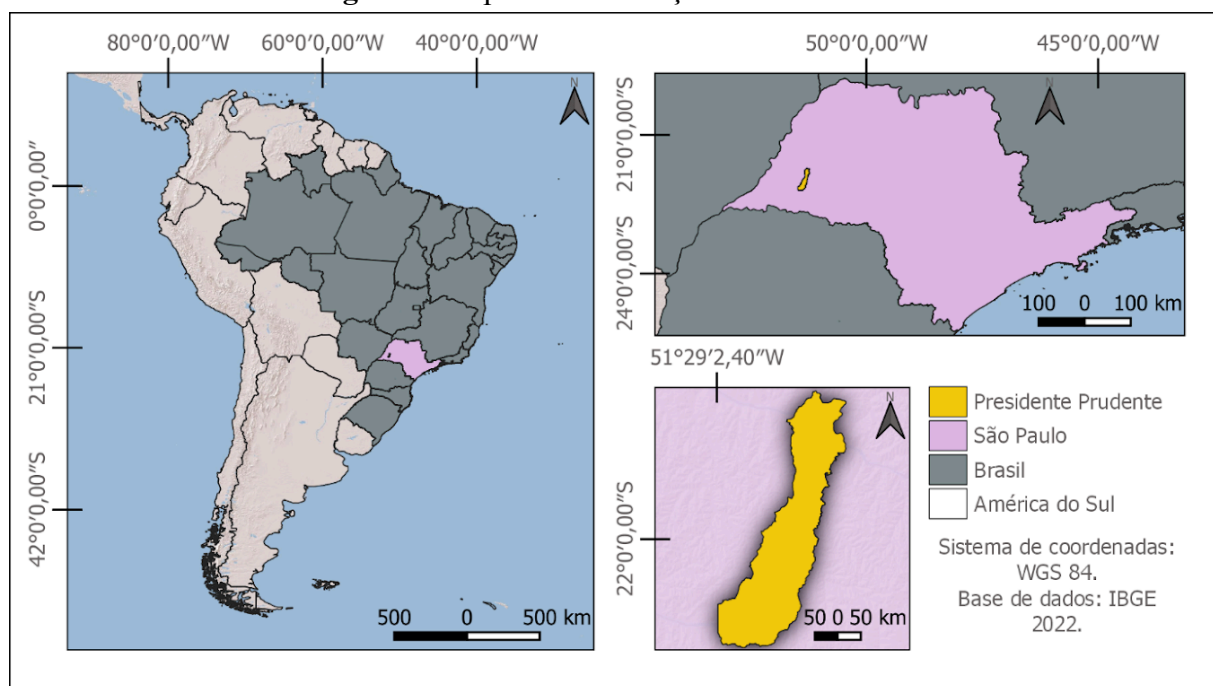


Por fim, foi realizado um terceiro experimento: “Experimento 3 - Segmentação de fragmento de vegetação arbórea por aprendizagem de máquina rasa”. O intuito desse experimento foi avaliar se o problema de mapeamento arbóreo urbano em imagens orbitais multiespectrais exige métodos mais complexos, como as redes profundas de segmentação semântica, ou se a aprendizagem rasa é o suficiente para essa tarefa. Nesse terceiro experimento foram utilizadas imagens de múltiplas datas para o treinamento e teste do algoritmo, similar ao aplicado no experimento 1.

### Área de estudo

A área de estudo abordada nesse trabalho localiza-se na cidade de Presidente Prudente, cidade essa situada na porção oeste do estado de São Paulo (Figura 1). De acordo com o IBGE, essa cidade possui uma área territorial equivalente a 560,637 km<sup>2</sup>, sua população total é de 225.668 pessoas, e sua densidade demográfica é de 402,52 hab./km<sup>2</sup> (“Presidente Prudente (SP) | Cidades e Estados | IBGE”, 2023).

**Figura 1-**Mapa de Localização área de estudo



Fonte: Base cartográfica limite dos países da América do Sul na escala 1:250.000, limite das unidades da federação na escala 1:4.000.000, municípios na escala 1:250.000 disponível no site do IBGE.

O bioma presente na região da área de estudo é predominantemente Mata Atlântica, com áreas de transição com o Cerrado. Sua vegetação é caracterizada como Floresta Estacional Semidecídua em área de transição com Cerrado de acordo com o Plano Municipal de Conservação e Recuperação da Mata Atlântica e Cerrado de Presidente Prudente -SP (SANDRA STEINMETZ et al., 2018).

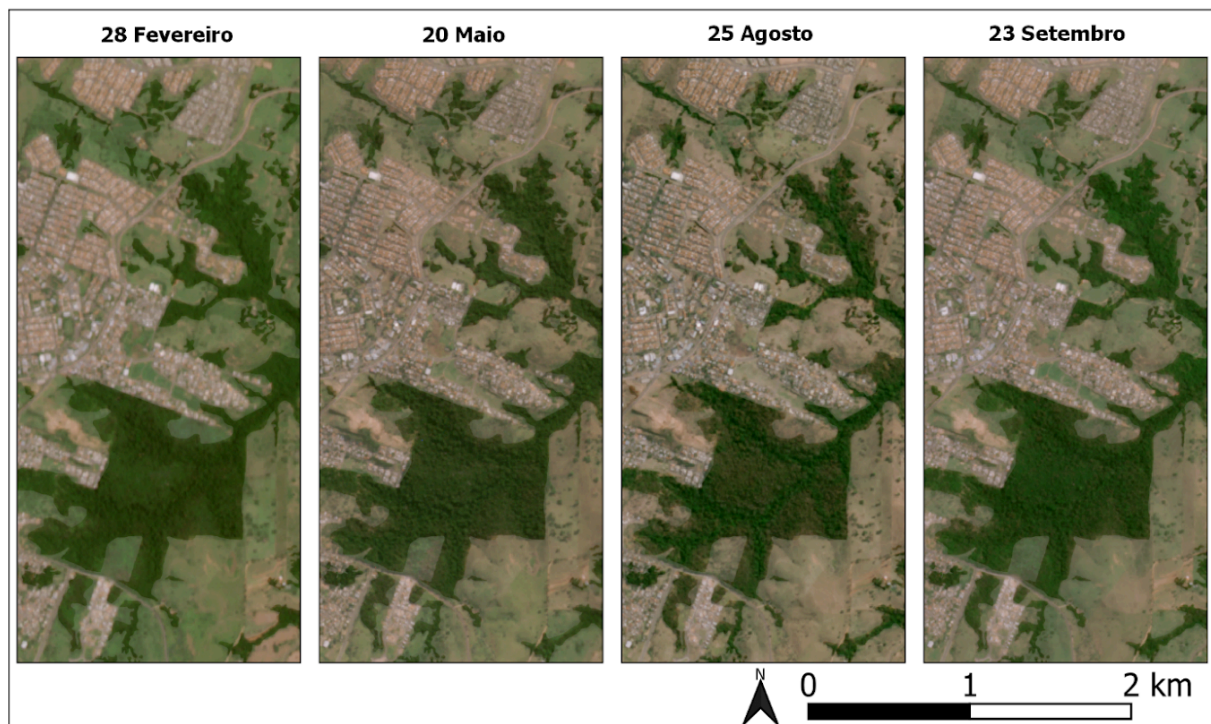


## Preparação dos dados

Para a realização deste trabalho, foram utilizadas as imagens PlanetScope Ortho Analytic 4B SR (PlanetScope Team, 2024). Essas imagens são georreferenciadas e adquiridas em quatro bandas: vermelho, verde, azul e infravermelho próximo (R-G-B-NIR). A resolução espacial é de aproximadamente 3 metros e a temporal é diária. Outra característica importante é que as imagens são disponibilizadas como um dado *ready-to-use* (PlanetScope Team, 2024), ou seja, são disponíveis já com as etapas de calibração radiométrica e correção atmosférica das cenas realizadas, o que é essencial quando o mapeamento ocorre em áreas recobertas por mais de uma cena ou em diferentes datas.

Foi definida uma imagem para cada estação do ano de 2022, sempre escolhendo aquela que tinha menor índice de nuvens (abaixo de 10%). Assim foram selecionadas imagens nas seguintes datas (Figura 2): 28 de fevereiro (verão), 20 de maio (outono) 25 de agosto (inverno) e 23 de setembro (primavera). O protocolo de se definir imagens de diferentes datas foi garantir ao experimento um conjunto de dados representativo das nuances espectrais e espaciais do alvo de interesse (regiões arbóreas) em diferentes momentos do ano. Isso é fundamental para se caracterizar a capacidade de adaptação de domínio dos modelos de aprendizagem de máquina (rasa ou profundo).

Figura 2- Imagens PlanetScope adquiridas em diferentes datas representando as distintas estações do ano na área em estudo.



Fonte: Autores, 2023.

Após a obtenção das imagens, foi iniciado o preparo do conjunto de dados para os experimentos com os algoritmos. Na primeira etapa, foi criada uma malha de polígonos,




também denominados de patches, totalizando 66 patches com dimensões de  $256 \times 256$  pixels, distribuídos pela área urbana de Presidente Prudente - SP. Na definição de cada patch, foi garantido a presença de ambas as classes, a classe de interesse ('fragmento de vegetação arbórea') e a classe de fundo ('não vegetação arbórea'). Esse equilíbrio é importante para garantir que os modelos tenham exemplos de ambas as classes durante a fase de treinamento. Cada imagem PlanetScope foi recortada utilizando os patches como limite. Os patches representam pacote de dados.

Em sequência fez-se a rotulação, isto é, a vetorização manual, das regiões arbóreas nas imagens PlanetScope em cada um dos patches. Esse é um trabalho minucioso e oneroso, mas essencial para coletar exemplos dos alvos que os modelos devem aprender a reconhecer nas imagens. Todo esse processo de anotação dos fragmentos de vegetação arbórea nas imagens foi realizado no software QGIS 3.3. Cada patch era composto por duas classes: "fragmento de vegetação arbórea" (classe de interesse) e "não vegetação arbórea" (classe outra).

A Figura 3 exemplifica como foi realizada a rotulação (vetorização manual). Em razão da resolução espacial das imagens PlanetScope, árvores isoladas não foram anotadas, sendo, portanto, a classe de fragmento de vegetação arbórea caracterizada por aglomerados de árvores. A classe "não vegetação arbórea" engloba as demais classes de uso do solo, como pastagem, corpo d'água, área urbanizada, solo exposto, culturas agrícolas, ruas, estradas, entre outras. A escala de visualização das imagens para a interpretação visual e anotação manual da classe de interesse variou entre 1:2.500 e 1:4.000.

**Figura 3-** Exemplo de rotulação dos fragmentos de vegetação arbórea.



Fonte: PlanetScope, adaptado pelos autores, 2023.

Os patches (total de 66) foram separados em dois grupos: treino e validação, e teste. Um total de 80% dos patches foi destinado para o treino e validação (10% dos 80%) dos algoritmos, e os 20% restantes para o teste. Esse protocolo foi mantido para os três algoritmos utilizados no trabalho, DeepLabV3+, U-Net e Random Forest. O intuito foi contrastar o desempenho dessas técnicas conforme é recorrente em trabalhos correlatos (CRUZ; OLIVEIRA, 2021; IMANI, 2020; SHEYKHMUSA et al., 2020) e verificar se a tarefa em questão é um problema de aprendizagem profunda ou pode ser resolvida por abordagem de aprendizagem rasa. Sabe-se que as redes de aprendizagem profunda exigem uma enorme quantidade de dados de treinamento, mas que a complexidade da tarefa é o que determina a abordagem necessárias. Se técnicas de aprendizagem rasa apresentarem desempenho similar



às redes profundas, entende-se que haverá uma economia de tempo e dinheiro por se utilizar aprendizagem rasa.

Cabe ressaltar que todos os experimentos foram conduzidos no ArcGIS Pro 3.1. No caso das redes profundas fez-se necessário utilizar o complemento “*Deep Learning Libraries for ArcGIS*”, e para o algoritmo *Random Forest* as ferramentas de classificação de imagens no ArcGIS Pro.

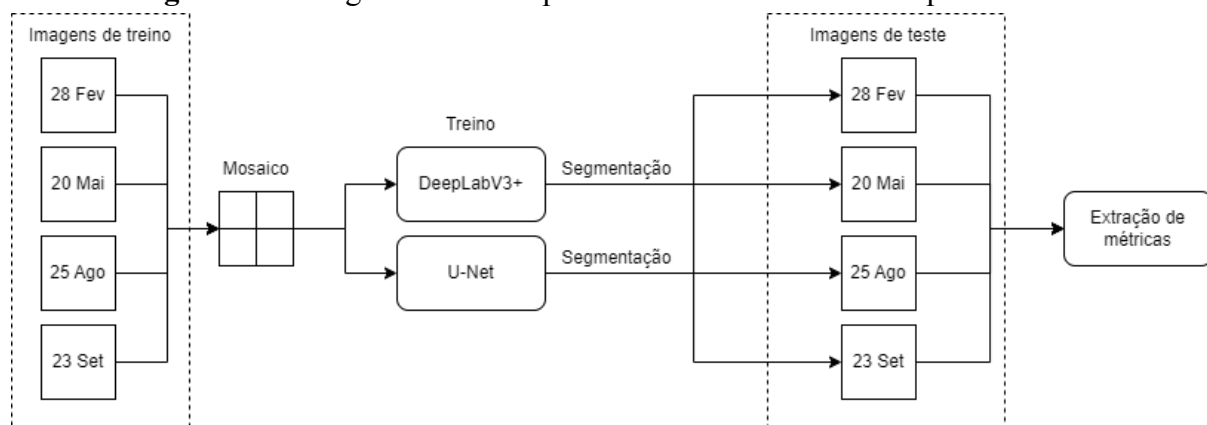
### Treinamento e validação

Como descrito anteriormente esse trabalho é composto por três experimentos, esses conduzidos com redes de aprendizagem profunda DeepLabV3+, U-Net e o algoritmo de aprendizagem de máquina Random Forest.

### Experimento 1. Segmentação de fragmentos de vegetação arbórea com redes de aprendizagem profunda.

No primeiro experimento, fez-se o treinamento das redes profundas com um conjunto de imagens com quatro bandas espectrais (RGB + NIR) capturadas em diferentes datas. Para isso, foram utilizados um total de 66 patches, sendo 80% destinados ao treinamento/validação das redes e 20% reservados para teste. A metodologia adotada nesse experimento está representada na Figura 4.

Figura 4- Fluxograma adotado para o desenvolvimento do experimento 1.



Fonte: Autores, 2024.

Os hiperparâmetros disponíveis para configuração no ArcGIS Pro na fase de treinamento das redes de aprendizagem profunda são batch size, max epochs, mixup, focal loss, chip size. O batch size é o número de amostras (patches) que são processadas em cada iteração da rede, sendo uma época o tempo que a rede leva para ver, pelo menos uma vez, todos os patches de treinamento. A cada época ocorre a atualização dos parâmetros (pesos) da rede por um processo de *back propagation* (ZHANG et al., 2019). Nos experimentos realizados esse hiperparâmetro foi definido como 8, valor esse que permitiu a rede aprender sem grande demanda computacional. Nos testes empíricos, observou-se que valores maiores



não trouxeram maior desempenho para a rede, mas exigiram um tempo maior para conclusão do treinamento.

O hiperparâmetro max epochs, ou número máximo de épocas, define a quantidade de vezes com que o treinamento trabalhará com todo o conjunto de dado antes de finalizar a aprendizagem, quanto maior o número de épocas maior será o tempo de processamento para a conclusão treino. Esse hiperparâmetro tem grande importância para a aprendizagem do modelo treinado, sendo que poucas épocas estão associadas a baixas aprendizagem (SANTOS et al., 2020). Após a realização de diversos testes, observou-se que a utilização de menos de 30 épocas resultava em baixa precisão, enquanto o aumento para além desse número não proporcionava melhorias significativas nos parâmetros avaliados. Portanto, neste estudo, 30 épocas foi a configuração adequada para a max epochs.

O hiperparâmetro mixup é uma estratégia de aumento de dados (*data augmentation*) utilizada para melhorar o treinamento do modelo (Fu et al., 2019). O mixup é uma técnica proposta por Zhang et al. (2017), que cria amostras de treinamento artificiais ao fazer uma combinação linear de pares de imagens e seus respectivos rótulos. Essa estratégia de aumento de dados tem sido empregada com recorrência em trabalhos com dados de sensoriamento remoto e foi empregada no presente estudo, visto que apenas 66 patches (de 256x256 pixels), totalizando aproximadamente 4 milhões de pixels, foram utilizados para representar exemplos das classes de interesse e da classe outra. Esse é um número reduzido de dados na abordagem de aprendizagem profunda.

Focall loss é uma função que tem como objetivo diminuir o impacto do desbalanceamento entre as classes do conjunto de treinamento (KUNANG et al., 2021). Quando essa função está ativa, o treinamento dará mais peso as classes que estão em desequilíbrio. Considerando que o conjunto de dados empregado no treinamento tem um bom balanceamento entre as duas classes, esse hiperparâmetro foi desabilitado buscando não aumentar consideravelmente a demanda de hardware. O hiperparâmetro chip size, refere-se ao tamanho do recorte de cada imagem. Esse parâmetro foi definido como o tamanho de 256x256 pixels.

Todos os hiperparâmetros mencionados anteriormente foram mantidos iguais para as duas redes nos experimentos realizados. Entretanto, existe um aspecto que é diferente para as duas redes, o Backbone. Esse se trata da parte inicial da rede neural profunda responsável por extrair características (features) de baixo e médio nível dos dados de entrada, como bordas, texturas, formas, padrões intermediários etc. Essa parte da rede é geralmente composta por várias camadas convolucionais e de pooling (no caso de redes convolucionais), e é pré-treinada em grandes conjuntos de dados, como ImageNet, para aprender uma representação genérica do domínio dos dados, sendo inserida no treinamento para aprimorar o desempenho do segmentador final. A utilização do Backbone é capaz de aprimorar a capacidade de extração de recursos importantes, evitar interferência de erros e dados pouco relevantes durante seu treinamento, aprimorando o desempenho final da rede (CHEN; WEI; ZHENG, 2023).



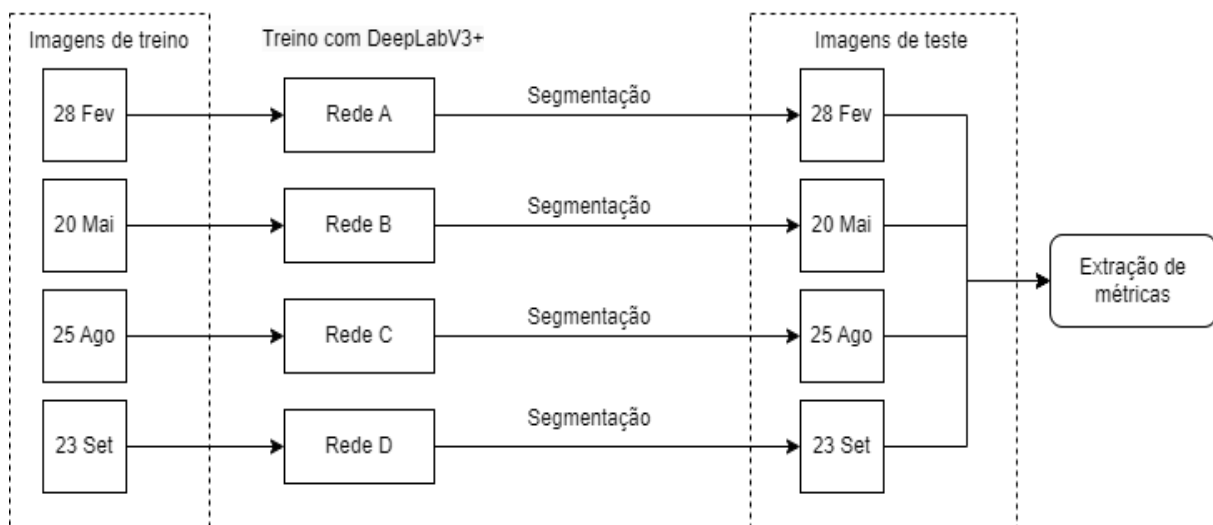
Na rede DeepLabV3+ considerou-se como backbone a ResNet-18, pois este apresenta bons resultados e demanda baixo tempo de treinamento, comparado ao uso de outros backbones, como ResNet-50 e Mobilenetv2 (ZHU et al., 2022). O modelo U-Net foi treinado com o uso do backbone Resnet-34, essa combinação de modelo e backbone provou ser capaz de gerar bons resultados mesmo em treinamentos com conjunto de dados pequenos (SOUZA; LÉLIS; SILVA, 2021).

## Experimento 2 – Segmentação de fragmentos de vegetação arbórea com a rede DeepLabV3+

No segundo experimento, a rede DeepLabV3+ foi treinada quatro vezes. A metodologia empregada nesse experimento é apresentada na Figura 5. A escolha dessa rede se deve aos resultados obtidos no experimento 1, onde essa foi a rede de melhor desempenho na tarefa proposta, conforme será mostrado e discutido na seção de resultados.

Para cada treino e teste, em um total de quatro, utilizou-se um conjunto de 43 patches de uma mesma data. Desses, 80% foram utilizados para treinar/validar a rede DeepLabV3+ e 20% para testá-la. Assim, nesse experimento 2, obteve-se quatro modelos de segmentação, denominados de Rede A, Rede B, Rede C e Rede D, conforme mostra a Figura 5.

Figura 5-Fluxograma experimento 2.



Fonte: Autores, 2024.

## Experimento 3 - Segmentação de fragmento de vegetação arbórea por aprendizagem de máquina rasa

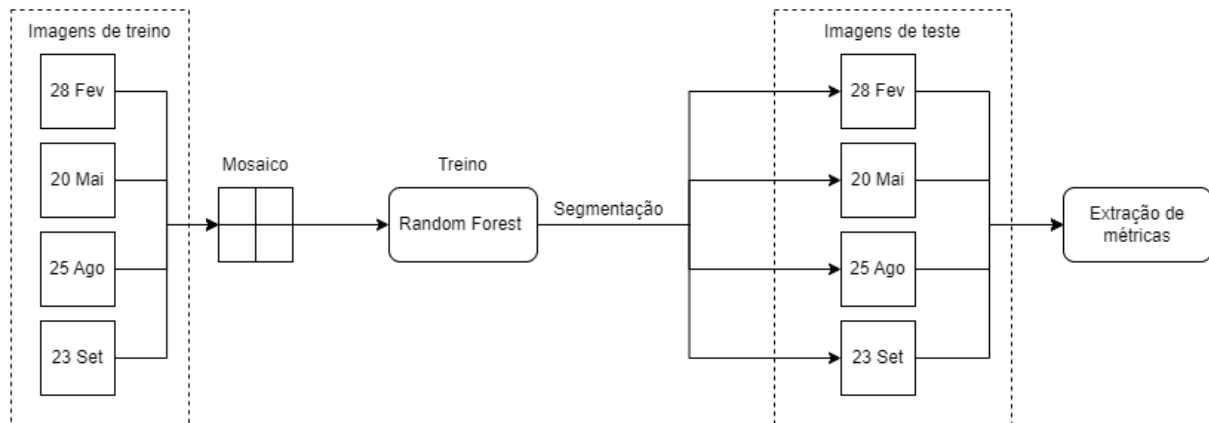
O terceiro e último experimento, diferentemente dos anteriores, baseou-se no uso de um algoritmo de aprendizagem de máquina rasa para a realização da segmentação da vegetação arbórea nas imagens PlanetScope. O algoritmo utilizado foi o Random Forest,



apresentado em 2001 por Leo Breiman, e considerado um modelo preditivo muito versátil (BREIMAN, 2001), sendo aplicado em várias áreas, incluindo o sensoriamento remoto. Comparado a outros modelos, o Random Forest apresenta melhor desempenho, inclusive em situações em que a quantidade de dados para treinamento é limitada, além de não exigir grande demanda computacional (CRUZ; OLIVEIRA, 2021; LAPINI et al., 2020).

Cabe ressaltar que o Randon Forest foi treinado com o mesmo conjunto de dados utilizado no experimento 1. Assim, dos 66 patches, 80% deles foram reservados para o treinamento enquanto os outros 20% foram destinados para o teste.

**Figura 6-** Fluxograma experimento 3.



Fonte: Autores, 2024.

No ArcGIS Pro, ao realizar o treinamento de um modelo utilizando o algoritmo Random Forest, é necessário configurar adequadamente alguns hiperparâmetros que impactam diretamente no desempenho do modelo. Entre os principais, destacam-se (BREIMAN, 2001):

1. Número de árvores (*n\_estimators*): Este hiperparâmetro define a quantidade de árvores de decisão que compõem a floresta. Um número maior de árvores tende a melhorar a estabilidade e a precisão do modelo, pois reduz a variância. No entanto, isso também pode aumentar o tempo de processamento, sendo necessário encontrar um equilíbrio entre desempenho e custo computacional.
2. Profundidade máxima das árvores (*max\_depth*): Controla o número máximo de níveis (ou splits) que cada árvore pode ter. Limitar a profundidade é uma forma eficaz de evitar overfitting, pois árvores muito profundas tendem a se ajustar demais aos dados de treinamento, perdendo capacidade de generalização. A escolha desse valor deve ser feita com base em testes e validação cruzada.
3. Número máximo de amostras (*max\_samples*): Define a quantidade de amostras de treinamento utilizadas para treinar cada árvore individual. Esse parâmetro está relacionado ao processo de *bootstrap* (amostragem com reposição), essencial para a diversidade entre as árvores da floresta. Ajustá-lo adequadamente pode melhorar a robustez e a capacidade de generalização do modelo.



Ressalta-se que os hiperparâmetros são definidos manualmente antes do treinamento e controlam o comportamento do algoritmo. Alguns exemplos de hiperparâmetros: número de árvores, profundidade, taxa de aprendizado. Enquanto os parâmetros são ajustados automaticamente pelo modelo durante o treinamento, com base nos dados. Os pesos de uma rede neural, os coeficientes de uma regressão linear, a estrutura de cada árvore, as divisões nos nós ou as regras de decisão no algoritmo Random Forest são exemplos de parâmetros (Probst et al. 2018).

A determinação da melhor combinação de parâmetros irá depender das características do problema que está sendo tratado. Para obtenção da melhor combinação de hiperparâmetros para esse experimento foi realizado vários testes e cada um dos treinamentos realizados foram avaliados por suas métricas de validação, assim para esse trabalho a melhor combinação de hiperparâmetros foi 100 para número máximo de árvores, 50 para profundidade máxima das árvores e 1500 para quantidade máxima de amostras por classe.

### **Avaliação de desempenho das redes profundas e algoritmo Random Forest.**

A avaliação do desempenho dos modelos nos diferentes experimentos (1, 2 e 3) foi conduzida com as principais métricas para a tarefa de segmentação semântica, conforme recomenda a literatura (FRANCIS; SIDIROPOULOS; MULLER, 2019a; PONT-TUSET; MARQUES, 2013; SUN et al., 2022; ZHANG et al., 2015). Essas métricas são extraídas da matriz de confusão, sendo elas: precisão, Recall, F1-Score e acurácia (MELKI et al., 2022). Vale ressaltar que para analisar cada métrica foram levados em consideração todos os pixels gerados pela segmentação, essa decisão permite uma avaliação mais rigorosa do desempenho dos modelos.

A precisão é uma métrica que indica a capacidade do modelo em identificar corretamente os pixels classificados como “fragmentos de vegetação arbórea”. Ela mede a proporção de predições positivas corretas em relação ao total de predições positivas realizadas pelo modelo. Matematicamente, a precisão é definida como a razão entre o número de verdadeiros positivos (TP) e a soma dos verdadeiros positivos com os falsos positivos (FP), conforme mostrado na fórmula a seguir:

$$Precisão = \frac{TP}{TP + FP}$$

A métrica Recall (também chamada de sensibilidade) representa a proporção de pixels de vegetação que foram corretamente identificados pelo modelo em relação ao total de pixels que realmente são vegetação no conjunto de dados. Em outras palavras, mede a capacidade do modelo de recuperar todos os pixels relevantes da classe “vegetação”. A fórmula do Recall é dada pela razão entre os verdadeiros positivos e a soma dos verdadeiros positivos com os falsos negativos (FN), conforme a seguinte expressão:

$$Recall = \frac{TP}{TP + FN}$$



O F1-score é uma métrica que combina a precisão e o recall em um único valor, fornecendo uma medida balanceada do desempenho do modelo. Ele é especialmente útil quando há desequilíbrio entre as classes. O F1-score é a média harmônica entre a precisão e o recall, calculado pela fórmula (FRANCIS; SIDIROPOULOS; MULLER, 2019b):

$$F1 = 2 * \frac{Precisão * Recall}{Precisão + Recall}$$

A acurácia é uma das métricas mais comuns para avaliar o desempenho de modelos em tarefas de segmentação. Ela é definida como a proporção de predições corretas feitas pelo modelo em relação ao total de pixels da imagem, considerando tanto os verdadeiros positivos quanto os verdadeiros negativos.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN}$$

## RESULTADOS E DISCUSSÃO


### Resultado Experimento 1. Mapeamento de fragmentos de vegetação arbórea por redes de segmentação semântica.

Os resultados obtidos com a rede DeepLabV3+ (Figura 7) mostram uma alta acurácia (entre 0,93 e 0,94) na capacidade de classificação de regiões arbóreas em imagens PlanetScope. A precisão oscilou entre 0,80 e 0,85, atingindo seu pico nas imagens do mês de maio, o que pode indicar uma redução na ocorrência de falsos positivos. O recall manteve-se na faixa de 0,76 a 0,8, evidenciando estabilidade na recuperação correta das áreas vegetadas. O F1-Score, que equilibra precisão e recall, apresentou valores entre 0,79 e 0,8, reforçando a consistência do desempenho da rede na tarefa. Esses resultados indicam que o modelo DeepLabV3+ manteve um desempenho consistente ao longo do período analisado. As pequenas variações observadas podem estar relacionadas às características específicas das imagens utilizadas, como condições de iluminação da cena ou mesmo diferenças sazonais na vegetação arbórea.

A Figura 8 apresenta as métricas obtidas na segmentação dos fragmentos de vegetação arbórea utilizando a rede U-Net. A análise comparativa demonstra que ambas as redes, DeepLabV3+ e U-Net, apresentaram desempenhos semelhantes, com acurácia variando de 0,92 a 0,93 para a U-Net. Em relação à precisão, a U-Net variou de 78% a 89%. Em imagens dos meses de agosto e setembro, a U-Net alcançou um pico de 0,89, superando a rede DeepLabV3+, o que pode sugerir uma redução na ocorrência de falsos positivos durante esses períodos.




**Figura 7** - Métricas de desempenho do modelo DeepLabV3+ nas imagens PlanetScope considerando o experimento 1.



Fonte: Autores, 2024.

A análise do recall revela diferenças significativas entre as duas abordagens. A U-Net apresentou maior variação, oscilando entre 0,64 e 0,80. Nos meses de agosto e setembro, o recall da U-Net foi inferior (0,64), sugerindo que a rede pode ter deixado de identificar algumas áreas vegetadas. Por fim, o F1-Score da U-Net apresentou uma variação maior, com valores entre 0,75 e 0,79. Essa diferença indica que a DeepLabV3+ conseguiu manter um equilíbrio mais consistente entre precisão e recall ao longo do período analisado. De modo geral, enquanto a DeepLabV3+ demonstrou maior estabilidade na segmentação, a U-Net se destacou pela alta precisão em determinados meses.

**Figura 8**- Métricas de desempenho do modelo U-Net nas imagens PlanetScope considerando o experimento 1.



Fonte: Autores, 2024.



## Resultados experimento 2 – Segmentação de fragmentos de vegetação arbórea com a rede de segmentação semântica DeepLabV3+.

Os resultados obtidos no experimento 2 estão apresentados na Tabela 1. Ressalta-se que esse experimento 2 foi conduzido somente com a rede DeepLabV3+, mas quatro modelos (denominados de Rede A, Rede B, Rede C e Rede D) baseados nessa rede foram obtidos, conforme explicado anteriormente. A partir da análise da Tabela 1, pode-se identificar algumas relações importantes no desempenho das redes de segmentação semântica. Os melhores resultados em valor de acurácia foram obtidos pelas redes B e C, indicando uma capacidade elevada na tarefa proposta. No entanto, ao analisar outras métricas, observa-se que o desempenho das redes varia.

A Rede B demonstrou um equilíbrio mais consistente entre precisão e recall, sugerindo uma capacidade de manter uma relação adequada entre falsos positivos e falsos negativos. Isso indica que o modelo conseguiu minimizar erros, evitando tanto classificações excessivas quanto omissões significativas. Em contraste, outras redes (A, C e D) apresentaram variações mais expressivas entre essas métricas, possivelmente devido a uma menor capacidade de generalização dos padrões aprendidos durante o treinamento.

**Tabela 1** – Métricas de desempenho nos testes realizados no experimento 2.

<b>Rede A. Experimento 2 (modelo treinado com imagem de 28/02/22)</b>				
<b>Inferência em</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>Recall</b>	<b>F1-Score</b>
28/02/2022	0,83	0,75	0,55	0,60
20/05/2022	0,86	0,91	0,56	0,69
25/08/2022	0,87	0,87	0,57	0,69
23/09/2022	0,87	0,87	0,57	0,69
<b>Rede B. Experimento 2 (modelo treinado com imagem de 20/05/22)</b>				
<b>Inferência em</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>Recall</b>	<b>F1-Score</b>
28/02/2022	0,83	0,63	0,84	0,73
20/05/2022	0,93	0,71	0,85	0,77
25/08/2022	0,92	0,64	0,88	0,74
23/09/2022	0,92	0,64	0,88	0,74
<b>Rede C. Experimento 2 (modelo treinado com imagem de 25/08/22)</b>				
<b>Inferência em</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>Recall</b>	<b>F1-Score</b>
28/02/2022	0,83	0,72	0,82	0,77
20/05/2022	0,93	0,80	0,79	0,80
25/08/2022	0,93	0,75	0,84	0,79
23/09/2022	0,93	0,75	0,84	0,79
<b>Rede D. Experimento 2 (modelo treinado com imagem de 23/09/22)</b>				
<b>Inferência em</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>Recall</b>	<b>F1-Score</b>
28/02/2022	0,89	0,87	0,63	0,73
20/05/2022	0,92	0,86	0,71	0,78
25/08/2022	0,92	0,65	0,87	0,75
23/09/2022	0,92	0,65	0,87	0,75

Fonte: Autores, 2024.




A métrica de F1-Score permaneceu em um intervalo entre 0,73 e 0,8, com exceção para a Rede A, refletindo um desempenho razoável na tarefa de segmentação das imagens. Além disso, ao correlacionar os dados com as datas das imagens utilizadas, observa-se uma tendência de que as redes apresentam melhores resultados ao segmentar imagens da mesma época em que foram treinadas. Isso reforça a hipótese de que as características visuais das imagens variam ao longo das estações do ano, impactando diretamente o desempenho dos modelos. Esse efeito pode ser atribuído a mudanças na iluminação, na composição das cenas e nas condições ambientais, tornando a segmentação mais desafiadora quando a rede precisa operar sobre imagens de períodos distintos. Ademais, sugere a necessidade de mais dados de treinamento para que os modelos aprendem maiores variações sazonais do alvo em estudo.

### Experimento 3 - Segmentação de fragmento de vegetação arbórea por aprendizagem de máquina rasa

O Random Forest apresentou acurácia e recall semelhantes aos obtidos nos experimentos 1 e 2 (Figura 9). Porém, é possível notar que os valores de precisão e F1-Score vão de 0,72 a 0,79, uma variação maior que no experimento 1.

**Figura 9** - Métricas de segmentação das imagens de teste utilizando Random Forest no experimento 3.



Fonte: Autores, 2024.

Um estudo conduzido por Ayhan e Kwan em 2020 (AYHAN; KWAN, 2020) apresenta vários experimentos com variadas técnicas de segmentação de imagens para segmentar diferentes classes de vegetação em imagens RGB. Nesse trabalho, o maior valor de acurácia obtido foi de 0,96 com a rede DeepLabV3+, e o menor valor foi de 0,81 com o algoritmo Random Forest. Outros estudos que empregam a rede U-Net na segmentação de vegetação em imagens RGB de alta resolução apresentam acurácia que varia de 0,84 a 0,9



(KATTENBORN; EICHEL; FASSNACHT, 2019; SARI et al., 2022). Esses resultados são semelhantes aos que foram obtidos no presente trabalho, sobretudo se considerado que imagens orbitais de 3m de resolução espacial foram consideradas. Isso reforça a capacidade das redes de segmentação semântica em extrair áreas de vegetação arbórea em cenários complexos como são as cidades.

Quanto aos resultados especificamente com o algoritmo Random Forest, nota-se que o modelo teve dificuldades na tarefa. Um estudo similar (CANO; MARCATO JUNIOR, 2021) obteve resultados melhores (Tabela 2), indicando a instabilidade desse modelo nas tarefas de segmentação de vegetação arbóreas em imagens orbitais.

O Random Forest teve grande dificuldade em segregar árvores de gramíneas, e isso se deve à alta similaridade espectral entre esses alvos nas imagens multiespectrais. Mesmo combinado imagens de diferentes datas, para se aumentar a variabilidade espectral do alvo de interesse, o modelo não conseguiu lidar de forma eficiente com a situação problema em questão.

**Tabela 2 – Comparativo experimento 3**

Métricas	Cano, Marcato Junior, 2021	Experimento 3.
Acurácia	0,94	0,91
Precisão	0,90	0,68
F1-Score	0,85	0,72

Fonte: Adaptado pelos autores, 2024.

## CONSIDERAÇÕES FINAIS

Este trabalho investigou o desempenho de redes de aprendizagem profunda e de um algoritmo clássico de aprendizagem de máquina (Random Forest) na tarefa de mapeamento de fragmentos de vegetação arbórea em áreas urbanas, utilizando imagens orbitais multiespectrais. Os resultados permitiram identificar pontos fortes e limitações de cada modelo, de acordo com os diferentes delineamentos experimentais adotados. Observou-se que a variação sazonal e as diferenças no comportamento espectral da vegetação arbórea impactaram o desempenho dos modelos — especialmente no caso do Random Forest, cuja sensibilidade a essas variações foi mais evidente

A utilização de um conjunto de dados multitemporal para o treinamento dos algoritmos mostrou-se uma estratégia importante para ampliar a variabilidade dos exemplos apresentados durante o aprendizado, visando favorecer a capacidade de generalização dos modelos. No entanto, observa-se que o volume total de dados de treinamento ainda é limitado, especialmente quando se trata de redes neurais profundas, que normalmente demandam grandes quantidades de dados para atingir alto desempenho.

Entre os três experimentos realizados, observou-se que o modelo DeepLabV3+ apresentou o melhor desempenho em dois deles, com destaque para o experimento 1, no qual a rede foi treinada com dados multitemporais. Nessa configuração, o modelo demonstrou maior robustez frente às variações espectrais, evidenciando a importância de treinar com dados representativos das diferentes condições fenológicas da vegetação.



As imagens PlanetScope Scope distribuídas pela iniciativa NICFIAE (*Norway's international climate and Forests Initiatives Satellite Data Program*) tem uma resolução temporal mensal, e resolução espacial de 5 m. Apesar dessas resoluções serem inferiores as usadas nesse trabalho, essas imagens ainda podem ser consideradas uma ótima fonte de dados para estudos ambientais. Essas imagens já são amplamente exploradas em estudos ambientais voltados a detecção de desmatamento e na produção de mapas de uso e cobertura da terra (DALAGNOL et al., 2023; MASOLELE et al., 2022; ZHANG et al., 2023). No entanto, a escassez de estudos focados em áreas urbanas evidencia uma lacuna científica em relação ao seu potencial para detecção de vegetação arbórea urbana, e o presente trabalho contribui nesse sentido.

Os resultados obtidos neste trabalho indicam que a combinação das imagens PlanetScope com técnicas de segmentação baseadas em redes de aprendizagem profunda possui grande potencial para aplicações urbanas. A estratégia explorada no presente trabalho possibilita a produção de dados geoespaciais importantes para o desenvolvimento de ações de planejamento urbano, apoiando iniciativas públicas voltadas à gestão sustentável das cidades.

### AGRADECIMENTOS

Agradecemos ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo apoio financeiro mediante os processos 305814/2023-0, 403213/2023-1, 308481/2022-4, 305296/2022-1.

### REFERÊNCIAS BIBLIOGRÁFICAS

- BARBOZA, E. N.; ALENCAR, G. S. D. S.; ALENCAR, F. H. H. D. A arborização melhora o conforto térmico em áreas urbanas: O caso de Juazeiro do Norte, Ceará. *Research, Society and Development*, v. 9, n. 6, p. e105963691, 19 abr. 2020.
- BECKETT, K. P.; FREER-SMITH, P. H.; TAYLOR, G. Particulate pollution capture by urban trees: effect of species and windspeed: PARTICULATE POLLUTION UPTAKE BY TREES. *Global Change Biology*, v. 6, n. 8, p. 995–1003, dez. 2000.
- BORDIM, M. H. S.; LONGO, R. M.; BORDIM, B. S. Urban environmental sustainability: analysis of the influence of vegetation in environmental parameters. M. H. S., 2022.
- BREIMAN, L. Random Forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 1 out. 2001.
- CHEN, S.; WEI, X.; ZHENG, W. ASA-DRNet: An Improved Deeplabv3+ Framework for SAR Image Segmentation. *Electronics*, v. 12, n. 6, p. 1300, 8 mar. 2023.
- COSTA, A. S.; FRANCO, I. M.; MARTORANO, L. G. TERMOGRAFIA INFRAVERMELHA EM SOBREVOLVO OBLÍQUO PARA INDICAR EFEITOS DA VEGETAÇÃO URBANA NA REGULAÇÃO TÉRMICA EM BELÉM, PARÁ. *Caderno de Geografia*, p. 17, 2022.
- CRISTAL DE ARAÚJO ALMEIDA, B.; SILVA BIZZO LIMA, I.; ALEXANDRE CARDOSO CANTUÁRIA, G. A. Influência da vegetação nas áreas residenciais de Brasília. Programa de Iniciação Científica - PIC/UniCEUB - Relatórios de Pesquisa, 29 abr. 2021.
- CRUZ, U. R. X. D.; OLIVEIRA, L. P. D. Comparativo entre os métodos de classificação MaxVer e Random Forest utilizando imagem Sentinel-2B. *CADERNOS DO LESTE*, v. 21, n. 21, 2021.



DALAGNOL, R. et al. Mapping tropical forest degradation with deep learning and PlanetScope NICFI data. *Remote Sensing of Environment*, v. 298, p. 113798, dez. 2023.

DINIZ, F. R.; GONÇALVES, F. L. T.; SHERIDAN, S. Heat Wave and Elderly Mortality: Historical Analysis and Future Projection for Metropolitan Region of São Paulo, Brazil. *Atmosphere*, v. 11, n. 9, p. 933, 31 ago. 2020.

DONATO, C. R. et al. Análise de aspectos ecológicos da vegetação como ferramenta indicadora da conservação do entorno de cavernas em Laranjeiras, Sergipe. *Scientia Plena*, v. 14, n. 12, 21 jan. 2019.

FAYE, M. et al. Impact of different heat wave definitions on daily mortality in Bandafassi, Senegal. *PLOS ONE*, v. 16, n. 4, p. e0249199, 5 abr. 2021.

FERRINI, F. et al. Role of Vegetation as a Mitigating Factor in the Urban Context. *Sustainability*, v. 12, n. 10, p. 4247, 22 maio 2020.

FRANCIS, A.; SIDIROPOULOS, P.; MULLER, J.-P. CloudFCN: Accurate and Robust Cloud Detection for Satellite Imagery with Deep Learning. *Remote Sensing*, v. 11, n. 19, p. 2312, 6 out. 2019a.

FRANCIS, A.; SIDIROPOULOS, P.; MULLER, J.-P. CloudFCN: Accurate and Robust Cloud Detection for Satellite Imagery with Deep Learning. *Remote Sensing*, v. 11, n. 19, p. 2312, 6 out. 2019b.

FU, Y. et al. Mixup Based Privacy Preserving Mixed Collaboration Learning. 2019 IEEE International Conference on Service-Oriented System Engineering (SOSE). *Anais... Em: 2019 IEEE INTERNATIONAL CONFERENCE ON SERVICE-ORIENTED SYSTEM ENGINEERING (SOSE)*. San Francisco East Bay, CA, USA: IEEE, abr. 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8705780/>>. Acesso em: 28 maio. 2023

GARUANA, L. et al. Integração de indicadores ecológicos, ambientais e de saúde humana em microbacias urbanas. 1 jul. 2020.

GATTO, E. et al. Impact of Urban Vegetation on Outdoor Thermal Comfort: Comparison between a Mediterranean City (Lecce, Italy) and a Northern European City (Lahti, Finland). *Forests*, v. 11, n. 2, p. 228, 18 fev. 2020.

HAMILL, T. M. Comments on “Calibrated Surface Temperature Forecasts from the Canadian Ensemble Prediction System Using Bayesian Model Averaging”. *Monthly Weather Review*, v. 135, n. 12, p. 4226–4230, 1 dez. 2007.

IMANI, M. Random Forest with Attribute Profile for Remote Sensing Image Classification. 2020 International Conference on Machine Vision and Image Processing (MVIP). *Anais... Em: 2020 INTERNATIONAL CONFERENCE ON MACHINE VISION AND IMAGE PROCESSING (MVIP)*. Iran: IEEE, fev. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9116878/>>. Acesso em: 8 jun. 2023

KUNANG, Y. N. et al. Deep learning with focal loss approach for attacks classification. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, v. 19, n. 4, p. 1407, 1 ago. 2021.

KUSSUL, N. et al. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geoscience and Remote Sensing Letters*, v. 14, n. 5, p. 778–782, maio 2017.

LAPINI, A. et al. Comparison of Machine Learning Methods Applied to SAR Images for Forest Classification in Mediterranean Areas. *Remote Sensing*, v. 12, n. 3, p. 369, 22 jan. 2020.

LÓPEZ-PUIGDOLLERS, D.; MATEO-GARCÍA, G.; GÓMEZ-CHOVA, L. Benchmarking Deep Learning Models for Cloud Detection in Landsat-8 and Sentinel-2 Images. *Remote Sensing*, v. 13, n. 5, p. 992, 5 mar. 2021.

MASOLELE, R. N. et al. Using high-resolution imagery and deep learning to classify land-use following deforestation: a case study in Ethiopia. *GIScience & Remote Sensing*, v. 59, n. 1, p. 1446–1472, 31 dez. 2022.

MELKI, P. et al. Exploratory Analysis on Pixelwise Image Segmentation Metrics with an Application in Proximal Sensing. *Remote Sensing*, v. 14, n. 4, p. 996, 18 fev. 2022.



NIU, Y. et al. Estimating fractional vegetation cover of maize under water stress from UAV multispectral imagery using machine learning algorithms. *Computers and Electronics in Agriculture*, v. 189, p. 106414, out. 2021.

OKE, T. R. *Boundary layer climates*. Second edition ed. London: Routledge, 2009.

OSCO, L. P. et al. A review on deep learning in UAV remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, v. 102, p. 102456, out. 2021.

PAIVA ALCOFORADO REBELLO, V. et al. Spatiotemporal vegetation response to extreme droughts in eastern Brazil. *Remote Sensing Applications: Society and Environment*, v. 18, p. 100294, abr. 2020.

PLANET TEAM. *Planet application program interface: In Space for life on earth*. San Francisco, CA. 2024.

PONT-TUSET, J.; MARQUES, F. Measures and Meta-Measures for the Supervised Evaluation of Image Segmentation. 2013 IEEE Conference on Computer Vision and Pattern Recognition. *Anais... Em: 2013 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)*. Portland, OR, USA: IEEE, jun. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6619121/>>. Acesso em: 29 set. 2023

Presidente Prudente (SP) | Cidades e Estados | IBGE. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/sp/presidente-prudente.html>>. Acesso em: 8 set. 2023.

PROBST, P.; WRIGHT, M.; BOULESTEIX, ANNE-LAURE. Hyperparameters and Tuning Strategies for Random Forest. *arXiv*, 2018.

REZENDE, C. L. et al. From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. *Perspectives in Ecology and Conservation*, v. 16, n. 4, p. 208–214, out. 2018.

SANDRA STEINMETZ et al. Plano Municipal de Conservação e Recuperação da Mata Atlântica e Cerrado de Presidente Prudente SP. , 2018. Disponível em: <<https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKewjt1p27mOKBAxWMJ7kGHcXvAL4QFnoECAsQAQ&url=https%3A%2F%2Fwww.presidenteprudente.sp.gov.br%2Fsite%2Fdocumento%2F55059&usg=AOvVaw0PDJNhokY2e63zn4zMkaia&opi=89978449>>

SANTOS, C. F. G. DO et al. MaxDropout: Deep Neural Network Regularization Based on Maximum Output Values. *arXiv*, , 27 jul. 2020. Disponível em: <<http://arxiv.org/abs/2007.13723>>. Acesso em: 28 maio. 2023

SHENDRYK, Y. et al. Deep learning for multi-modal classification of cloud, shadow and land cover scenes in PlanetScope and Sentinel-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 157, p. 124–136, nov. 2019.

SHEYKHMOUSA, M. et al. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 13, p. 6308–6325, 2020.

SOLECKI, W. D. et al. Mitigation of the heat island effect in urban New Jersey. *Environmental Hazards*, v. 6, n. 1, p. 39–49, jan. 2005.

SOUZA, L. B. M. D.; LÉLIS, S. P. B. D.; SILVA, R. R. V. Avaliação de Redes de Segmentação de Deep Learning para Segmentar Melanoma. *Anais do XIV Encontro Unificado de Computação do Piauí (ENUCOMPI 2021)*. *Anais... Em: ENCONTRO UNIFICADO DE COMPUTAÇÃO DO PIAUÍ*. Brasil: Sociedade Brasileira de Computação, 23 nov. 2021. Disponível em: <<https://sol.sbc.org.br/index.php/enucompi/article/view/17750>>. Acesso em: 29 maio. 2023

SRIVASTAVA, N. et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. 2014.

SUN, C. et al. Individual Tree Crown Segmentation and Crown Width Extraction From a Heightmap Derived From Aerial Laser Scanning Data Using a Deep Learning Framework. *Frontiers in Plant Science*, v. 13, p. 914974, 14 jun. 2022.



TAKASHIMA-OLIVEIRA, T. T. G. et al. Modificações paisagísticas e implicações térmicas no distrito administrativo de Belém, Pará. *Revista Verde de Agroecologia e Desenvolvimento Sustentável*, v. 13, n. 3, p. 404, 1 jul. 2018.

THOMA, D. P. et al. Semi-arid vegetation response to antecedent climate and water balance windows. *Applied Vegetation Science*, v. 19, n. 3, p. 413–429, jul. 2016.

WAGNER, F. H. et al. Mapping Tropical Forest Cover and Deforestation with PlanetScope NICFI Satellite Images and Deep Learning in Mato Grosso State (Brazil) from 2015 to 2021. *arXiv*, 17 nov. 2022. Disponível em: <<http://arxiv.org/abs/2211.09806>>. Acesso em: 8 jun. 2023

WANG, J. et al. Significant effects of ecological context on urban trees' cooling efficiency. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 159, p. 78–89, jan. 2020.

ZHANG, X. et al. Segmentation quality evaluation using region-based precision and recall measures for remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 102, p. 73–84, abr. 2015.

ZHANG, Y. et al. Taming the Noisy Gradient: Train Deep Neural Networks with Small Batch Sizes. *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. Anais... Em: TWENTY-EIGHTH INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE {IJCAI-19}*. Macao, China: International Joint Conferences on Artificial Intelligence Organization, ago. 2019. Disponível em: <<https://www.ijcai.org/proceedings/2019/604>>. Acesso em: 28 maio. 2023

ZHANG, Y. et al. Monitoring monthly tropical humid forest disturbances with PlanetScope NICFI images in Cameroon. *Agricultural and Forest Meteorology*, v. 341, p. 109676, out. 2023.

ZHANG, Hongyi; CISSÉ, Moustapha; DAUPHIN, Yann N.; LOPEZ-PAZ, David. mixup: Beyond empirical risk minimization. *arXiv preprint arXiv:1710.09412*, 2017. Disponível em: <https://arxiv.org/abs/1710.09412>. Acesso em: 7 jun. 2025.

ZHU, R. et al. Semantic Segmentation Using DeepLabv3+ Model for Fabric Defect Detection. *Wuhan University Journal of Natural Sciences*, v. 27, n. 6, p. 539–549, dez. 2022.

## COMO CITAR ESTE TRABALHO

SILVA, Lucas Antônio et. al. Mapeamento de fragmentos arbóreos urbanos com imagens orbitais e aprendizagem profunda. *Revista Tamoios*, São Gonçalo, v. 21, n. 2, p. 165-185, 2025. Disponível em: <https://doi.org/10.12957/tamoios.2025.86644>. Acesso em: DD MMM. AAAA.