



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
CENTRO DE CIÊNCIAS MATEMÁTICAS E DA NATUREZA
INSTITUTO DE GEOCIÊNCIAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

RODRIGO GOMES DA SILVA

USO DE DEEP LEARNING PARA IDENTIFICAÇÃO DA ARBORIZAÇÃO NO
CONTEXTO DA REGIÃO METROPOLITANA DO RIO DE JANEIRO

Rio de Janeiro

2025

RODRIGO GOMES DA SILVA

USO DE DEEP LEARNING PARA IDENTIFICAÇÃO DA ARBORIZAÇÃO NO
CONTEXTO DA REGIÃO METROPOLITANA DO RIO DE JANEIRO

Dissertação apresentada ao Programa de
Pós-Graduação em Geografia do
Departamento de Geografia do Instituto de
Geociências, Universidade Federal do Rio
de Janeiro como requisito para a obtenção
do título de mestre em Geografia

Orientador: Profa. Dra. Carla Bernadete
Madureira Cruz

Rio de Janeiro

2025

FICHA CATALOGRÁFICA

CIP - Catalogação na Publicação

G586u Gomes da Silva, Rodrigo
 USO DE DEEP LEARNING PARA IDENTIFICAÇÃO DA
 ARBORIZAÇÃO NO CONTEXTO DA REGIÃO METROPOLITANA DO
 RIO DE JANEIRO / Rodrigo Gomes da Silva. -- Rio de
 Janeiro, 2025.
 72 f.

 Orientador: Carla Bernadete Madureira Cruz.
 Dissertação (mestrado) - Universidade Federal do
 Rio de Janeiro, Instituto de Geociências, Programa
 de Pós-Graduação em Geografia, 2025.

 1. Deep Learning. 2. Sensoriamento Remoto. 3.
 Arborização. 4. RMRJ. I. Madureira Cruz, Carla
 Bernadete, orient. II. Título.

Elaborado pelo Sistema de Geração Automática da UFRJ com os dados fornecidos
pelo(a) autor(a), sob a responsabilidade de Miguel Romeu Amorim Neto - CRB-7/6283.

RODRIGO GOMES DA SILVA

USO DE DEEP LEARNING PARA IDENTIFICAÇÃO DA ARBORIZAÇÃO NO
CONTEXTO DA REGIÃO METROPOLITANA DO RIO DE JANEIRO

Dissertação apresentada ao Programa de
Pós-Graduação em Geografia do
Departamento de Geografia do Instituto de
Geociências, Universidade Federal do Rio
de Janeiro como requisito para a obtenção
do título de mestre em Geografia.

Aprovada em: 01/09/2025.

BANCA EXAMINADORA

Prof. Dr. Carla Bernadete Madureira Cruz (Orientador)
Universidade Federal do Rio de Janeiro (UFRJ)

Prof. Dr. Raúl Sánchez Vicens
Universidade Federal Fluminense (UFF)

Prof. Dr. Andréa Franco de Oliveira
Instituto Estadual do Ambiente (INEA)

RESUMO

As áreas urbanas desempenham papel central nas mudanças climáticas, ao mesmo tempo em que sofrem fortemente seus impactos. Na Região Metropolitana do Rio de Janeiro (RMRJ), marcada por alta densidade populacional e intensa expansão urbana, a arborização exerce função essencial na mitigação de efeitos ambientais e na promoção da qualidade de vida. Contudo, sua mensuração em grande escala exige metodologias avançadas. Este estudo aplica técnicas de *deep learning* a dados de sensoriamento remoto para identificar e mapear a arborização no contexto da RMRJ. A pesquisa envolve: revisão do estado da arte sobre o uso de *deep learning* para detecção de vegetação em contexto urbano; avaliação do desempenho do modelo por métricas de acurácia; e análise quantitativa da distribuição da vegetação, considerando aspectos espaciais. Como resultado, obteve-se um ótimo desempenho do modelo criado, com altos valores de acurácia de acordo com os testes de desempenho, onde os valores de exatidão superam o valor de 0,9 em todas as medições.

Palavras-chave: Aprendizado profundo; Arborização urbana; Sensoriamento remoto..

ABSTRACT

Urban areas play a central role in climate change while also being strongly affected by its impacts. In the Rio de Janeiro Metropolitan Region (RMRJ), characterized by high population density and intense urban expansion, urban trees play an essential role in mitigating environmental effects and promoting quality of life. However, large-scale measurement of urban tree cover requires advanced methodologies. This study applies deep learning techniques to remote sensing data in order to identify and map urban tree cover in the RMRJ. The research involves: a review of the state of the art on the use of deep learning for vegetation detection in urban contexts; evaluation of model performance through accuracy metrics; and a quantitative analysis of vegetation distribution, considering spatial aspects. As a result, the model developed in this study achieved excellent performance, with high accuracy values in all evaluations, consistently exceeding 0.9 across all performance metrics.

Keywords: Deep learning; Urban tree cover; Remote sensing

SUMÁRIO

1. Introdução.....	14
2. Objetivos	17
3. Área de Estudo e justificativa	18
4. Revisão bibliográfica	21
4.1 Deep Learning	21
4.1.1 Deep learning: uma perspectiva histórica de desenvolvimento	21
4.1.2 Redes Neurais Artificiais.....	25
4.1.3 Redes Neurais Convolucionais.....	26
4.1.3.1 Convolução	27
4.1.3.2 Função de ativação não-linear	29
4.1.3.3 Operação pooling	29
4.2 Mapeamento de vegetação em ambiente urbanizado	30
4.2.1 Cobertura vegetal em contexto urbano: uma breve revisão conceitual .	30
4.2.2 Mapeamento de cobertura vegetal urbana	33
5. Primeiro capítulo: Aprendizagem profunda e identificação de vegetação em contexto urbano: Um estado da arte	35
5.1 Introdução	35
5.2 Processos metodológicos	36
5.3 Resultados e estatísticas iniciais	37
5.4 Discussão	41
6. Segundo Capítulo: Identificação de arborização urbana no contexto da RMRJ	44
6.1 Objetivos	44
6.2 Operacionalização	44
6.2.1 Dados e softwares utilizados	45
6.2.1.2 Projeto espacial Planet.....	45
6.2.1.3 Softwares e plataformas.....	48
6.2.2 Coleta de amostras	49
6.2.3 Processamento dos dados.....	52
6.2.4 U-Net: a arquitetura de rede neural convolucional utilizada.....	53
6.2.5 Validação do produto	58
6.3 Resultados e discussões	60

7. Considerações finais	76
8. Referências bibliográficas.....	76

1. INTRODUÇÃO

Ambientalmente, as mudanças climáticas são o principal produto gerado por ações antrópicas nos últimos cem anos (Braga, 2012). As grandes cidades, nesse sentido, são palco das principais atividades que fomentam tais alterações no clima, mas, em contrapartida, é também onde acontecem os principais impactos associados. Assim, é evidente que as áreas urbanizadas exercem papel de protagonismo no que concerne às mudanças climáticas.

A urbe é onde são encontradas as maiores aglomerações populacionais. Na atualidade, mais de quatro bilhões de pessoas vivem em cidades ao redor do mundo (Berry et al., 2022), o que caracteriza mais da metade da população global. Já em um contexto brasileiro, ainda no início dos anos 2000 pouco mais de 80% da população já residia em zonas urbanas (Gomes; Soares, 2004) - porcentagem que, atualmente, segundo dados do censo de 2022, deu lugar a 87% (IBGE, 2022). Dessa forma, com a ciência de que as áreas urbanizadas são as mais sensíveis ao efeito causado pelas mudanças climáticas, é produzido para toda população urbana diversos impactos negativos, que podem ir de extremos desastres ambientais à problemáticas envolvendo conforto térmico (Braga, 2012). Ou seja, a existência e expansão da malha construída não somente gera impactos em grande escala, como no caso das mudanças climáticas - uma questão global -, mas também afeta diretamente a vida da população que nela reside, o que requer esforços para mitigação dos problemas acarretados.

Sob tal ótica, a vegetação inserida em contextos urbanos, dada a conjuntura atual, se apresenta como essencial para a diminuição dos efeitos da artificialidade encontrada nas áreas densamente construídas. Ela funciona como um dos principais meios de melhoria de qualidade de vida da população, possuindo impacto direto na saúde e bem estar dos indivíduos alocados nas cidades (Martelli, 2016). No entanto, apesar de toda vegetação, independente do porte, desempenhar papel positivo na qualidade ambiental das cidades (Gillner et al., 2016), a vegetação arbórea se destaca com relevância ainda maior. Frente a outras estruturas de vegetação, como gramíneas ou tipologias arbustivas, a vegetação arbórea amplia e intensifica os serviços ambientais oferecidos à urbe. Isso se dá, por exemplo, em decorrência do maior porte nessa tipologia, complexidade estrutural e capacidade funcional das copas arbóreas, podendo aumentar o potencial de regulação térmica, interceptação

de poluentes e aprimoramento de condições sócio ambientais (Nowak; Dwyer, 2007). Sob uma perspectiva micro climática, as árvores na cidade possuem grande eficiência na moderação térmica por intermédio do sombreamento e da evapotranspiração, aspectos que reduzem fortemente temperaturas superficiais e atenua o fenômeno das ilhas de calor (Oke, 1989; Ferreira, 2019) - benefícios que não se encontram em magnitude similar em tipologias arbustivas ou de gramíneas, uma vez que não apresentam estruturas suficientes para influenciar nesses processos. Essa diferença na estrutura vegetal é decisiva em regiões densamente urbanizadas, uma vez que a presença de árvores pode reduzir temperaturas superficiais em até 8°C se comparado a áreas sem cobertura arbórea (Ferreira, 2019). Além disso, a arborização em contexto urbano também pode impactar diretamente na qualidade do ar da urbe, através da interceptação de partículas e gases poluentes (Escobedo; Kroeger; Wagner, 2011). Este fator se dá em decorrência da área foliar e altura das copas, que interagem de forma direta com o ar na zona respiratória humana. Sob uma ótica socioambiental, a arborização nas cidades também agrega valor estético, simbólico e psicológico aos espaços urbanos, o que está diretamente conectado à promoção de bem-estar e conforto à população da urbe (Ulrich, 1984; Nucci, 2008). Desse modo, nota-se que, embora gramíneas e vegetações arbustivas desempenhem papel importante, a arborização se destaca ecológica e funcionalmente no contexto urbano.

Dada a relevância, a Sociedade Brasileira de Arborização Urbana indica que para que se tenha uma boa qualidade de vida no meio urbano, é recomendado que haja pelo menos 15 m² de cobertura vegetal arbórea por habitante (Lourenço, et al., 2021). Sendo assim, a utilização de metodologias que permitam mensurar a arborização em contexto urbano ainda existente em se configura como indispensável. Essa necessidade se torna ainda mais intensa quando se trata de extensos aglomerados urbanos, com exorbitantes números populacionais, somados a extensas áreas de malha urbana, que existem e se expandem sem respeitar limites político-administrativos - como é o caso das entidades urbanas tituladas Regiões Metropolitanas (RM). A Região Metropolitana do Rio de Janeiro (RMRJ), em um contexto brasileiro, é uma das RM mais relevantes, uma vez que concentra um dos maiores PIBs e se mantém como uma das mais influentes em âmbito nacional (Lourenço et al., 2021). Nesta RM, desde a década de 80, identifica-se uma expansão horizontal de centenas de km² e uma ampliação de população residente de quase 4

milhões de pessoas (Lourenço et al., 2021). Tendo em vista isso, são inúmeras as pressões antrópicas incidindo sobre a área, o que faz com que esta entidade urbana possua uma urgência em estudos e aplicações metodológicas a fim de identificar, mensurar e qualificar a vegetação arbórea contida na RMRJ. Tais estudos, se realizados de forma precisa, podem auxiliar no planejamento e gestão de configurações urbanas como a RMRJ, pois auxiliam no desenvolvimento de estratégias de conservação e reposição de vegetação secundária em ambiente urbanizado.

O Sensoriamento Remoto, nesse sentido, vem à tona como uma importante estratégia na missão de identificar a vegetação arbórea metropolitana. A partir do fruto dos sensores remotos, é possível coletar dados e delimitar objetos sobre a superfície terrestre. Isso faz com que o sensoriamento remoto seja fundamental para detecção, identificação, disposição espacial e quantificação da vegetação na superfície terrestre, e, sendo assim, em áreas com diferentes níveis de urbanização. Diferentes técnicas de processamento, características espectrais e fluxos metodológicos, vão determinar a acurácia e precisão do que poderá ser identificado com as imagens satelitárias.

Desse modo, com a densa e complexa contribuição dos dados de sensoriamento remoto, surge a demanda por métodos mais avançados de processamentos de dados, como, por exemplo, uma importante técnica que trabalha com dados de sensoriamento remoto e recentemente vem sendo muito utilizada com êxito: o *deep learning* (ou aprendizagem profunda).

Um subconjunto do *machine learning* (ou aprendizagem de máquina), o *deep learning* nos últimos anos vem se consolidando como o carro-chefe da inteligência artificial (IA) (Taquary, 2019), uma vez que, mesmo com sua recente gênese, já são percebidos inúmeros avanços e superações de entraves que persistiram por diversos anos no campo da inteligência artificial (LeCun, Bengio e Hinton, 2015). Tal relevância pode ser percebida até em funcionalidades cotidianas, onde cada vez mais aplicações ligadas a IA são aprimoradas ou recriadas a partir da introdução da aprendizagem profunda em seu funcionamento (LeCun, Bengio e Hinton, 2015).

A técnica de *deep learning* pode ser definida como uma forma de aprendizado a partir de redes neurais, onde as camadas e combinações são apreendidas profundamente (Osco, 2023). Desse modo, funções de grande complexidade podem

ser aprendidas sem muita dificuldade e de forma significativamente mais acelerada (LeCun, Bengio e Hinton, 2015), o que potencialmente supera diversas abordagens clássicas de aprendizado de máquina, como *Support Vector Machine* e *Random Forest*, dois importantes algoritmos de classificação (Taquary, 2019).

Dada a potencialidade das técnicas de aprendizagem profunda, sua aplicação pode ser encontrada em diversas áreas do conhecimento, como em pesquisas médicas, agricultura de precisão, vendas, dentre outras práticas, sobretudo que lidam com uma densa quantidade de dados (Ganatra; Patel, 2020; Dharshini; Vijila, 2021). De maneira não dessemelhante, a representação da superfície terrestre a partir de dados multiescalares também possui um grande destaque quando baseados em técnicas de *deep learning*.

Considerando diversas aplicações, a integração de técnicas de *deep learning* a produtos de sensoriamento remoto se consolida, atualmente, como a abordagem mais avançada para estudos sobre o espaço geográfico (Li et al., 2022; Aleissae et al., 2023 *apud* Osco., 2023 p. 33) Além disso, segundo LeCun (2015), as técnicas de *deep learning* possuem uma clara primazia em tarefas de detecção e reconhecimento em imagens; somado a isso, estas ainda possuem ótimo desempenho trabalhando com dados de elevada complexidade e dimensão, onde entregam resultados bem próximos ao desempenho humano, em alguns casos.

Assim, dado o exposto, hoje já são encontrados diversos estudos que fazem a associação *deep learning*-sensoriamento remoto. Estes estudos contemplam diversos objetivos, como para delimitação de zonas funcionais urbanas, detecção de linhas de plantio, dentre outros (Yang et al., 2021; Ribeiro, 2023).

2. OBJETIVOS

Sob tal ótica, dada a importância de identificações precisas da vegetação arbórea contida na Região Metropolitana do Rio de Janeiro e o ótimo desempenho esperado dos produtos a partir de dados orbitais e *deep learning*, o presente estudo possui como objetivo mais geral realizar a identificação da arborização contida na RMRJ com base em *deep learning*.

Mais especificamente, objetiva-se:

- Realizar um estado da arte sobre técnicas de *deep learning* aplicadas a identificação de arborização em contexto urbano;
- Realizar uma análise de desempenho baseado no dado gerado de identificação da vegetação arbórea urbana no contexto da RMRJ, considerando acurácias e exatidão adquirida;

3. ÁREA DE ESTUDO E JUSTIFICATIVA

Ainda na década de 60, dado o intenso e acelerado processo de metropolização que se dava no território brasileiro, surge a demanda pela criação de Regiões Metropolitanas (Silva et al., 2020). No entanto, foi apenas na década seguinte, 1970, que começaram a ser oficialmente delimitadas, por ordem federal, as primeiras Regiões Metropolitanas brasileiras.


Estabelecida ainda durante o período militar, a política de criação das Regiões Metropolitanas teve a lógica de promoção de uma maior integração territorial no Brasil, que seria efetivada a partir de diversas e intensas inter-relações entre diferentes limites político-administrativos (Barreto, 2012). Além do estreitamento de relações, a demanda pela criação das RMs também teve como importante fator a necessidade de que fossem desenvolvidas políticas específicas para gestão dessas áreas com o acelerado acréscimo de malha urbana (Lourenço et al., 2021). Nesse sentido, os mais importantes centros urbanos brasileiros observados no início da década de 70 foram escolhidos para compor o grupo das entidades urbanas em emergência. As nove Regiões Metropolitanas pioneiras, institucionalizadas entre 1973 e 1974 e intituladas pelo Instituto Brasileiro de Geografia e Estatística (IBGE) como as de “primeira geração”, concentravam-se nas regiões Nordeste (Recife, Salvador e Fortaleza); Sul (Porto Alegre e Curitiba); Norte (Belém); e Sudeste (São Paulo, Belo Horizonte e Rio de Janeiro - esta última RM, tendo seu perímetro como área de interesse neste estudo).

A gênese da RMRJ se dá em 1974 a partir de uma lei complementar (LC nº 20) que ordena a eliminação do estado da Guanabara e, por conseguinte, o anexa ao estado do Rio de Janeiro. Inicialmente, a RMRJ era composta por 14 municípios: Rio de Janeiro, Niterói, Duque de Caxias, Itaboraí, Itaguaí, Magé, Maricá, Nilópolis, Nova Iguaçu, Paracambi, Petrópolis, São Gonçalo, São João do Meriti e Mangaratiba. Ao longo dos anos, a RM passou por diversas reconfigurações em sua composição

municipal, que ocorreu ou pela emancipação de alguns municípios, ou pela saída/entrada de outros. A última modificação composicional da RMRJ se deu no ano de 2018, a partir de uma lei complementar (LC Nº 184), onde o município de Petrópolis voltou a integrar a entidade urbana.

Atualmente, a RMRJ, que possui o município do Rio de Janeiro como sede, conta com mais 21 municípios em sua composição: Belford Roxo, Cachoeiras de Macacu, Duque de Caxias, Guapimirim, Itaboraí, Itaguaí, Japeri, Magé, Maricá, Mesquita, Nilópolis, Niterói, Nova Iguaçu, Paracambi, Petrópolis, Queimados, Rio Bonito, São Gonçalo, São João de Meriti, Seropédica e Tanguá. A RMRJ e a repartição municipal de seus integrantes fluminenses podem ser visualizadas na figura 1.

Figura 1: Mapa de localização da Região Metropolitana do Rio de Janeiro.



Fonte: O autor (2025).

Segundo o Instituto de Pesquisa Econômica Aplicada (IPEA), a RMRJ já concentra mais de 70% de toda população do estado do Rio de Janeiro, onde, dessa porcentagem, mais da metade reside apenas no município núcleo (Rio de Janeiro).

A relevância da Região Metropolitana do Rio de Janeiro se estende para um contexto nacional, uma vez que o município núcleo da RM é uma das duas mais importantes metrópoles do Brasil. Isso pode ser provado com o estudo da Regiões de Influência das Cidades (REGIC) de 2018, onde o Arranjo Populacional do Rio de Janeiro é caracterizado como de extrema influência nacional, ocupando a terceira posição no ranking geral, com um dos maiores PIBs e densidade demográfica.

No que tange ao perímetro urbano da RMRJ, desde a década de 80, apesar de já possuir uma malha urbana bem consolidada e extensa, ocorreu um importante acréscimo de mancha construída. Prova disso, tem-se um estudo desenvolvido por Lourenço et al. (2021) onde é relatado que, somente no limite da RMRJ, a malha urbana adicional representou pouco mais de 450 km² entre 1985 e 2018. Nesse período, a expansão se caracterizou, principalmente, por adições urbanas periféricas, ou seja, que ocorrem majoritariamente à franja da mancha urbana. No entanto, importantes inclusões da mancha ocorreram de forma pulverizada ao longo da RM, onde não possuíam ligação contínua com a mancha principal, ocorrendo em áreas com a matriz do entorno não construída. A dinâmica de expansão supracitada - ou seja, pulverizada - é o que acontece nos casos Comperj, no município de Itaboraí, e da Companhia Siderúrgica da América do Sul, na cidade do Rio de Janeiro. Nesses dois casos, ocorreu-se um significativo e abrupto acréscimo da área artificializada, que se deu em um entorno predominantemente não urbanizado (Lourenço et al., 2021).

Tais informações revelam que, de forma incontrollável, o acréscimo de área construída é constante e desordenado. Este fato, atrelado a importância da região metropolitana em âmbito nacional, cria uma necessidade de estudos sobre a vegetação que ainda resiste não só no perímetro da urbe, mas também em toda RMRJ. Desse modo, a geração de dados e informações sobre a área pode auxiliar no ordenamento urbano da RMRJ, isso por intermédio da definição de estratégias que, a partir da geoinformação de áreas vegetadas em ambiente urbanizado, viabilizam o estabelecimento de áreas prioritárias para projetos/programas de regeneração e conservação de remanescentes, bem como a criação de conexões/corredores entre

fragmentos de vegetação em contexto urbano. Em decorrência do exposto, o limite da Região Metropolitana do Rio de Janeiro é a área de interesse deste estudo.

4. REVISÃO BIBLIOGRÁFICA

4.1 *Deep Learning*

4.1.1 *Deep learning*: uma perspectiva histórica de desenvolvimento

Ainda na antiguidade era percebido o interesse no desenvolvimento de autômatos com capacidade de agir de forma inteligente, similar ao comportamento humano (Barbosa; Bezerra, 2020). Atualmente, a reprodução do comportamento semelhante ao pensar humano através de máquinas está cada vez mais presente na vida cotidiana, o que pode ser visto desde as funcionalidades e aplicações mais simples de um smartphone até a construção de arquiteturas diversas na área de robótica. Assim, a chamada inteligência artificial, hoje em dia, se consagra como um dos campos mais auspiciosos dentre as diversas áreas do conhecimento científico, o que faz relevante compreender, de forma breve, os principais marcos históricos do seu desenvolvimento até a contemporaneidade (Barbosa; Bezerra, 2020).

A inteligência artificial dá os seus primeiros sinais ainda em um contexto de Segunda Guerra Mundial, uma vez que durante esse período foram fomentadas diversas produções na área eletrônica e computacional (Gomes, 2010). Exemplo disso, tem-se os canhões antiaéreos desenvolvidos, que eram dotados de um sistema de pontaria que, caso ocorresse o deslocamento do alvo, a própria máquina aplicaria correção ao direcionamento - o que foi comparado ao comportamento humano (Barbosa & Bezerra). Entre os últimos anos da segunda guerra mundial e os primeiros anos que sucederam esse contexto histórico, surgem importantes contribuições para o campo da inteligência artificial, como Warren McCulloch e Walter Pitts, em 1943, que apresentaram as primeiras estruturas do pensar artificialmente; Claude Shannon, em 1950, com a exibição de uma máquina que era capaz de jogar xadrez; e, dentre outros, Alan Turing, ainda em 1950, que elaborou uma máquina que realiza emulação da comunicação humana por escrito.

No entanto, apenas no ano de 1956 ocorre o que é considerado o marco-zero da inteligência artificial: a Conferência de Dartmouth, que apresentou os principais

personagens basilares para a IA. Esta conferência, que reuniu cerca de 10 cientistas, cunhou o termo Inteligência artificial e, com isso, inaugurou uma nova área do conhecimento que tomou proporções mundiais (Fernández-Caballero et al., 2006; Coelho, 2012). Desde então, com base nisso, ocorreram diversas contribuições e avanços na área, que hoje já está presente em diversas atividades e equipamentos de uso comum.

Dado o contexto de surgimento, a IA, que é um ramo da ciência da computação, pode ser definida como uma associação de diferentes técnicas usadas para a construção de máquinas inteligentes, onde possuem capacidade de resolução de entraves que necessitam inteligência humana (Nilsson, 2009). Nos últimos anos também puderam ser observados diversos avanços em pesquisas relacionadas à inteligência artificial, que se dão em grande escala e são potencialmente relevantes em qualquer área do conhecimento (Russel; Norvig, 2009). Assim, por sua interdisciplinaridade, a IA intersecta com diversos domínios da ciência, possuindo diferentes subcampos, como o machine learning.

A aprendizagem de máquina, ou machine learning, pode ser definida como um campo que confere às máquinas a capacidade de aprender sem que ocorra uma explícita programação (Samuel, 1959). O processo de aprendizagem em machine learning se dá a partir da utilização de dados que, por conseguinte, são usados como base para criação de hipóteses (Leporace, 2023).

Apesar de em muitos casos ser tratada como um sinônimo da inteligência artificial, a aprendizagem de máquina é apenas uma de suas vertentes. Na programação clássica, principalmente marcada pela primeira fase da inteligência artificial, necessitava-se de direcionamentos minuciosos, que deveriam ser seguidos em detalhe. No entanto, no caso do machine learning, não é solicitado que sejam dadas todas as instruções previamente, pois ainda que os algoritmos sirvam como um guia, tratam-se de orientações sensivelmente dessemelhantes, pois, de modo geral, eles possuem a aptidão de aprender o que deve ser feito (Leporace, 2023).

Um dos campos mais relevantes da ciência moderna, o machine learning teve sua primeira menção ainda na década de 50. Nesta década, que foi de suma importância para os avanços ligados à inteligência artificial no geral, se deram um dos principais e mais relevantes esforços para fazer com que as máquinas tivessem

inteligência similar à humana (Shinde; Shah, 2018). Elaborado por Anthony Oettinger, o primeiro programa de inteligência artificial que incorpora o aprendizado de máquina surge ainda em 1951. Este programa, que foi pioneiro na implementação da aprendizagem de máquina, foi intitulado de “*response learning programme*” e “*shopping programme*” e teve como objetivo a reprodução do comportamento de uma criança enviada às compras (Shinde & Shah, 2018). A partir de então, foram identificados diversos avanços no que tange o aprendizado de máquina e aplicações, onde atualmente já é possível encontrar diversos frameworks de aprendizado com código de acesso liberado, disponíveis para manipulação e implementações diversas.

Dado o cenário de *big data* nos dias atuais, é indubitável a necessidade de adoção de técnicas de *machine learning* cada vez mais sofisticadas. Isso se dá porque as técnicas mais convencionais de aprendizado de máquina são limitadas em sua capacidade de processar dados diversos em sua forma bruta (LeCun, Bengio e Hinton, 2015; Taquary, 2019). Nesse contexto, surge o *deep learning*.


Os primeiros ensaios ligados a técnicas de *deep learning* se deram ainda em meados dos do século XX, mais especificamente na década de 1950 (Goodfellow; Bengio; Courville, 2016). Após isso, mesmo que estudos e testes na área continuassem a se desenvolver em passos curtos, impasses ligados à incapacidade computacional acarretaram em uma intensa desatenção à temática *deep learning* (Spolti, 2018).

No entanto, alguns aspectos alteraram a conjuntura supracitada. Os anos posteriores à década de 1950 foram marcados por diversos avanços tecnológicos, que se deram, por exemplo, a partir da expansão da capacidade de armazenamento, aprimoramento do processamento computacional e avanços na área da inteligência artificial. Somado a isso, de forma concomitante, ocorreu-se o surgimento do algoritmo de *backpropagation*, que foi descoberto por Rumelhart et al. (1986) e viabilizou, finalmente, o treinamento de redes com múltiplas camadas. Tais aspectos redirecionaram os olhares para pesquisas na área de *deep learning*, dadas as potencialidades já parcialmente sabidas no campo da ciência em questão - o que ocasionou o aumento significativo do investimento de diferentes empresas no estudo de *deep learning*, vislumbrando novas aplicações (Spolti, 2018; Pereira, 2022; Ribeiro; Hosaki, 2023).

Assim, a partir do ano de 2006, o *deep learning* inicia uma nova era de pesquisa em aprendizagem de máquina, onde é realizada a proposição de uma nova visão a respeito do aprendizado de representações (LeCun et al., 2015; Pereira, 2022). Entretanto, foi no ano de 2010 que ocorreu a emergência com maior impacto da aprendizagem profunda (Leporace, 2023), fazendo com que as técnicas de *deep learning* fossem cada vez mais introduzidas a estudos de diversas temáticas, dada a multiplicidade de problemas que podem ser resolvidos a partir de *deep learning*. Com isso, métodos e classificadores mais comuns, que são parte da aprendizagem de máquina, estão perdendo espaço para dar lugar a metodologias que imitam de forma mais aprimorada o funcionamento do cérebro humano (Goodfellow; Bengio; Courville, 2016).

Baseado em padrões de processamentos cerebrais humanos (Alzubaidi et al., 2021), o *deep learning* pode ser definido como um campo de ampla magnitude que possui técnicas e arquiteturas de aprendizagem de máquina. Nessas arquiteturas, chamadas de redes neurais, há a presença de entradas, camadas escondidas de processamento e saída - o que pode ser observado na figura 2, que contém uma ilustração de uma rede neural profunda. Vale destacar ainda que nessas arquiteturas, que são não lineares e de origem hierárquica, são realizadas diversas operações que auxiliaram a maior precisão do resultado final. No que tange seu funcionamento, o *deep learning* faz utilização de uma enorme quantidade de dados, onde são obtidas informações com altos níveis de abstração, que são utilizadas para classificação (Hamaguti; Breve, 2022).

Figura 2: Rede neural profunda.



Fonte: adaptado Data Science Academy (2022).

Por fim, sob a ótica do *deep learning*, alguns conceitos são de essencial ciência.

4.1.2 Redes Neurais Artificiais


O surgimento das redes neurais revolucionou a área de inteligência artificial, uma vez que suas arquiteturas foram base para diversos avanços nessa temática. O primeiro modelo de um neurônio artificial teve evidência na primeira metade da década de 1940, quando McCulloch e Pitts, em 1943, usavam a rede para representação de funções lógicas, que tiveram inspiração no sistema neural humano. Contudo, encontrava-se grande limitação na proposição dos autores, onde, para utilização do modelo, eram necessárias intervenções matemáticas manuais. No ano de 1958, Rosenblatt propôs um modelo que funcionaria como uma evolução do que apresentaram McCulloch e Pitts há exatamente 15 anos: o modelo *Perceptron*. Neste caso, o modelo conseguiu aprender padrões lógicos e a alteração de pesos ao longo da rede era realizada de forma automática. A partir de então, diversos avanços se deram baseados nesses dois modelos, que trouxeram o que temos hoje, arquiteturas complexas de redes neurais artificiais e que são de extrema importância para resolução de problemas ligados a diversas vertentes científicas.

As redes neurais são arquiteturas baseadas no modelo de processamento de informações que ocorre no cérebro humano, por meio de processos de aprendizagem. Este método tem possibilidade de aplicação geral, desde trabalhos mais simplificados até os mais complexos, onde serão aprendidas funções por intermédio dos dados utilizados (Mitchell, 1991).

A estrutura básica de uma rede neural pode ser dividida em 3 camadas: a primeira, chamada camada de entrada, ou *input*, como o próprio nome sugere, é a etapa em que serão introduzidos os dados que vão munir a rede. A segunda camada, chamada de camada oculta ou escondida, é a etapa em que serão processados os dados de entrada a partir de cálculos matemáticos, que irão, por sua vez, direcionar a decisão de saída. Por último, a terceira camada, que é intitulada camada de saída, ou

output, é onde será entregue o resultado final. Um modelo mais simples de arquitetura de redes neurais pode ser visualizado na figura 3.

Figura 3: Estrutura de uma rede neural simples.



Fonte: Hyndman e Athanasopoulos (2018).

4.1.3 Redes Neurais Convolucionais

Segundo Spolti (2018), As arquiteturas em *deep learning* possuem uma elevada flexibilidade, onde são realizadas, de maneira simplificada, modificações estruturais a depender do tipo de aplicação. Dessa forma, diversas são as arquiteturas construídas, baseadas em uma estrutura acadêmica sólida. Dentre as arquiteturas mais utilizadas, pode-se destacar as CNNs (Spolti, 2018).

As redes neurais convolucionais (RNCs), ou Convolutional Neural Network (CNN), que inicialmente foram intituladas LeNet-5, são uma modalidade específica das RNAs cunhado por Yann LeCun et al. ainda em 1998. Nesse sentido, desde o início dos anos 2000 as CNNs possuíram bastante destaque na detecção, segmentação e reconhecimento de objetos em imagens (LeCun et al., 2015). No entanto, este método foi amplamente utilizado apenas a partir de 2012, com a competição ImageNet, que iniciou uma sequência de novas proposições de arquitetura de CNNs, que eram baseadas em aprendizagem profunda e faziam uso de milhares de imagens e diversas classes (LeCun et al., 2015). Esse fato revolucionou a visão computacional, onde,

atualmente, as CNNs são a abordagem de maior destaque para quase a totalidade de tarefas ligadas a reconhecimento e detecção em imagens, aproximando-se, em muitos casos, do desempenho humano.

Uma das arquiteturas de rede de aprendizagem profunda, as CNNs, que são baseadas no córtex visual do cérebro humano, são redes neurais para processamento de dados em forma matricial, onde em pelo menos uma de suas camadas realiza uma operação de convolução (Utsch, 2018; Nicolau, 2020; Spolti, 2018). Vale ainda ressaltar que a principal proposta atrelada a existência das CNNs é prover a solução de entraves ligados à classificação, onde a entrada é uma imagem e a saída um rótulo/classe. Basicamente, segundo Spolti (2018), as camadas nas CNNs possuem 3 etapas principais respectivas: convolução, função de ativação não-linear e pooling.

4.1.3.1 Convolução

Operação que deu origem à titulação das redes neurais convolucionais, a etapa de convolução se caracteriza como indispensável para aplicação de uma CNN. A convolução pode ser definida como um tipo de operação matemática linear que é utilizada para extração de informações em um dado matricial, onde há a tentativa de que sejam mantidas apenas as informações mais importantes (Hakim; Fadhil, 2021 *apud* Hamaguti; Breve, 2022). O processo de extração das informações mais relevantes se dá a partir da adoção de filtros convolucionais, que percorrem a imagem na horizontal e na vertical, realizando operações de convolução sobre todo o dado de entrada.

Segundo Spolti (2018), os três componentes principais de uma camada de convolução são: a entrada, o detector de características (kernel de convolução ou filtro) e, por fim, o resultado da operação. A entrada nessa arquitetura de rede de aprendizagem profunda serão dados matriciais.

O kernel de convolução é definido como a janela deslizante, geralmente de tamanho 3x3, formada por pesos - que são definidos de forma aleatória, inicialmente, mas se ajustam durante o aprendizado. A janela citada percorrerá toda a imagem da esquerda para a direita e de cima para baixo, onde a dimensão de cada movimento

dependerá do stride (tamanho do passo do kernel ao longo da imagem) determinado (Spolti, 2018). De forma geral, nesta etapa, conforme o kernel percorre os pixels da imagem, ocorre a multiplicação entre matrizes; ou seja, entre os valores do filtro (kernel) e os valores contidos no contexto que o kernel se encontra na imagem - área essa que é chamada de *receptive field*. Após a multiplicação, os valores são somados e o resultado disso será o valor de saída. De forma a melhor elucidar o funcionamento citado, tem-se o esquema contido na figura 4.

Figura 4: Exemplificação de operação de convolução com strid 1 e kernel 2x2.

Input		Kernel		Output																	
<table border="1" style="border-collapse: collapse; width: 100px; height: 100px;"> <tr><td style="padding: 5px;">0</td><td style="padding: 5px;">1</td><td style="padding: 5px;">2</td></tr> <tr><td style="padding: 5px;">3</td><td style="padding: 5px;">4</td><td style="padding: 5px;">5</td></tr> <tr><td style="padding: 5px;">6</td><td style="padding: 5px;">7</td><td style="padding: 5px;">8</td></tr> </table>	0	1	2	3	4	5	6	7	8	*	<table border="1" style="border-collapse: collapse; width: 100px; height: 100px;"> <tr><td style="padding: 5px;">0</td><td style="padding: 5px;">1</td></tr> <tr><td style="padding: 5px;">2</td><td style="padding: 5px;">3</td></tr> </table>	0	1	2	3	=	<table border="1" style="border-collapse: collapse; width: 100px; height: 100px;"> <tr><td style="padding: 5px;">19</td><td style="padding: 5px;">25</td></tr> <tr><td style="padding: 5px;">37</td><td style="padding: 5px;">43</td></tr> </table>	19	25	37	43
0	1	2																			
3	4	5																			
6	7	8																			
0	1																				
2	3																				
19	25																				
37	43																				

Fonte: Zhang, et al., 2021.

Neste exemplo, (figura 4), que esquematiza de maneira simplificada o processo de convolução, o valor do stride é 1 e o tamanho do filtro corresponde a 2x2. Aqui é realizada uma multiplicação entre as matrizes (input e kernel) e, logo após, elas são somadas, dando origem à camada final. Ou seja, na janela destacada em azul, foi realizado o cálculo $0 \times 0 + 1 \times 1 + 3 \times 2 + 4 \times 3 = 19$. Assim, o que no input era a área de um kernel, neste caso 2x2, é transformado em apenas um dado (pixel) no output.

Geralmente, as camadas de convolução são sucedidas por uma função de ativação.

4.1.3.2 Função de ativação não-linear

Componentes de extrema relevância no que tange às redes neurais, as funções de ativação vão definir se um determinado neurônio que compõe a rede vai ser ativado ou não (Zhang, et al., 2023). Ou seja, é realizada uma avaliação, a partir da aplicação da função de ativação, da relevância que um determinado neurônio possui para um resultado preciso, o que, a depender da resposta, poderia levar à desconsideração do neurônio. Logo, a função de ativação se caracteriza como uma transformação não linear que é realizada nos dados de entrada, o que faz com que seja possível executar tarefas de maior complexidade (Zhang, et al., 2023).

Em *deep learning* a função de ativação *Rectified Linear Unit* (ReLU) é a mais comum, e sua fórmula é definida como: $f(x) = \max(0, x)$. Esta função, ReLU, se destaca por não realizar a ativação de todos os neurônios ao mesmo tempo, o que aumenta a eficiência da rede (Zhang, et al., 2023).

4.1.3.3 Operação pooling


As operações pooling são responsáveis por diminuir a dimensionalidade espacial das representações, que são resultantes da camada anterior. Isso se dá, principalmente, na intenção de que sejam extraídas as informações mais relevantes em uma pequena região e, além disso, que seja diminuído o custo computacional para processamento.

Esta operação funciona de maneira análoga ao que acontece no processo de convolução. A partir de uma janela, que dessa vez é de formato fixo e não visita mais de uma vez uma mesma região, toda a imagem é percorrida e, por conseguinte, uma única saída é o fruto da operação realizada na janela, que neste caso é conhecida como janela de pooling (Zhang, et al., 2023). O objetivo central da operação de pooling é que, no contexto da janela, haja um único valor-resumo para a área.

Apesar de semelhante, neste caso não ocorre um cálculo de correlações cruzadas entre matrizes, como é no caso da convolução. Isto é, não há kernel e seus respectivos pesos. Aqui, a extração da saída de cada janela é resultado de alguma medida matemática, como valor máximo ou médio, por exemplo.

No contexto do *deep learning*, a operação pooling mais utilizada é a intitulada max pooling. Nesta, o resultado de toda janela será o seu componente de maior valor, o que acarretará na exclusão dos demais componentes da janela. Exemplo da operação max pooling pode ser observado na figura 5.

Figura 5: Exemplificação de operação max pooling.



Fonte: Adaptado de Kim; Jeong (2019).

Após isso, mesmo com a diminuição dimensional da matriz, vale ressaltar que as características ainda são preservadas, pois é de ciência que o maior valor é onde foi identificada a maior similaridade com o detector de características.

4.2 Mapeamento de vegetação em ambiente urbanizado

4.2.1 Cobertura vegetal em contexto urbano: uma breve revisão conceitual

O modelo de desenvolvimento fundamentado na intensa exploração de recursos naturais que é encontrado em um contexto brasileiro remonta à sua colonização, ainda em 1500 (Bargos, 2010). Nesse sentido, observa-se, desde então, uma forma de produção do espaço que progressivamente reconfigura a superfície e suas dinâmicas às necessidades de ocupação e expansão humana.

De maneira análoga, o processo de consolidação e expansão urbana também possuiu caráter devastador, a partir de processos desordenados, irrefreáveis e irreversíveis (Lourenço et al., 2021). Isso se dá porque, com a ampliação da urbe, o meio natural perde cada vez mais espaço para dar lugar a áreas de elevada artificialização. Com isso, são gerados impactos que se materializam, sobretudo, no próprio ambiente urbano. Assim, as áreas urbanizadas, que produzem os maiores impactos ambientais e têm as maiores concentrações populacionais, se caracterizam como ponto focal dos impactos gerados pela urbanização - o que afeta de forma direta e acentuada a qualidade de vida humana.

Nesse sentido, a cobertura vegetal em ambiente urbanizado possui papel fundamental na mitigação de impactos promovidos pela sua intensa artificialidade, sobretudo se a urbe se manifesta espacialmente de forma extensa e/ou com elevada densidade. Tal fato ocorre porque a presença de vegetação arbórea em ambiente urbanizado promove uma melhoria na qualidade ambiental da área (Souza et al., 2020). Morato et al. (2005) destaca que a existência de uma boa qualidade ambiental urbana ocorre quando há condições adequadas para conforto - em termos biológicos, econômicos, tipológicos e estéticos, por exemplo (Bargos, 2010) - e saúde da população. Sendo assim, a provisão de qualidade ambiental impacta diretamente na qualidade de vida da população residente da urbe.

Diversas temáticas, como equilíbrio ambiental e cidades sustentáveis, que dizem respeito à arborização no contexto da urbe, são encontradas no Estatuto da Cidade (Oliveira, 2015). Apesar disso, no que tange ao planejamento urbano, o direcionamento de atenção à vegetação dessa área acaba sendo negligenciada. Como consequência, ocorre uma diminuição da qualidade ambiental de perímetros urbanizados.

Apesar da ampla aceitação científica da contribuição positiva da cobertura vegetal urbana para a qualidade ambiental das cidades, observa-se que, ao desenvolver análises com tal temática, ocorrem-se discordâncias conceituais.

Ao trabalhar com a cobertura vegetal inserida em contexto urbanizado, diversos autores têm utilizado diferentes termos, como arborização urbana, áreas verdes, verde urbano, dentre outros, como sinônimos (Bargos, 2010). Entretanto, na maioria das vezes, os termos não fazem referência a um mesmo objeto de análise. Segundo

Bargos (2010), nos últimos anos, o conceito de áreas verdes urbanas tem sido mais amplamente utilizado para análises de toda vegetação urbana. Apesar disso, encontram-se muitas discordâncias na definição do que se entende como as áreas verdes urbanas.

Segundo Milano (1993), as áreas verdes urbanas podem ser consideradas como áreas de livre acesso inseridas no contexto das cidades, onde suas características de cobertura do solo precisam ser majoritariamente vegetadas, sem levar em consideração o porte dessa vegetação.

Os autores Paiva e Gonçalves (2002), por sua vez, colocam que as áreas verdes precisam, em sua completude, conter algum tipo de vegetação, podendo ser de domínio público ou privado. Por outro lado, Cavalheiro e Del Picchia (1992) concebem que, conceitualmente, apenas espaços livres podem ser considerados áreas verdes.

Lima et al. (1994) defendem que as áreas verdes podem ser delimitadas onde ocorre o predomínio de vegetação arbórea. No entanto, os autores não consideram parte dessa classe as árvores contidas à margem de vias públicas. De forma semelhante, Loboda e Angelis (2005), em decorrência da impermeabilidade do solo, não consideram as árvores ao leito de vias como áreas verdes urbanas.

Desse modo, observa-se que ocorrem diversas controvérsias literárias sobre a concepção de áreas verdes urbanas. No primeiro caso citado, Milano (1993), é entendido que algumas áreas não vegetadas podem ser consideradas como áreas verdes, caso sua matriz de entorno, dentre outros aspectos, seja majoritariamente vegetada. O domínio público ou privado, além disso, também pode ser um fator determinante para definição de áreas verdes urbanas, como é o que acontece nas definições supracitadas de Paiva e Gonçalves (2002) e Cavalheiro e Del Picchia (1992). Vale destacar, por fim, que os autores Lima et al. (1994) e Loboda e Angelis (2005), realizam a exclusão de árvores à borda de vias públicas da definição de áreas verdes urbanas, em decorrência da artificialidade do solo em que esses elementos arbóreos estão inseridos.

Sendo assim, dada a intenção deste estudo de considerar toda a arborização contida na RMRJ, inclusive especificamente no perímetro de malha urbana -

respeitando o fator escala -, o conceito de áreas verdes urbanas não se configura como o ideal a ser aqui trabalhado.

Além dos conceitos supracitados, a arborização urbana é utilizada como objeto de estudo em diversos trabalhos de temática urbano-ambiental. A arborização urbana pode ser compreendida como um conjunto de árvores que compõem o cenário urbano, estejam elas dispostas de forma planejada ou espontânea. Esse conceito engloba desde indivíduos arbóreos isolados em vias públicas, calçadas e praças, até maciços vegetais presentes em parques, jardins, áreas institucionais e fragmentos florestais que resistiram ao processo de urbanização (Grey & Deneke, 1978; Milano & Dalcin, 2000).

De acordo com Grey e Deneke (1978), a arborização urbana não pode ser reduzida a elementos pontuais ou com fins decorativos, mas deve ser considerada como um recurso urbano estruturante, parte da infraestrutura essencial das cidades. Nesse sentido, os autores argumentam que toda vegetação arbórea, seja em espaço público ou privado, compõe um patrimônio coletivo que influencia diretamente a qualidade ambiental e a habitabilidade urbana. Em reforço a isso, Milano e Dalcin (2000) expressam que a cobertura arbórea urbana assume papel central na amenização do clima local, no controle da erosão do solo, na interceptação da água das chuvas e na valorização estética e paisagística dos ambientes construídos. Além disso, destacam-se os aspectos sociais, pois a arborização contribui para a melhoria da qualidade de vida, estimula o uso dos espaços públicos e atua como elemento de integração comunitária. Sendo assim, pelo maior alinhamento com os objetivos deste estudo, o objeto de análise aqui adotado será a arborização urbana, que considerará a vegetação arbórea em ambiente metropolitano.

4.2.2 Mapeamento de cobertura vegetal urbana

Dada a relevância atrelada à cobertura vegetal urbana para qualidade ambiental da urbe e, por consequência, para qualidade de vida da população, são necessárias mensurações para posteriores análises quali-quantitativas da vegetação inserida em grandes entidades urbanas, como é o caso da RMRJ, a fim de que funcionem como suporte para tomada de decisão. Nesse sentido, a utilização de métodos e técnicas que auxiliem no levantamento preciso e atual de estruturas de

vegetação em ambientes urbanizados são de suma importância (Pipi e Trindade, 2013). Destacam-se, sendo assim, as geotecnologias na coleta de informações espaciais.

Segundo Bargas (2010), foi construída uma “nova visão” sobre a superfície terrestre ainda na década de 50, com o lançamento do primeiro satélite orbital. Isso porque as novas capturas visuais do planeta possibilitaram novas perspectivas, o que, por sua vez, viabilizou de forma mais facilitada e eficiente a identificação de elementos e fenômenos que se dão sobre a superfície. Desse modo, pode-se dizer que as geotecnologias revolucionaram o modo de apreensão e análise espacial.

Consideradas como fundamentais para análises de questões vinculadas ao entendimento do espaço, as geotecnologias são definidas, segundo Fitz (2008, p. 310), como “conjunto de tecnologias computacionais que tem por finalidade o desenvolvimento de trabalhos que venham a interferir no espaço geográfico em termos de planejamento, gestão ou manejo”. Assim, essas técnicas, que tiveram acelerado avanço sobretudo a partir da década de 1990 (Pancher, 2012), contribuem intensamente para o desenvolvimento de estudos que geram, como consequência, a ampliação de dados sobre a superfície.

Nesse espectro, o sensoriamento remoto e o geoprocessamento, campos pertencentes às geotecnologias, estão entre as principais ferramentas que auxiliam na detecção e representação de informações sobre a superfície terrestre (Leite; Rosa, 2006).

Segundo Oliveira (2015), no que tange análises espaciais da cobertura vegetal urbana, os Sistemas de Informações Geográficas (SIGs), ferramentas computacionais associadas às geotecnologias, têm sido muito utilizados. Nesse sentido, atualmente são encontrados diversos estudos baseados em geotecnologias para identificação, diferenciação e análise espacial da cobertura vegetal urbana, que, a depender do objetivo, utilizam diferentes abordagens e métodos.

Hashim et al., (2019), por exemplo, a partir da utilização de imagens satelitárias de altíssima resolução (VHR) e da criação do Índice de Vegetação por Diferença Normalizada (NDVI), realizou a identificação de vegetação inserida em uma matriz de entorno majoritariamente urbanizado, utilizando como área de estudo uma pequena parte de um parque nacional da Malásia. Nesta abordagem, a vegetação contida em

ambiente urbanizado foi dividida em três categorias: vegetação rasteira, vegetação de grande porte e área não vegetada. Como resultado, obteve-se um Kappa equivalente a 0,5, o que pode ser entendido como um bom desempenho (Fonseca, 2000).

Ademais, Feng, Liu e Gong (2015), a partir de veículos aéreos não tripulados (UAV), também realizaram mapeamento de vegetação em paisagem urbana, especificamente em uma pequena parcela territorial da cidade de Lishui, na China. Neste caso, o algoritmo Random Forest e a análise por textura foram utilizadas como método de classificação. Como resultado, o Random Forest atrelado à análise por textura revelou um ótimo desempenho, o que pode ser provado com o valor de Kappa dessa classificação, definido como 0,83 - caracterizando, segundo Fonseca (2000), um excelente desempenho.

Em um contexto brasileiro, estudos com base em geotecnologias para trabalhar com a temática da vegetação da urbe também são desenvolvidos. Souza, Oliveira e Júnior (2020) mapearam a vegetação que compreende ao município de Campos dos Goytacazes, no Rio de Janeiro, a partir de imagens Sentinel. Aqui foram desenvolvidas diversas análises que chegaram a diagnósticos importantes, como a quantidade de metros quadrados de vegetação por habitante; porcentagem de setores censitários que não possuem áreas verdes, dentre outros. No entanto, não há aferição da acurácia do mapeamento neste estudo.

Com isso, como ressaltam Leite e Rosa (2006), as geotecnologias possuem extrema importância no amparo ao planejamento urbano, subsidiando estudos que promovem informações que, por sua vez, impulsionam análises para uma utilização mais racional do espaço urbano. Por fim, vale destacar que diversas são as possibilidades, metodologias e abordagens vislumbradas a partir da adoção das geotecnologias para diagnósticos sobre a cobertura vegetal urbana.

5. PRIMEIRO CAPÍTULO: APRENDIZAGEM PROFUNDA E IDENTIFICAÇÃO DE VEGETAÇÃO EM CONTEXTO URBANO: UM ESTADO DA ARTE

5.1 Introdução

O sensoriamento remoto tem sido amplamente utilizado no mapeamento da cobertura vegetal, sobretudo em escalas regionais e globais (Wulder et al., 2019; Zhu

et al., 2017). Entretanto, a especificidade da arborização urbana apresenta desafios próprios, decorrentes da complexidade espectral e estrutural do ambiente construído, onde áreas verdes encontram-se fragmentadas, heterogêneas e inseridas em matrizes fortemente urbanizadas (Gillner et al., 2016; Norton et al., 2015). Nesse contexto, a adoção de técnicas de *deep learning* surge como um campo promissor, capaz de superar limitações associadas a métodos tradicionais de classificação. Apesar desse potencial, verificou-se, inicialmente, que a literatura ainda é incipiente quanto à aplicação direta de algoritmos de *deep learning* para a detecção de vegetações em áreas urbanizadas, onde ocorre maior concentração de esforços em aplicações relacionadas a florestas naturais, agricultura e monitoramento de uso e cobertura da terra em escalas amplas (Ma et al., 2019; Zhang et al., 2020). Nos casos em que o ambiente urbano é considerado, observa-se que grande parte dos estudos se concentra em abordagens locais e experimentais, muitas vezes utilizando metodologias e recursos não diretamente comparáveis entre si (Li et al., 2020). Dessa forma, este estudo se torna essencial na análise dos possíveis padrões metodológicos utilizados para identificação de vegetação no contexto urbano, como os algoritmos de *deep learning* mais recorrentes, os tipos de sensores empregados, as métricas de validação utilizadas e as escalas espaciais predominantes. Assim, essas informações não apenas oferecem um panorama consolidado do campo, mas também permitem situar este estudo em relação aos avanços e desafios que caracterizam tal temática.

Sob tal ótica, este capítulo, que direciona atenção à construção de um estado da arte sobre a aplicação de técnicas de *deep learning* em estudos sobre a cobertura vegetal urbana a partir de imagens de sensoriamento remoto, constitui parte fundamental desta pesquisa.

5.2 Processos metodológicos

Para cumprir com o objetivo supracitado, foram iniciadas as buscas por bibliografias que atendam à temática requerida neste estado da arte. Entre o início de 2023 e o mês de setembro do mesmo ano se deram as buscas bibliográficas. A plataforma de pesquisa Google Scholar foi utilizada como o principal canal de consulta para seleção dos estudos. No entanto, além dessa plataforma, as procuras também se deram em canais alternativos, como Google Search, LinkedIn e referências

bibliográficas de estudos similares. Além disso, recursos de inteligência artificial, como o Chat GPT e o Gemini também foram utilizados para realização das buscas.

Para seleção inicial dos estudos a serem utilizados, foram levados em consideração três aspectos: título, resumo e objeto de estudo. Como resultado dessa busca inicial, encontram-se 74 estudos científicos - desde artigos à teses de doutorado.


Após isso, iniciou-se a etapa de filtragem desses estudos. Esta etapa possuiu como objetivo a separação dos trabalhos que, após leitura mais aprofundada, de fato conversam com o objetivo da busca, levando em consideração: método baseado em *deep learning* e objeto de estudo definido apenas como vegetação em contexto urbano. Além disso, esta etapa também almejou eliminar as repetições entre os estudos selecionados. O resultado da referida filtragem acarretou na exclusão de 58 trabalhos, em decorrência do desalinhamento com a temática que se propõe o estado da arte. Dessa forma, apenas 16 estudos foram selecionados para esta análise. Por fim, para realização das análises estatísticas presentes neste estudo, utilizou-se o software Excel.

5.3 Resultados e estatísticas iniciais

Com posse apenas das produções científicas que trabalham com cobertura vegetal urbana e técnicas de *deep learning*, inicialmente, foram construídas algumas estatísticas gerais sobre os estudos considerados - que serão aqui apresentadas. Essas estatísticas se basearam em: ano de publicação; país de origem da publicação; abordagem conceitual (objeto); e, por fim, produto orbital utilizado.

No que tange ao ano das publicações, foram encontradas produções acadêmicas para 2019, 2020, 2021, 2022 e 2023. Sob tal ótica, o ano de 2019 concentrou o maior número de publicações, com 5. O ano de 2021, segundo que concentra mais publicações, possui 4 publicações; 2022 e 2023 vêm na sequência, com 3 publicações cada e, por fim, o ano de 2020 possuiu apenas uma publicação. Um gráfico com a apresentação dessas informações em porcentagem pode ser visualizado na figura 6.


Figura 6: Gráfico sobre anos que concentram mais publicações na temática vegetação em contexto urbano e *deep learning*.



Fonte: O autor (2025).

Tratando-se do país em que está alocada a instituição em que foi desenvolvida a pesquisa, têm-se a China com a grande maioria dos estudos, com 6 publicações, o que representa cerca de 43% do total. Em seguida, destaca-se os EUA, com 3; Austrália e Inglaterra, com 2 estudos cada. Na classe “outros”, onde o Brasil está inserido, foram agrupados os países que possuíram apenas uma publicação, agrupamento no qual o Brasil está contemplado. Bem como no caso anterior, pode-se visualizar um gráfico contendo as informações supracitadas na figura 7.


Figura 7: Gráfico sobre países que estão alocadas nas instituições em que foram desenvolvidos os estudos com a temática cobertura vegetal urbana e *deep learning*.



Fonte: O autor (2025).

A escolha do objeto de estudo, dentro do espectro da cobertura vegetal urbana, de cada trabalho também foi considerada na criação das estatísticas iniciais. Dentre eles, foram encontradas 6 diferentes abordagens da cobertura vegetal urbana: floresta urbana (3); copa de árvores (3); áreas verdes urbanas (2), árvores individuais (1); árvores urbanas (4); e, por fim, vegetação urbana (3). Um gráfico com a contagem em números absolutos das publicações e suas respectivas abordagens conceituais pode ser visualizado na figura 8.

Figura 8: Gráfico sobre objeto de análise no espectro da cobertura vegetal urbana.



Fonte: O autor (2025).

Por fim, como última estatística realizada, fez-se uma análise considerando os dados base (imagens) para produção dos mapeamentos de vegetação em contexto urbano. Dentre os dados foram encontrados 9 tipos diferentes: imagens worldview, que tiveram 6 publicações utilizando este produto orbital; fotografia por smartphone, que constou em 3 estudos; Sentinel-2 e Gaofen apresentaram 2 publicações cada um. Além disso, Skysat Planet, Pleiades, Quickbird, drone e NAIP apareceram em um dos estudos analisados. Um gráfico desta estatística pode ser visualizado na figura 9.

Figura 9: Gráfico sobre dados base (imagens) utilizados para produção dos mapeamentos.



Fonte: O autor (2025).

5.4 Discussão

No que tange os resultados anteriormente descritos, alguns aspectos e possíveis justificativas podem ser destacados. A consolidação de um estado da arte específico sobre a aplicação de *deep learning* ao mapeamento de vegetação em ambientes urbanos, com base em dados de sensoriamento remoto, mostra-se estratégica para entender a contribuição deste estudo para trazer à tona tendências, lacunas e desafios atrelados à identificação de cobertura vegetal urbana utilizando técnicas de *deep learning*. O corpus analisado reúne dezesseis estudos (incluindo dois artigos de revisão), com notável diversidade de escalas, sensores, arquiteturas de rede e objetos de estudo, variando de segmentação do dossel arbóreo (UTC) a detecção de indivíduos, classificação de espécies, estimativa de métricas estruturais e extração ampla de cobertura vegetal urbana. Em conjunto, esses trabalhos ilustram um campo em maturação metodológica, porém ainda esparsa quanto à padronização de procedimentos, especialmente quando se trata de aplicações em mesoescala orbital.

A partir de uma perspectiva temporal, as produções se concentram em um período mais recente: cinco dos estudos encontrados foram publicados no ano de 2019 (Weinstein et al., 2019; Stubbings et al., 2019; Hartling et al., 2019; Lumnitz, 2019; Braga et al., 2019); Em 2020, apenas 1 estudo foi publicado (Timilsina et al., 2020); já em 2021, quatro estudos foram disponibilizados (Shahtahmassebi et al., 2021; Gómez et al., 2021; Awad e Lauteri, 2021; Wang et al., 2021); No ano de 2022, 3 trabalhos foram desenvolvidos com a temática de interesse (Ventura et al., 2022; Neyns e Canters, 2022; Xuan et al., 2022); por fim, para 2023, ano em que se finalizou esta análise, foram também publicados 3 estudos (Guo et al., 2023; Lin et al., 2023; Chen, Zhang e Lei, 2023). Desse modo, dado o recorte temporal, reforça-se que a ascensão do *deep learning* em aplicações referentes à vegetação em ambiente urbanizado ocorreu nos últimos 6 anos, o que está em sintonia com o relato de dois desses estudos (Shahtahmassebi et al., 2021; Neyns e Canters, 2022), que apontam em média o mesmo período de ascendência dos estudos dessa temática. Este fenômeno pode ser justificado, dentre outros aspectos, pela confluência de três principais fatores: ampliação da disponibilidade de imagens orbitais de altíssima resolução; avanços recentes na capacidade computacional de processamento de dados; e, por fim, o refinamento de arquiteturas de aprendizado profundo. A priori,

vale ressaltar que a grande oferta de imagens que vão de alta a altíssima resolução, que podem ser disponibilizadas por iniciativas comerciais ou públicas, permitiu análises mais detalhadas do contexto urbano. Nesse sentido, estudos como os de Neyns e Canters (2022) falam sobre isso, onde é destacado que a resolução espacial submétrica abriu novas perspectivas para o mapeamento de elementos urbanos, o que permitiu que o *deep learning* superasse métodos tradicionais de classificação. De forma paralela, o desenvolvimento de GPUs mais acessíveis e de melhor desempenho, aliado à expansão de serviços de computação em nuvem, proporcionou um ambiente técnico favorável para a execução de modelos de *deep learning* em larga escala (Shahtahmassebi et al., 2021). Dado o avanço, ocorre-se uma diminuição da necessidade ampliada de tempo e recursos para a geração do treinamento das redes neurais (Shahtahmassebi et al., 2021). O terceiro fator que pode justificar a elevada adesão às técnicas de *deep learning* à mapeamentos de vegetação em contexto urbano se refere ao amadurecimento das arquiteturas de redes neurais. O sucesso na combinação metodológica entre técnicas de *deep learning* e o sensoriamento remoto fez com que as redes neurais convolucionais, que são amplamente aplicadas em visão computacional, fossem progressivamente aprimoradas para lidar com dados multiespectrais e hiperespectrais, como demonstram Weinstein et al. (2019) e Gómez et al. (2021). Além disso, a adaptação de arquiteturas como a U-Net e suas variações consolidou um padrão metodológico robusto dado o bom desempenho percebido, o que explica sua ampla difusão nos anos recentes (Lin et al., 2023; Chen, Zhang e Lei, 2023).

Além do aspecto temporal, percebido e investigado ao desenvolver este capítulo, a análise do tipo de dado produzido (objeto de estudo com enfoque em indivíduos) e resolução dos recursos imagéticos utilizados, estabelecem um importante padrão percebido: a similaridade entre os estudos no que tange a escala dos produtos aqui analisados. O que se observa, nesse sentido, é a dominância de imagens de altíssima a alta resolução espacial, capturadas por satélites comerciais (WorldView-2/3, Gaofen-1/2, QuickBird) e/ou por plataformas aéreas (NAIP; NEON), frequentemente combinadas o LiDAR (Timilsina et al., 2020; Hartling et al., 2019) ou a imagens capturadas na rua (Stubblings et al., 2019; Lumnitz, 2019). Cerca de 90% dos estudos científicos aqui considerados utilizam como base ou suporte imagens/dados de altíssima resolução espacial. No que tange o acervo utilizado para

o desenvolvimento deste capítulo, apenas dois trabalhos possuíam como base o Sentinel 2, produto orbital de mesoescala.

Desse modo, este fato sublinha a lacuna de abordagens que utilizam o *deep learning* em resolução intermediária. A dinâmica aqui encontrada, de predominância de imagens de altíssima resolução, está em concordância com revisões que apontam ganhos de acurácia e discriminação espectral/espacial à medida que se eleva a resolução (Shahtahmassebi et al., 2021; Neyns e Canters, 2022), mas também pode denunciar limitações de custo, disponibilidade e replicabilidade em áreas extensas, uma vez que sensores de escalas menos detalhadas, como os encontrados nos nanossatélites da Planet, oferecem maior cadência temporal, ampla cobertura e acesso aberto.

Por fim, quanto à qualidade dos produtos gerados, em praticamente todos os casos com comparação explícita, abordagens profundas superam métodos clássicos como Random Forest, por exemplo. Como prova disso, vale citar alguns estudos e as suas respectivas acurácias adquiridas. O modelo DenseNet alcançou 82,6% de acurácia geral em classificação de oito espécies, contra cerca de 52% no teste utilizando Random Forest (Hartling et al., 2019); PSPNet supera amplamente métodos cromáticos em imagens de rua (Stubbings et al., 2019); e modelos U-Net/UNet++/DeepLab apresentam ganhos mensuráveis sobre métodos tradicionais (Lin et al., 2023; Wang, 2021.; Chen, Zhang e Lei, 2023). No espectro da segmentação da cobertura vegetal urbana, destacam-se resultados robustos com Índice Jaccard (IoU)/Mean Intersection over Union (MIoU) elevados: o estudo nacional no Brasil (Guo et al., 2023) reporta MIoU 83,07% e exatidão global 95,76% em 472 cidades; em cenário chinês com 2 m e banda NIR, SD-UNet atinge IoU 0,8977 e exatidão global de 0,958 (Lin et al., 2023); em contexto mexicano (com imagens de altíssima resolução), IoU 0,75 e exatidão global equivalente a 0,97 (Gómez et al., 2021); e, em área brasileira com WorldView-2 (0,5 m), IoU 0,812 (Ventura et al., 2022.). Além desses, vale alencar que os trabalhos que não apresentaram comparações também alcançaram bons resultados de acurácia, com média de desempenho correspondente a cerca de 0,8, o que corrobora para a noção que a utilização de técnicas de *deep learning* oferece delineamentos consistentes da cobertura vegetal urbana em diferentes arquiteturas e contextos.

6. SEGUNDO CAPÍTULO: IDENTIFICAÇÃO DE ARBORIZAÇÃO NO CONTEXTO DA RMRJ


6.1 Objetivos

Este capítulo tem como objetivo gerar, avaliar performance e analisar quantitativamente a identificação de arborização no contexto da Região Metropolitana do Rio de Janeiro, usando como base produtos do sensoriamento remoto e técnicas de *deep learning*.

6.2 Operacionalização

Neste tópico serão apresentados os dados, plataformas e métodos utilizados para a produção da identificação de arborização nos limites da RMRJ utilizando técnicas de *deep learning*. O fluxograma de procedimentos (figura 10) descreve e esquematiza as principais etapas de operacionalização deste estudo. Neste fluxograma, o ponto de partida, como observa-se na figura 10, é a definição de dados e softwares a serem utilizados; subsequentemente, são iniciadas as etapas dos processos para identificação da arborização em contexto urbano, desde a coleta de amostras, treinamento do modelo utilizado e, por fim, a classificação. Após isso, é verificada a acurácia do dado produzido a partir de processos de validação, o que precede as análises e representações do produto.

Figura 10: Fluxograma de operacionalização capítulo 2.



Fonte: O autor (2025).

6.2.1 Dados e softwares utilizados

6.2.1.1 Projeto espacial Planet

O projeto espacial Planet revolucionou a indústria da observação da terra. Isso porque este projeto espacial, que tem como objetivo declarado gerar imagens diárias para facilitar a identificação de alterações na superfície terrestre, tornou possível o acesso a dados orbitais diários para setores que extrapolaram os mais tradicionais, como da agricultura e da defesa (Planet, 2023). Segundo a própria Planet, seus dados hoje são de indubitável importância, trazendo contribuições que mitigam riscos e desenvolvem soluções inovadoras para enfrentar os mais diferentes desafios socioambientais prementes.

O surgimento das chamadas “constelações de nanossatélites” possuem indubitável influência na grande tendência mundial de aumento de produção de dados satelitários (Taquary, 2019). Isso se dá porque, nessa metodologia, são lançados à órbita diversos satélites de pequeno porte e em baixas órbitas. Esses nanossatélites orbitam, em conjunto e de forma sincronizada, ao redor da terra (Cunha et al., 2022); isso faz com que, dado o cenário, ocorra uma alta taxa de visitação (Teixeira et al., 2020). A Planet desenvolve seus dados a partir da metodologia de constelação de nanossatélites: a constelação PlanetScope.

Especificamente no caso Planet, a constelação conta, atualmente, com mais de 200 nanossatélites em órbita que geram imagens de toda a superfície terrestre desde 2015. Esses nanossatélites são do tipo Dove e possuem sensores com as mesmas especificações. Sua constelação possui órbita circular, heliosíncrona ou da Estação Espacial Internacional, descendente e pode variar entre as altitudes de 390 a 500 Km. Tais especificações permitem uma revisita diária dos satélites (Saraiva et al., 2020).

No que tange os produtos gerados pelo projeto espacial Planet, tratam-se de imagens que são disponibilizadas já ortorretificadas, com correção atmosférica, equalização e correção de cores; possuem resolução espacial de cerca de 3 metros, resolução radiométrica de 12 bits, resolução temporal de 1 dia e, hoje, pode chegar até 8 bandas espectrais: azul (455-515 nm), verde (500-590 nm), vermelho (590-670 nm), infravermelho próximo (780-860 nm), azul costal, verde I, amarela e a borda do

vermelho. Ademais, a câmera utilizada nos nanossatélites é a Bayer Mask CCD, com uma cena básica de tamanho entre 20 km x 12 km e 24.6 km x 16.4 km em nadir.

Apesar disso, este estudo não utiliza as cenas originais disponibilizadas pela Planet como base para a aplicação metodológica e análises. Aqui, trabalha-se com o produto de mosaicos mensais produzidos e disponibilizados pela Planet. Os mosaicos são construídos para o intervalo de um mês; ou seja, mensalmente são disponibilizados mosaicos de imagens contínuas referentes ao mês anterior. Estes mosaicos possuem 4 bandas (RGB e NIR) e passam pelos mesmos processos de correção encontrados nas imagens individuais por cena. A resolução espacial dos mosaicos é de 4.77 metros e eles são disponibilizados desde 2015 - vale ressaltar que a disponibilização dos mosaicos entre 2015 e 2020 era bi-anual e, a partir de meados de 2020, passaram a ser disponibilizados mensalmente.

A escolha de trabalhar com os mosaicos ao invés das cenas individuais se deu em decorrência de alguns aspectos de extrema relevância. A produção de mosaicos mensais conseguiu eliminar grande parte de problemas inter-sensores, por intermédio do processo de normalização de imagens que foi adotado, que gera uma maior coerência espectral e radiométrica entre diferentes regiões do mosaico (Taquary, 2019). Além disso, a visita diária dos nanossatélites permitiu que os mosaicos fossem produzidos com a menor quantidade de nuvem possível para o seu respectivo mês de referência. Por fim, um importante diferencial para escolha dos mosaicos foi sua disponibilização gratuita a partir do programa norueguês NICFI.

No que tange o *NICFI Satellite Data Program*, trata-se de uma iniciativa internacional da Noruega que tem enfoque na mitigação de problemas climáticos e florestais. Através do programa NICFI, o governo Norueguês se compromete a contribuir com 3 bilhões de NOK (moeda norueguesa) por ano para salvar florestas tropicais do mundo. Este programa surgiu em 2020 a partir de um contrato internacional do Ministério do Clima e Meio Ambiente da Noruega e o Kongsberg Satellite Services (KSAT) - além de outros parceiros como Airbus e Planet - para o fornecimento de monitoramento de alta resolução por satélite nos trópicos. Com tal programa, a Planet passa a disponibilizar gratuitamente imagens de alta resolução entre os trópicos para usuários que possuam objetivos análogos aos da NICFI: conservação e reflorestamento de florestas tropicais, combate às mudanças climáticas, conservação de biodiversidade e desenvolvimento sustentável. Sendo

assim, componentes de órgãos de proteção ambiental, academias, pesquisas ambientais, dentre outros, podem ter acesso gratuito às imagens Planet, que podem ser acessadas por Geo Serviço, extensões em software SIG ou pelo Google Earth Engine. No entanto, há limitações.

Neste programa, NICFI, existem três níveis de acesso aos dados Planet: nível 0, nível 1 e nível 2. No primeiro caso, nível 0, os dados são abertos ao público apenas para visualização dos mosaicos já produzidos e os que ainda serão disponibilizados. Esse acesso acontece a partir de sites “*Purpose Ally*”, que são sites que envolvem o público no monitoramento de florestas, como é o caso do *Global Forest Watch*. Já no segundo caso, nível 1, é permitido acessar, visualizar e baixar os mosaicos Planet, que podem ser baixados da plataforma Planet ou via integração da Planet, como no Google Earth Engine, por exemplo. Neste nível de acesso, é necessário que o usuário realize um cadastro e comprove que faz parte de alguma instituição que possua objetivos que conversem com os do programa. O terceiro e último nível de acesso, o nível 2, é mais restrito, chamado de “parceiros selecionados”. Neste caso, só terão acesso os parceiros selecionados pelo Ministério do Clima e do Meio Ambiente da Noruega. No geral, apenas instituições governamentais ligadas à preservação e controle ambiental. Aqui, além das cenas da Planet e dos mosaicos mensais, poderão ser acessados os dados orbitais da Airbus desde o ano de 2002. Por fim, destaca-se que o programa foi descontinuado em 2024, mas todos os dados licenciados por meio deste programa podem ser livremente utilizados após o seu término (Planet, 2023).

Para a proposta deste estudo, o nível 2 atendeu às demandas. Nesse sentido, espera-se que os dados Planet atendam à escala operacional de mapeamento adotada pelo estado do Rio de Janeiro, uma vez que a última produção mais detalhada de uso e cobertura do solo para todo estado possui escala de 1:25.000.

Baseando-se no equilíbrio entre registro mais recente e qualidade da imagem (menor quantidade de nuvens, sombra e ruído), o período do ano escolhido para classificação da imagem foi entre maio e setembro - período de estiagem no estado do Rio de Janeiro. A escolha deste intervalo para seleção de imagens para classificação está fundamentada nas condições climáticas da área, que, por sua vez, interferem diretamente nos registros orbitais. O Sudeste brasileiro é marcado por um regime climático sazonal, onde ocorre uma mais elevada concentração de chuvas no verão e, em contrapartida, ocorre uma redução significativa dessa elevada umidade e

precipitação no período outono-inverno, onde ocorre a predominância de massas de ar mais secas e estáveis (Nobre et al., 2012; Alvalá et al., 2017). Além disso, a umidade também pode interferir na qualidade radiométrica das imagens, uma vez que o ar mais seco diminui absorção e espalhamento da radiação eletromagnética, o que significa uma maior confiabilidade na captação da reflectância atmosférica (Kaufman & Tanré, 1996).

Ao analisar os dados disponíveis dentro do período pré definido para seleção da imagem, o mosaico de maio de 2024 foi selecionado para este estudo, uma vez que apresentou boa nitidez e baixa umidade atmosférica. Este mosaico, que conta com 4.77 metros de resolução espacial e bandas *Red*, *Green*, *Blue* e *NIR*, foi adquirido via Google Earth Engine (GEE).

6.2.1.2 *Softwares* e plataformas

A seleção e aquisição do mosaico Planet utilizado neste estudo para identificação da arborização em contexto metropolitano foi realizada via plataforma Google Earth Engine.

A plataforma GEE pode ser caracterizada como uma plataforma gratuita que realiza processamento computacional em nuvem de dados georreferenciados (Carvalho et al., 2021). Nesta plataforma, que utiliza majoritariamente a API *JavaScript*, é possível adquirir, manusear e processar dados de forma mais acelerada e simplificada, sem que seja necessário alto nível de conhecimento em programação (Silva et al., 2023). O GEE se destaca, sobretudo, por possuir um grande inventário de dados disponível em seu acervo, como imagens de sensores orbitais, de terreno, temperatura, dentre outros (Silva et al., 2023), e é neste inventário que os mosaicos Planet são adicionado quando o usuário está credenciado no programa NICFI.

Além do GEE, o ArcGIS Pro também foi utilizado para manuseio e processamento de dados espaciais. Esta plataforma, que se constitui atualmente como uma das principais entre os Sistemas de Informação Geográfica (SIG), pode ser definida como um ambiente computacional de geoprocessamento integrado, onde é permitida a manipulação, visualização, análise e modelagem de dados geoespaciais (Esri, 2020). Desse modo, o ArcGIS Pro é de extrema relevância para trabalhos que utilizam dados geoespaciais, sobretudo por sua capacidade de unificação de diferentes fontes de dados em uma única plataforma, o que permite análises em

diferentes escalas e áreas do conhecimento (Tomlinson, 2019). Para garantir o pleno funcionamento, crescente ampliação da compatibilidade de facilidade de compartilhamento de dados, a infraestrutura do ArcGIS Pro é continuamente atualizada, o que permite que, atualmente, já seja possível realizar conexão com ambientes de aprendizado de máquina (Zhou et al., 2019). As técnicas de *deep learning*, de forma análoga, foram recentemente incorporadas ao ArcGIS Pro a partir de ferramentas que possibilitam o treinamento, validação e execução de modelos que utilizam estruturas de redes neurais convolucionais (Esri, 2021). Sendo assim, este estudo utilizou este software, ArcGIS Pro, para realização do produto deste estudo, desde a coleta de amostras para treinamento do modelo, até a análise e representação do dado gerado.

6.2.2 Coleta de amostras


Para criação e processamento do modelo de identificação de arborização na RMRJ utilizando técnicas de *deep learning*, necessitou-se, inicialmente, da criação de amostras poligonais de vegetação arbórea. A coleta de amostras, em sua gênese, foi pensada de forma manual, por meio da delimitação criteriosa de cerca de 1600 polígonos em imagens orbitais, visando identificar áreas representativas e diversificadas de arborização metropolitana. No entanto, este método de coleta de amostras se revelou ineficiente devido ao elevado volume de amostras necessário para entrega de bons resultados em modelos de aprendizado profundo - fato já apontado em estudos prévios (Zhou et al., 2019; Li et al., 2022). Sendo assim, para auxiliar na coleta volumosa de amostras, recorreu-se a outras fontes de dados de arborização.

Sob tal demanda, um importante mapeamento produzido pela World Resources Institute (WRI) para identificação de arborização foi utilizado como base para coleta de amostras neste estudo. Com gênese a partir da lacuna existente na compreensão científica da estrutura e extensão das florestas globais (Meta, 2024), a WRI, em parceria com a Meta, elaborou um produto que representa um importante marco recente e inovador de dados globais de cobertura vegetal e altura do dossel de árvores (Meta, 2024). Este mapeamento, que informa localização, forma e altura da copa das árvores identificadas, possui destaque, dentre outras coisas, pela utilização de

modelos de aprendizado profundo, imagens orbitais de altíssima resolução (Maxar), radar e Lidar aéreo. Sendo assim, este produto foi utilizado como suporte para coleta de amostras.

No entanto, apesar de servir como suporte para coleta de amostras, foram realizadas filtragens nos dados da WRI antes de sua utilização. A priori, foi realizada uma seleção de áreas no limite da RMRJ para coleta de amostras. Essa seleção se baseou na tentativa de captar diferentes e representativas respostas da cobertura arbórea na RMRJ para que, dessa forma, o modelo construído realizasse a identificação dos distintos tipos de vegetação arbórea existentes na área, bem como as diferentes misturas espectrais encontradas a depender do seu entorno. A figura 11 mostra a distribuição das amostras selecionadas. Como é possível notar na imagem, buscou-se coletar amostras em grandes e pequenos fragmentos de vegetação inseridos em ambiente urbanizado. Em complemento, dada a necessidade observada a partir do produto gerado, também foram coletadas amostras de vegetação menores que 1 hectare em áreas intensamente urbanizadas, como é o caso de alguns municípios da Baixada Fluminense. Essa abordagem buscou contemplar as características espectrais mistas típicas dessas áreas, onde a vegetação ocorre de forma bem fragmentada e inserida em um contexto urbano predominantemente artificial.

Figura 11: filtro inicial de amostras: seleção em áreas de interesse.




Fonte: O autor (2025).

Posteriormente, outros filtros foram utilizados para refinamento das amostras selecionadas. Desta vez, a filtragem utilizou como auxílio o Índice de Vegetação por Diferença Normalizada (NDVI).

O Índice de Vegetação por Diferença Normalizada, que pode variar entre os valores de -1 e 1 e é resultado do cálculo da razão entre a diferença e soma das bandas do infravermelho próximo (NIR) e vermelho, é uma das métricas mais utilizadas em estudos de sensoriamento remoto que analisam presença, vigor e densidade da vegetação utilizando como base a resposta espectral da superfície terrestre (Rouse et al., 1974). Isso se dá porque a vegetação, sobretudo as mais saudáveis, tendem a absorver intensamente a radiação no espectro do vermelho e, em contrapartida, no caso do infravermelho próximo, ocorre uma forte reflexão (Tucker, 1979; Jensen, 2016). Nesse sentido, por gerar um destaque em áreas vegetadas, quanto maiores os valores de NDVI em uma imagem, maior a atividade fotossintética, o que indica presença de vegetação (Pettorelli, 2013). Por outro lado, valores próximos de zero ou negativos geralmente indicam ausência de vegetação, como corpos d'água e áreas urbanizadas (Huete et al., 2002).

Em decorrência do supracitado, gerou-se o índice de vegetação para a imagem escolhida neste estudo (figura 12), que, por sua vez, foi base para a extração valor da média NDVI de cada um dos polígonos que se mantiveram após a primeira filtragem. Com isso, fez-se uma seleção dos polígonos que apontavam média do índice superior a 0,6, com a intenção de que fossem descartados os polígonos erroneamente classificados como vegetação pela WRI - o que comprometeria a coleta de amostras e, conseqüentemente, a assertividade do modelo.

Figura 12: Índice NDVI gerado para a RMRJ.



Fonte: O autor (2025).

6.2.3 Processamento dos dados

Com o conjunto de amostras definido, o que totalizou cerca de 450 mil polígonos, os dados foram processados no ArcGIS Pro. Primeiramente, utilizou-se a ferramenta “*Export Training Data for Deep Learning*” para converter os dados vetoriais em conjuntos de treinamento adequados para *deep learning*, com base em imagens de sensoriamento remoto. Em seguida, o modelo foi treinado com a ferramenta “*Train Deep Learning Model*”, o que gerou um arquivo no formato DLPK - que é um pacote de modelo de aprendizado profundo utilizado no ambiente ArcGIS Pro. Posteriormente, aplicou-se a ferramenta “*Classify Pixels Using Deep Learn*” para classificar a imagem de interesse conforme o modelo treinado e as amostras coletadas. Essa metodologia integrada possibilitou a geração da identificação da arborização na RMRJ, o que contribui para a compreensão espacial e planejamento ambiental no contexto metropolitano.

Por fim, vale apontar que os processos de exportação do treinamento, treinamento e classificação foram realizados duas vezes para criação de diferentes versões de treinamento do modelo e, dessa forma, duas diferentes saídas.

Inicialmente, foi realizado o mapeamento baseado na imagem planet com apenas as bandas do visível (RGB), com a intenção de que o modelo pudesse ser replicado em imagens que contém apenas as bandas do visível. Destaca-se que, neste caso, a coleta e exportação de amostras foi baseada em uma imagem com composição RGB, bem como a aplicação do modelo já produzido a partir da amostragem. Em seguida, os processos foram aplicados a uma imagem apenas com a banda NDVI, índice gerado com base nas bandas do vermelho e infravermelho próximo. Bem como no caso anterior, todos os processos foram gerados com base na imagem com apenas a banda NDVI. Foram desenvolvidas essas duas versões do modelo e identificação porque também se objetiva entender a performance do modelo com diferentes recursos, o que dá luz ao entendimento do método mais adequado para identificação arbórea na urbe.

6.2.4 U-Net: a arquitetura de rede neural convolucional utilizada

O método empregado para realização da identificação arbórea em ambiente urbanizado foi a arquitetura de rede neural convolucional U-Net. As Redes Neurais Convolucionais são um tipo de rede neural que realiza o processamento de dados de forma matricial (Nicolau, 2020). Seu surgimento se deu em decorrência da dificuldade encontrada ao trabalhar com imagens em redes neurais clássicas - consequência da utilização de um elevado número de pesos (Sacadura, 2021). Dado o entrave, as CNNs, como o próprio nome sugere, realizam em suas camadas a operação matemática de convolução, onde são aplicadas generalizações ao dado de entrada, o que pode diminuir sua resolução final. Desse modo, tais redes são ideais para estudos com imagens, sobretudo se o dado de entrada, a imagem, possuir elevada complexidade e grande extensão.

A U-Net surgiu para segmentação semântica de imagens ainda em 2015, cunhado por Olaf Ronneberger, Philipp Fischer e Thomas Brox a partir da publicação "*U-Net: Convolutional Networks for Biomedical Image Segmentation*". Esses autores trouxeram uma proposta de aprimoramento de um estudo desenvolvido por Evan

Shelhamer, Jonathan Long e Trevor Darrell e apresentado no ano anterior, 2014, que trata sobre as chamadas Redes Totalmente Convolucionais (FLC - Fully Convolutional Networks) (LeCun et al., 2015). No mesmo ano em que foi publicado por Ronneberger et al., 2015, a arquitetura U-Net foi vencedora de um relevante desafio de detecção de células, o ISBI (*International Symposium on Biomedical Imaging*). Neste simpósio, a U-Net possuiu importante destaque, o que atraiu atenção e significância para esta arquitetura de Redes Neurais Convolucionais.

Os autores que produziram a estrutura U-Net buscaram, inicialmente, dar suporte a atividades de detecção, quantificação celular e estudo de formas no que tange a segmentação de imagens biomédicas (Diniz, 2020). Uma das principais motivações para o desencadeamento deste estudo foram os problemas de localização existentes no dado final quando aplicados a Redes Neurais Convolucionais tradicionais (Diniz, 2020). As redes neurais convolucionais tradicionais, base para o desenvolvimento da U-Net, em casos de aplicação biomédica, não possuem desempenho satisfatório. Isso se dá porque em muitos casos na biomedicina uma resposta puramente binária para uma doença não é o suficiente, uma vez que a localização exata da anomalia detectada é de suma importância (Diniz, 2020). De forma resumida, essa degradação da informação localizacional é acarretada principalmente pelos processos de convolução. Como já citado, nesta etapa, a imagem é convoluída várias vezes, ou seja, generalizada. Nesse contexto, a capacidade de localização precisa é perdida. Após isso, para reversão do problema sem que haja perda do resultado adquirido, são realizadas convoluções transpostas no resultado anteriormente produzido. As convoluções transpostas expandem novamente a imagem até o seu tamanho original ou próximo a ele (Diniz, 2020). Dessa forma, é recuperada a capacidade de análises baseadas em localização.

Dado contexto e motivação de surgimento, a U-Net pode ser caracterizada como uma solução de Aprendizado Profundo que possui estrutura de Redes Neurais Convolucionais. Esta arquitetura não possui camadas completamente conectadas, utiliza apenas a parte considerada válida das convoluções aplicadas e permite o trabalho com imagens mais pesadas e complexas (LeCun et al., 2015). Com a U-Net, o objetivo central é a classificação de imagens, onde a entrada é uma imagem e a saída um dado rotulado, que, nos dois casos, possuem mesma resolução (LeCun et al., 2015). Destaca-se, além disso, a avançada capacidade da rede de localizar e


distinguir padrões em uma imagem, obtendo-se ótimos resultados mesmo em casos onde o conjunto de dados de treinamento não é muito significativo (Diniz, 2020).

A rede U-Net possui estrutura que se assemelha à letra “U”, como é possível visualizar na figura 13. Isso se dá porque essa rede neural possui simetria quase perfeita em seus dois lados (Diniz, 2020). Essa estrutura em “U” é dividida em duas fases. Na rede, a parte à esquerda é intitulada etapa de contração (ou *downsampling*) e nela é seguida a mesma metodologia de uma típica Rede Neural Convolucional. Ou seja, são feitas convoluções, onde cada uma das convoluções é seguida pela função de ativação ReLu e, além disso, por uma operação de max pooling. Como já explanado, o impacto disso é a generalização matricial do dado, onde a resolução, na maioria das vezes, é diminuída à metade. Entraves com precisão de localização são então criados.

Por outro lado, no que tange a porção direita da rede, ocorre, quase simetricamente à etapa anterior, a fase de expansão. Neste caso, a construção também se dá a partir de blocos de convolução. Em cada um dos blocos, é aplicada uma convolução transposta. Diferente do que acontece na convolução tradicional, a convolução transposta é uma técnica de *upsampling*, onde ocorre uma expansão do dado de entrada; Ou seja, seu funcionamento é o oposto do que realiza o *downsampling*. Dessa forma, com o dado matricial de volta, ou próximo, à sua resolução inicial, questões ligadas à imprecisão de localização são resolvidas.

Assim, por apresentar um bom desempenho ao classificar dados matriciais, esta arquitetura de redes neurais convolucionais foi escolhida como método de classificação de aprendizagem profunda neste estudo.

Figura 13: Arquitetura U-Net.



Fonte: adaptada de Ronneberger, Fischer e Brox (2015) apud Ruiz et al., 2021.

6.2.5 Delimitação de área urbanizada

Para além da análise do dado de identificação da arborização em todo território metropolitano, neste estudo a vegetação inserida apenas na mancha urbana também foi avaliada. Nesse sentido, surge a demanda de um mapeamento de área urbana preexistente que converse com a escala de análise dos dados aqui utilizados. Sob tais requisições, foi escolhido o Mapeamento de Cobertura e Uso da Terra do CAR, financiado e disponibilizado pelo governo estadual do Rio de Janeiro.

Com coordenação de execução do laboratório ESPAÇO de Sensoriamento Remoto e Estudos Ambientais da Universidade Federal do Rio de Janeiro, o mapeamento do CAR surge da necessidade de atendimento às demandas do Cadastro Ambiental Rural (CAR) e, outrossim, do monitoramento das áreas de Mata Atlântica para suporte ao combate do desmatamento e outras práticas ilícitas. Nesse sentido, segundo a relatoria do estudo, para o atendimento dessas e outras demandas estaduais, a escala 1:25.000 ou maiores são satisfatórias.


Para produção do dado, foram utilizadas imagens entre os anos de 2013 e 2016. Dentre os produtos orbitais estão imagens World View (reamostrada para 2 metros de resolução espacial), RapidEye (5 metros de resolução espacial), Landsat 5 e 8 (30 metros de resolução espacial) e o Modelo Digital de Elevação SRTM (30

metros de resolução espacial). Conforme exposto, foram utilizados produtos com especificações diferentes, que, em conjunto, atendem à escala proposta.

Como resultado final, as classes foram divididas em Áreas Antrópicas Não Agrícolas (ANA); Áreas Antrópicas Agropastoris (AAG), Áreas Antrópicas Agropastoris não consolidadas (AAG_N_CONS); Silvicultura; Áreas de Vegetação Florestal (ANF); Mangue; Restinga; Áreas Naturais (NNF); e, por fim, Corpos d'água.

A classe de Áreas Antrópicas Não Agrícolas (ANA) engloba matrizes de área urbana em seus mais diferentes níveis, bem como áreas residenciais, comerciais, industriais, de mineração, agrícola e, por fim, solo exposto e redes viárias associadas a núcleos urbanos. A vegetação intra urbana, sobretudo no caso de fragmentos menores que 5.000 metros quadrados, também é pertencente a essa classe. Desse modo, por atender às demandas deste estudo e, ademais, por fazer parte do mapeamento oficial do estado mais detalhado e recente, a classe ANA, que pode ser visualizada na figura 14, foi definida como o perímetro urbano a ser utilizado neste estudo para análises.

Figura 14: Mapa de localização da Região Metropolitana do Rio de Janeiro + área urbanizada.



Fonte: O autor (2024).

6.2.6 Validação do produto

A validação dos diversos produtos cartográficos que podem ser elaborados a partir de técnicas de sensoriamento remoto é uma etapa indispensável para aferição de confiabilidade, assertividade e, sendo assim, qualidade dos dados. Em contextos em que o mapeamento gerado objetiva a identificação de uma única classe - como, por exemplo, arborização, que é objeto de análise neste estudo - a utilização de métodos mais clássicos de validação multiclasse, como o índice Kappa, torna-se inadequada, uma vez que o desenvolvimento dessas metodologias de validação se deu para avaliação de concordância entre múltiplas categorias, o que pode fazer com que a análise não reflita adequadamente o desempenho de mapeamentos monoclasse (Foody, 2002). Sendo assim, a validação binária a partir da construção de uma matriz de confusão com duas classes (classe-alvo e não classe-alvo) apresenta uma mais coerente abordagem metodológica, sobretudo em casos em que a classe de interesse representa uma menor proporção espacial na superfície analisada, que é o que acontece, na maioria das vezes, quando se tem a vegetação em áreas densamente urbanizadas como objeto de análise.

Dessa forma, para a avaliação dos dados gerados neste estudo, utilizaram-se métodos de análise adequados para mapeamento monoclasse: acurácia do usuário; acurácia do produtor; F1-score; exatidão global; e índice de Jaccard (IoU). No caso da acurácia do usuário, é indicada a proporção de áreas corretamente classificadas em relação ao total. Assim, tem-se a avaliação da confiabilidade do mapeamento, o que é útil para vencer entraves ligados aos falsos positivos (Congalton; Green, 2009). A acurácia do produtor, de forma complementar, indica a proporção da classe de interesse que foi corretamente detectada no mapeamento, o que contribui para mensuração da capacidade do modelo de evitar casos em que ocorram falsos negativos (Olofsson et al., 2014). A combinação dessas duas métricas supracitadas é representada pelo F1-score, que faz uma média harmônica entre precisão e sensibilidade.

Além dessas, a exatidão global, comumente utilizada também para validações multiclasse, expressão percentual total de acertos presentes na matriz de confusão, a partir da análise de todas as amostras. A utilização desta métrica neste estudo se dá,

sobretudo, porque ela é capaz de gerar uma estimativa mais geral de desempenho. Apesar de sua eficiência na análise, orienta-se a utilização deste método de validação acompanhado a outro conjunto de métricas para descarte de possíveis interpretações equivocadas em decorrência da predominância de uma determinada classe (Olofsson et al., 2014).

Por fim, também utilizado para mensuração da qualidade dos dados produzidos, o Índice de Jaccard - que também é conhecido como *Intersection over Union*, vem obtendo grande destaque em decorrência de sua alta capacidade de avaliar a semelhança espacial entre os dados classificados e os de referência (Zhou et al., 2019; Li et al., 2022). Este índice é particularmente indicado para validações binárias, como a que ocorre neste estudo. Isso se dá porque, de forma simultânea, consideram-se os acertos da classificação e os erros por comissão e omissão. Desse modo, com a utilização de pontos amostrais extraídos de forma aleatória e, neste caso, estratificada, é viabilizada a quantificação da presença ou ausência da classe de interesse tanto no mapeamento gerado, quanto na referência (Congalton & Green, 2009) - o que permite a construção da matriz binária e, com isso, o cálculo do índice em questão. Vale destacar que esta métrica se diferencia das demais, como a exatidão global, por exemplo, em decorrência de sua menor tolerância a erros de omissão e comissão, o que entrega um resultado da validação mais robusto e exigente. Por isso, estudos mais recentes vêm utilizando este método de validação e destacando a sua eficácia, sobretudo no que tange a classificações geradas por métodos e ferramentas de aprendizado profundo em dados multi e hiperespectrais (Ribeiro, 2023).

Nesse sentido, para a construção das métricas de validação supracitadas dos dados gerados, optou-se por empregar uma amostragem estratificada, técnica que assegura representatividade equilibrada e homogeneidade dos grupos amostrais. Silva et al. (2014), em seu estudo, relata que em ambientes com elevada heterogeneidade espacial - como nas áreas urbanas ou de vegetação fragmentada -, a amostragem estratificada de validação proporciona estimativas mais precisas em relação aos métodos sistemáticos simples.

Desse modo, essa abordagem foi implementada neste estudo por meio da geração de 500 pontos aleatórios para a classe vegetação em toda RMRJ e outros 500 para a classe não vegetação na mesma delimitação, na tentativa de garantir


equilíbrio amostral e mitigando, assim, possíveis vieses decorrentes da predominância de uma delas na área analisada. De forma complementar, a vegetação gerada para toda a RMRJ foi recortada apenas para a mancha urbana da RM, a fim de estudos de desempenho específicos para esta área. Nesse sentido, foram redistribuídos mais 500 pontos para a classe vegetação inserida na mancha urbana da RMRJ, e mais 500 para a não-vegetação do mesmo perímetro urbano. Vale ressaltar que, neste estudo, a chamada “vegetação” da RMRJ faz referência apenas a vegetação arbórea, assim como a classe não-vegetação diz respeito às áreas onde há ausência de vegetação arbórea.

Sendo assim, este procedimento de distribuição de pontos foi replicado nas quatro versões distintas do mapeamento: uso de composições RGB abrangendo toda a Região Metropolitana do Rio de Janeiro (RMRJ); aplicação de RGB restrita à zona urbanizada da RMRJ; uso do índice NDVI para toda a RMRJ; e uso do NDVI limitado à área urbanizada. Em cada uma das versões, foram analisados 1.000 pontos (500 por classe), totalizando 4.000 amostras individuais. A averiguação da classe em que cada ponto se encontrava (vegetação ou não-vegetação) foi realizada mediante inspeção direta sobre a própria imagem de sensoriamento remoto utilizada no processo de classificação, assegurando, assim, a coerência metodológica entre o dado de referência e o dado classificado. Complementarmente, empregou-se o Google Earth Pro como fonte de apoio para a validação visual, principalmente em casos de maior incerteza ou ambiguidade, sempre considerando a escala de análise como fator fundamental para evitar distorções interpretativas. Por fim, vale ressaltar que não foi realizada nenhuma espécie de edição manual ou via software do dado produzido antes da aplicação das métricas de validação ou análises espaciais.

6.3 Resultados e discussões


Como resultado dos procedimentos metodológicos anteriormente relatados, foram gerados para a RMRJ dois mapeamentos de arborização, um utilizando como base uma imagem orbital com composição RGB e o outro utilizando o NDVI, dados que podem ser observados nas figuras 15 e 16, respectivamente.

Figura 15: Mapeamento de vegetação arbórea na RMRJ (RGB).



Fonte: O autor (2025).

Figura 16: Mapeamento de vegetação arbórea na RMRJ (NDVI).



Fonte: O autor (2025).

Ao analisar os resultados gerados, inicialmente, vê-se grande semelhança entre os dois mapeamentos, com similar distribuição e forma dos fragmentos. No caso do mapeamento gerado com a composição RGB, foi detectada área de 343.257,83 hectares de vegetação inserida em ambiente metropolitano. Já no mapeamento gerado utilizando o NDVI, foi identificada área de vegetação metropolitana correspondente a 352.093,77 hectares. Sendo assim, entre os mapeamentos ocorreu uma diferença de área de pouco mais de 8.800 hectares - o que buscou ser investigado. No geral, os dois mapeamentos apresentaram um bom desempenho, onde foi possível detectar pequenas áreas de vegetação inseridas em ambiente urbanizado e, além disso, foi encontrada boa precisão no delineamento dos polígonos de vegetação, mesmo os que não apresentavam forma mais regular/geométrica. Como exemplo disso, têm-se as imagens 17 e 18, que trazem exemplos da identificação de vegetação na RMRJ passíveis de visualização em imagem Planet (base para a classificação) e em Worldview (que possui maior detalhamento e foi utilizada para a validação dos dados).

Figura 17: Área-exemplo do mapeamento de arborização (RGB) - Barra da Tijuca/RJ. Polígonos com contorno amarelo representam a vegetação detectada.



Fonte: O autor (2025).

No caso da imagem 17, que traz o resultado do mapeamento realizado com RGB, é possível observar que ocorreu uma satisfatória classificação de áreas vegetadas, mesmo que inseridas em meio majoritariamente urbanizado. A precisão

do mapeamento fica visualmente mais perceptível se o olhar é direcionado à imagem WorldView, apresentada à direita, onde é possível visualizar com maior detalhamento as áreas vegetadas na imagem. Dinâmica análoga acontece ao observar a imagem U, que traz o mapeamento produzido com o NDVI, onde também demonstra boa precisão na identificação de arborização a partir de uma análise visual.

Figura 18: Área-exemplo do mapeamento de arborização (NDVI) - Barra da Tijuca/RJ. Polígonos com contorno verde representam a vegetação detectada.



Fonte: O autor (2025)

Em complemento, as imagens 19 e 20, representadas pelos mapeamentos baseados em RGB e NDVI, respectivamente, também trazem áreas-exemplo da classificação produzida - passíveis de visualização em imagens Planet e WorldView. Nestes casos, exemplos de uma área na Ilha do Governador (RJ), observam-se fragmentos de vegetação pouco maiores, mas ainda introduzidos em ambiente urbanizado. Aqui, também se observa uma boa assertividade a partir de análise visual da delimitação dos polígonos, fato que mostra um bom desempenho na delimitação de fragmentos maiores.

Figura 19: Área-exemplo do mapeamento de arborização (RGB) - Ilha do Governador/RJ. Polígonos com contorno amarelo representam a vegetação detectada.



Fonte: O autor (2025).

Figura 20: Área-exemplo do mapeamento de arborização (NDVI) - Ilha do Governador/RJ. Polígonos com contorno verde representam a vegetação detectada.




Fonte: O autor (2025)

No entanto, apesar dos dois mapeamentos apresentarem semelhanças, com a análise mais detalhada da identificação de arborização, foi possível perceber diferenças entre os produtos. Apesar de os dois mapeamentos apresentarem um bom desempenho a partir de análises iniciais realizadas de forma visual, notou-se, sobretudo em casos de ocorrência de vegetação com áreas menores e em entornos

mais intensamente urbanizados, uma maior dificuldade na precisão da demarcação dos limites da vegetação identificada - Exemplo disso pode ser observado na figura 21. Nesta figura (21), que apresenta registros orbitais Planet e os mapeamentos com base no RGB e no NDVI, é possível observar um exemplo claro do relato anterior, onde o mapeamento RGB, aparentemente, deixa de mapear bordas de área vegetada, diminuindo seus limites e apresentando confusões na delimitação, onde parte da borda dos pequenos fragmentos de vegetação são desconsiderados. Este destaque fica ainda mais claro quando se observa de forma sobreposta os dois mapeamentos na imagem.

Figura 21: Área-exemplo da identificação de arborização, com polígonos verdes referenciando o produto NDVI e polígonos amarelos, produto RGB.



Fonte: O autor (2025).

Outrossim, vale destacar outra característica muito recorrente no que tange o mapeamento RGB: detecção de corpos hídricos. Conforme pode ser observado em exemplos nas figuras 22 e 23, ocorreram diversos casos em que o modelo, ao

classificar a imagem, coloca a água como vegetação. A figura 22 mostra um caso assim, onde é possível observar que o mapeamento RGB gerou diversos polígonos no interior de um corpo hídrico. Isso não acontece de forma tão intensa no caso do mapeamento gerado com base no NDVI, conforme é possível visualizar na imagem, onde não é constatada a presença de polígonos ao centro do mesmo corpo d'água.

Figura 22: Área-exemplo do mapeamento de arborização (RGB e NDVI) - Maricá/RJ. Polígonos verdes referenciam o produto NDVI e polígonos amarelos, produto RGB.



Fonte: O autor (2025).

De maneira análoga, a figura 23 traz outro exemplo onde o mapeamento RGB acaba confundindo água com vegetação. Neste caso, enquanto o mapeamento NDVI contorna mais precisamente os limites entre a água e a vegetação, o dado RGB parece generalizar mais, não fazendo uma boa separação entre água e vegetação. Essa característica do mapeamento RGB também pode ser observado em um exemplo anteriormente apresentado (figura 17), onde o modelo não foi capaz de separar a vegetação do canal que corta a área-exemplo. Diferente do RGB, o produto NDVI desta área (figura 18) apresenta uma superior capacidade de separação da água e da vegetação contida na imagem, contornando mais precisamente o limite entre a vegetação e o canal existente.

Figura 23: Área-exemplo da identificação de arborização (RGB e NDVI) - Barra da Tijuca/RJ. Polígonos verdes referenciam o produto NDVI e polígonos amarelos, produto RGB.



Fonte: O autor (2025).

Essa discrepância de performance na separação da vegetação e com corpo hídrico entre os mapeamentos gerados (um apenas com as bandas do visível e o outro com o NDVI) já foi encontrada em diversos estudos. Isso se dá porque as imagens RGB trabalham exclusivamente com a faixa do espectro visível, o que limita a discriminação entre diferentes alvos, sobretudo em áreas onde a resposta espectral de corpos d'água e de vegetação pode se confundir devido à similaridade de tons e à interferência de sombras (Jensen, 2016). Por outro lado, o NDVI, que é construído baseado nas bandas *NIR* e *RED*, destaca a alta reflectância da vegetação no NIR e a forte absorção na banda do vermelho em função da atividade fotossintética (Rouse, 1973). Essa diferença faz com que a vegetação apresente valores de NDVI elevados e positivos, enquanto a água, que absorve grande parte da radiação tanto no vermelho quanto no infravermelho próximo, tende a apresentar valores muito baixos ou negativos (Huete et al., 2002). Sendo assim, ocorre uma facilitação na separação das duas classes em questão.

Após as análises de desempenho desenvolvidas para os produtos a partir de identificação visual, aplicaram-se métricas de validação com intuito de testar a performance dos mapeamentos desenvolvidos e, dessa forma, realizar comparações. Estas análises desenvolvidas evidenciam distinções relevantes tanto em termos de

desempenho estatístico quanto de adequação metodológica às especificidades da detecção de cobertura vegetal em ambientes urbanizados. Ambos os dados, conforme já relatado, foram submetidos a um processo de validação sistemático, pautado na distribuição de 1.000 pontos de referência para cada produto, sendo 500 alocados em áreas previamente classificadas como vegetadas e outros 500 em áreas classificadas como não vegetadas. Como resultado disso, as figuras 24 e 25, RGB e NDVI, respectivamente, trazem detalhes sobre a validação e métricas aplicadas aos dados.

Figura 24: Matriz de confusão binária + métricas de validação (RGB).

	Referência: Vegetação	Referência: Não vegetação		
Mapa: Vegetação	498	2		
Mapa: Não vegetação	15	485		
			Acurácia do Usuário (UA)	1,00
			Acurácia do Produtor (PA)	0,97
			F1-Score	0,98
			Exatidão Global (OA)	0,98
			Índice de Jaccard	0,97

Fonte: O autor (2025).

Figura 25: Matriz de confusão binária + métricas de validação (NDVI).

	Referência: Vegetação	Referência: Não vegetação		
Mapa: Vegetação	495	5		
Mapa: Não vegetação	6	494		
			Acurácia do Usuário (UA)	0,99
			Acurácia do Produtor (PA)	0,99
			F1-Score	0,99
			Exatidão Global (OA)	0,99
			Índice de Jaccard	0,98

Fonte: O autor (2025).

No produto baseado em RGB (figura 24), a matriz de confusão revelou 498 verdadeiros positivos (VP), 485 verdadeiros negativos (VN), apenas 2 falsos positivos (FP) e 15 falsos negativos (FN). A partir desses valores, obtiveram-se métricas de desempenho expressivas: a acurácia do usuário foi de 1,0, a acurácia do produtor alcançou 0,97, o F1-Score atingiu 0,98, a exatidão global chegou a 0,98, e o índice de Jaccard resultou em 0,97. Esses números, embora elevados, sinalizam uma tendência do produto RGB em cometer erros residuais de omissão, como evidenciado pelo maior número relativo de falsos negativos (15), o que implica na subestimação de algumas

áreas de vegetação em detrimento da classe de não vegetação - fato que foi observado a partir de análises visuais do produto, que conta na figura 21, onde é realizada uma subestimação das bordas dos fragmentos arbóreas identificados. Esse fenômeno é recorrente quando a classificação se baseia exclusivamente em composições espectrais no visível (RGB), o que pode se dar, dentre outros, pela menor reflectância do vermelho em casos de vegetação saudável, possibilidade de dificuldade na separabilidade de áreas com estresse na vegetação e áreas urbanizadas muito claras e impossibilidade de captação da reflectância no infravermelho próximo (Jensen, 2016; Foody, 2002). Dessa forma, a distinção entre alvos de reflectância próxima pode se mostrar ambígua e, portanto, suscetível a confusões na classificação.

Já no mapeamento fundamentado no NDVI (figura 25), o desempenho estatístico revelou-se ainda mais consistente. A matriz de confusão apontou 495 VP, 494 VN, 5 FP e apenas 6 FN. As métricas derivadas atestam que: a acurácia do usuário foi de 0,99, a acurácia do produtor igualmente de 0,99, o F1-Score de 0,99, a exatidão global de 0,99 e o índice de Jaccard de 0,98. O equilíbrio entre os erros de comissão e de omissão é mais evidente nesse caso, com valores mais próximos e numericamente inferiores quando comparados ao produto RGB. Isso sugere que o NDVI, por incorporar informações do infravermelho próximo e, portanto, captar diretamente a atividade fotossintética e o vigor da vegetação, apresenta maior capacidade discriminatória para identificar áreas vegetadas mesmo em cenários urbanos heterogêneos. Assim, supõe-se que o índice contribui para reduzir ambiguidades espectrais que ocorrem quando se utilizam apenas bandas no espectro visível.

A partir de uma análise comparativa, observa-se que ambos os produtos obtiveram métricas de desempenho bem elevadas, com exatidão global superior a 0,9, o que atesta a eficácia das técnicas de classificação aplicadas. Contudo, o diagnóstico do produto NDVI apresentou-se ligeiramente mais robusto e equilibrado. Essa robustez é particularmente visível na relação entre a acurácia do usuário e do produtor, que, no caso do NDVI, convergem em 0,99, denotando consistência tanto na perspectiva de quem consome o mapa quanto na perspectiva da classe real observada durante a validação. No produto RGB, embora a acurácia do usuário tenha sido perfeita (1,0), indicando que quase a totalidade das áreas mapeadas como vegetação

de fato correspondiam à realidade, a acurácia do produtor foi inferior (0,97), revelando um valor mais elevado de áreas vegetadas omitidas pelo classificador. Essa discrepância pode representar limitações importantes quando o interesse do estudo reside em captar da melhor forma possível a distribuição espacial da vegetação, o que é crucial em análises ambientais e de planejamento urbano (Lourenço, et al., 2021).


O F1-Score e o índice de Jaccard corroboram essa diferenciação. Ambos são métricas mais direcionadas à avaliação de classificações binárias, sendo sensíveis ao balanço entre erros de comissão e omissão. Enquanto o produto RGB apresentou F1-Score de 0,98 e Jaccard de 0,97, o NDVI alcançou 0,99 em ambos, sugerindo maior estabilidade na detecção das classes.

Dado o exposto, a validação do modelo sobre a totalidade do território metropolitano permitiu entender a performance da classificação na captura da heterogeneidade da vegetação arbórea existente em toda RMRJ, onde foram contemplados desde grandes maciços florestais à fragmentos arbóreos inseridos em áreas urbanizadas. Esta abordagem possui o mérito de fornecer uma visão mais ampla da cobertura vegetal, permitindo a avaliação de padrões espaciais da vegetação metropolitana e oferecendo subsídios para comparações com bases de dados já consolidadas. No entanto, considerando que a vegetação arbórea inserida somente no perímetro urbano apresenta características espectrais e espaciais próprias (Xue et al., 2024), que podem, em alguns casos, ser mais complexas de serem mapeadas em decorrência da alta densidade de edificações, elevada fragmentação e intensas misturas espectrais em decorrência da majoritária de superfícies altamente artificializadas, entendeu-se que é metodologicamente pertinente realizar também uma avaliação exclusivamente às áreas urbanizadas da RMRJ. Dessa forma, além auxiliar no entendimento comparativo da robustez do modelo *deep learning* na identificação de arborização no perímetro urbano versus a totalidade metropolitana, o enfoque de avaliação apenas para a área urbanizada direciona um olhar analítico mais específico, dessa vez com dados que podem auxiliar mais diretamente no planejamento urbano e qualidade de vida da população residente.

Para tal análise, usando como base o perímetro urbano que é resultado do mapeamento de uso e cobertura do ERJ desenvolvido pela SEAS/UFRJ, recortaram-se os mapeamentos de vegetação desenvolvido para a RMRJ apenas pelo perímetro urbano. Assim, o resultado desse recorte pode ser observado espacialmente nas


figuras 26 e 27, que representam os produtos fruto do mapeamento RGB e NDVI, respectivamente. Em seguida, foram redistribuídos, para os dois casos (RGB e NDVI), novos pontos de validação: 500 para cada área delimitada como vegetação, e mais 500 para áreas não-vegetadas na urbe. Bem como no mapeamento para toda RMRJ, foi elaborada uma matriz de confusão binária para os dois dados, que pode ser observada nas figuras 28 e 29.

Figura 26: Mapeamento de vegetação arbórea em área urbanizada da RMRJ (RGB).



Fonte: O autor (2025).

Figura 27: Mapeamento de vegetação arbórea em área urbanizada da RMRJ (NDVI).



Fonte: O autor (2025).

Figura 28: Matriz de confusão binária + métricas de validação em vegetação arbórea no perímetro urbano (RGB).

	Referência: Vegetação	Referência: Não vegetação		
Mapa: Vegetação	492	8		
Mapa: Não vegetação	31	469		
			Acurácia do Usuário (UA)	0,98
			Acurácia do Produtor (PA)	0,94
			F1-Score	0,96
			Exatidão Global (OA)	0,96
			Índice de Jaccard	0,93

Fonte: O autor (2025).

Figura 29: Matriz de confusão binária + métricas de validação em vegetação arbórea no perímetro urbano (NDVI).

	Referência: Vegetação	Referência: Não vegetação		
Mapa: Vegetação	498	2		
Mapa: Não vegetação	9	491		
			Acurácia do Usuário (UA)	1,00
			Acurácia do Produtor (PA)	0,98
			F1-Score	0,99
			Exatidão Global (OA)	0,99
			Índice de Jaccard	0,98

Fonte: O autor (2025).

Ao analisar os dados, observa-se que no que tange validação considerando apenas a área urbanizada, foram obtidos, de maneira análoga a verificação anterior, bons resultados, com o resultado de todas as métricas de validação superiores a 0,9. No entanto, há diferenças mais expressivas entre essas duas validações - as que consideraram apenas o perímetro urbano.

No caso do mapeamento baseado em RGB (figuras 26 e 28), observou-se um desempenho satisfatório, mas com limitações que podem ser decorrentes do uso exclusivo do espectro visível. Os resultados indicaram 492 verdadeiros positivos (VP), 8 falsos positivos (FP), 469 verdadeiros negativos (VN) e 31 falsos negativos (FN). A partir desses valores, os indicadores de acurácia apresentaram valores relativamente elevados: a acurácia do usuário foi de 0,98, a acurácia do produtor de 0,94, o F1-Score de 0,96, a exatidão global de 0,96 e o índice de Jaccard de 0,93. Embora os índices estejam próximos do valor máximo possível, nota-se a presença de erros de omissão (FN), que reduzem a acurácia do produtor e podem indicar maior dificuldade do classificador em identificar corretamente as áreas vegetadas. Por outro lado, o mapeamento baseado em NDVI (figuras 27 e 29) apresenta desempenho superior em todos os parâmetros analisados. Os resultados foram 498 VP, 2 FP, 491 VN e apenas 9 FN. As métricas demonstraram acurácia do usuário de 1,0, acurácia do produtor de 0,98, F1-Score de 0,99, exatidão global de 0,99 e índice de Jaccard de 0,98. Esses valores indicam um produto de alta confiabilidade, com baixa incidência tanto de erros de omissão quanto de comissão. A comparação direta entre os dois diagnósticos gerados revela que, embora a classificação baseada em RGB apresente índices de acurácia elevados, ela pode acabar subestimando a ocorrência de vegetação no perímetro urbano. Esse comportamento se reflete nos 31 casos de FN identificados,

em contraste com apenas 9 no produto baseado em NDVI. Em contextos urbanos, onde a vegetação frequentemente ocorre de forma fragmentada e sob forte interferência de elementos artificiais, a ausência do infravermelho próximo no processo de classificação pode comprometer a fidelidade do mapeamento, resultando em maior número de omissões. Dessa forma, observa-se que o NDVI se mostra mais adequado para a identificação de arborização urbana, especialmente em áreas densamente ocupadas como a RMRJ.

Quando se realiza uma análise comparativa entre os diagnósticos obtidos para a totalidade da RMRJ e aqueles realizados exclusivamente no perímetro urbano, observa-se uma mudança relevante no padrão de desempenho das classificações. No recorte restrito ao perímetro urbano, a classificação baseada em RGB demonstrou de forma mais evidente suas limitações, com a apresentação de confusões que podem se dar pela maior sensibilidade aos efeitos de sombras, variação fenológica e presença de superfícies artificiais espectralmente semelhantes à vegetação. O NDVI, por sua vez, manteve alto desempenho tanto na análise metropolitana quanto na urbana, indicando robustez frente à heterogeneidade espacial e espectral típica das cidades.

Após as análises de acurácia dos mapeamentos gerados, foi desenvolvida uma análise quantitativa do produto, a fim de entender brevemente a distribuição espacial da arborização na RMRJ, bem como em seu perímetro urbano. Em decorrência do seu melhor desempenho em todas as métricas analisadas, o produto NDVI foi utilizado para o levantamento quantitativo realizado.

Para compreender a distribuição espacial da vegetação arbórea na RMRJ, a primeira análise considerou o recorte da vegetação em relação aos limites político-administrativos de cada município. A proporção de arborização foi obtida pela razão entre a área vegetada e a área total municipal, expressa em hectares. Como resultado, destacam-se Nilópolis (3,40%), São João de Meriti (6,37%) e Queimados (18,85%), que apresentaram as menores porcentagens de vegetação arbórea. As áreas absolutas vegetadas nesses municípios foram de 66,09 ha, 224,38 ha e 1431,30 ha, respectivamente. Tais resultados refletem a intensa pressão antrópica sobre esses territórios, marcados por alta densidade populacional, urbanização consolidada e escassez de áreas verdes remanescentes, fenômeno recorrente em centros urbanos periféricos da metrópole carioca (Abreu, 2018; Monteiro & Câmara, 2021). No extremo

oposto, os municípios de Petrópolis (65,62%), Cachoeiras de Macacu (63,66%) e Magé (62,74%) apresentaram os maiores percentuais de cobertura vegetal, com áreas absolutas de 51.916,20 ha, 60.781,09 ha e 24.518,36 ha, respectivamente. Esses valores elevados podem ser explicados tanto pela presença de fragmentos significativos de Mata Atlântica quanto pela menor intensidade do processo de urbanização em algumas porções desses municípios, sobretudo nas áreas de relevo acidentado e menos propícias à ocupação (Fundação SOS Mata Atlântica & INPE, 2021).

Além da análise em escala municipal, buscou-se também compreender a dinâmica da vegetação restrita ao perímetro urbano da RMRJ, recortado a partir de shapefile específico da mancha urbanizada, dado este que, conforme já explanado, foi desenvolvido pela SEAS/INEA. Essa análise complementar é de fundamental relevância, uma vez que a vegetação arbórea inserida exclusivamente em áreas urbanas possui características espectrais e estruturais diferenciadas, frequentemente associadas a jardins, parques urbanos, arborização viária ou pequenos fragmentos residuais de vegetação nativa (Yuan et al., 2017; Norton et al., 2015). Os resultados obtidos para essa delimitação evidenciam um cenário distinto daquele observado no recorte metropolitano. Em termos relativos, os municípios de Nilópolis (2,76%), Mesquita (5,60%) e São João de Meriti (6,21%) foram aqueles que apresentaram menor porcentagem de vegetação em área urbana, com áreas absolutas de apenas 26,45 ha, 77,62 ha e 217,63 ha, respectivamente. Esses valores reforçam o quadro de extrema carência de infraestrutura verde nos municípios mais densamente urbanizados, o que pode implicar maiores vulnerabilidades socioambientais, como intensificação de ilhas de calor urbano, deficiência de drenagem e menor qualidade de vida para a população local (Gill et al., 2007; Salbitano et al., 2016). Em contrapartida, os municípios de Petrópolis (24,28%), Guapimirim (17,43%) e Magé (17,30%) destacaram-se com as maiores proporções de vegetação dentro do perímetro urbano, apresentando áreas absolutas de 1435,29 ha, 312,39 ha e 1113,52 ha, respectivamente. Ainda que os percentuais sejam inferiores àqueles observados quando considerada a totalidade municipal, o desempenho relativamente elevado desses municípios dentro da área urbanizada sugere a existência de estratégias mais eficazes de preservação e integração de áreas verdes em meio ao tecido urbano.

A comparação entre os dois recortes espaciais – limite municipal total e perímetro urbano – evidencia que a distribuição e a proporção de vegetação variam significativamente conforme a escala e a delimitação territorial adotada. Quando considerada a totalidade dos municípios, áreas mais periféricas e montanhosas apresentam maior proporção de vegetação, enquanto áreas centrais densamente urbanizadas apresentam baixíssimos índices. No entanto, ao restringir a análise ao perímetro urbano, a disparidade entre os municípios é reduzida, e as diferenças passam a refletir não apenas processos de ocupação histórica, mas também pode indicar a existência de políticas locais de arborização mais eficazes, bem como a manutenção da arborização em contexto urbano.

7. CONSIDERAÇÕES FINAIS

A relevância de análises da arborização no contexto metropolitano fluminense e os indicativos sobre a qualidade dos dados produzidos a partir de técnicas de deep learning justificam a relevância da temática abordada neste estudo: a análise da aplicação de técnicas de *deep learning* na identificação da arborização inserida na Região Metropolitana do Rio de Janeiro. Assim, vale, por fim, considerar alguns aspectos conclusivos.

A elaboração de um estado da arte específico para a temática deste estudo pode indicar que o campo se encontra em processo de amadurecimento metodológico, embora já apresente diversidade metodológica quanto a abordagens e escalas. Apesar dessa diversidade, o levantamento realizado revelou alguns padrões metodológicos. Os resultados apontaram que a grande maioria das publicações científicas utilizam imagens de altíssima resolução espacial, provenientes de plataformas comerciais, como WorldView, QuickBird e Gaofen. Tal predomínio evidencia ganhos expressivos em termos de acurácia e detalhamento espectral, mas, ao mesmo tempo, pode denunciar limitações associadas ao custo e à replicabilidade em escalas mais amplas. Além disso, outro aspecto majoritariamente observado diz respeito à concentração territorial das produções científicas. O levantamento sistemático realizado demonstrou que, embora os estudos de *deep learning* aplicados à cobertura vegetal urbana tenham se intensificado a partir de 2019, a produção científica ainda é relativamente restrita e concentrada em determinados países, como China e Estados Unidos. Embora haja poucas publicações em análise neste estudo,

essa concentração pode sugerir não apenas desigualdades de acesso a bases de dados de alta resolução (comumente utilizados em estudos com aplicação de técnicas de deep learning), mas também a existência de lacunas significativas no Sul Global, que concentra diversas demandas socioambientais relativas à cobertura vegetal urbana (Sierra; Suárez-Collado, 2021). Dessa forma, a inserção de mais um estudo brasileiro, que apresentou bom desempenho e utilizou produto orbital mais acessível, nesse cenário reforça a relevância desta pesquisa.

Além disso, no que tange ao resultado adquirido a partir da aplicação do modelo de identificação da arborização na RMRJ, vale considerar alguns aspectos. Os resultados obtidos, tanto na análise visual quanto na aplicação de métricas de validação, demonstraram que ambas as abordagens apresentaram um bom desempenho para a identificação de vegetação. No entanto, o mapeamento baseado em NDVI teve um desempenho mais robusto, principalmente no que se refere à precisão da delimitação das áreas arborizadas. A precisão visual foi consistente, como evidenciado pelas imagens exemplificativas da Barra da Tijuca e Ilha do Governador (figuras 17, 18, 19 e 20), onde o mapeamento com NDVI demonstrou maior capacidade de discriminação entre a vegetação e outros alvos, como corpos d'água, em comparação ao produto RGB. A aplicação de métricas de validação, como acurácia, F1-Score e índice de Jaccard, reafirmou que o produto NDVI apresentou resultados estatisticamente superiores aos do produto RGB, especialmente no contexto de áreas urbanizadas, onde o produto RGB tende a demonstrar maior número de erros de omissão e comissão. Apesar das diferenças supracitadas, em todas as análises de acurácia realizadas, os dois produtos revelam performance superior a 0,9, o que é considerado pela literatura como um desempenho muito bom (Jensen, 2016; Foody, 2002).

A análise da arborização exclusivamente no perímetro urbano da RMRJ também apresentou resultados relevantes. O mapeamento com NDVI se destacou, com uma exatidão global de 0,99 e um índice de Jaccard de 0,98, evidenciando sua robustez frente à heterogeneidade espacial e espectral das áreas urbanizadas. Em contraste, o mapeamento RGB revelou algumas limitações, como a maior ocorrência de falsos negativos (FN) e uma dificuldade maior em identificar precisamente fragmentos menores, se comparado ao NDVI. Bem como na análise considerando todo o contexto da RMRJ, apesar de o produto NDVI apresentar desempenho pouco

superior, os dois casos mostram bons resultados, com valores das métricas aplicadas que, em todos os casos, superam 0,90.

Com isso, fica evidente que a aplicação de *deep learning* ao mapeamento de vegetação urbana é não apenas viável, mas também estratégica para responder às demandas de monitoramento em ambientes urbanos. A fragmentação da vegetação, característica da matriz urbana, impõe desafios adicionais, sobretudo em termos de mistura espectral e complexidade estrutural. Ainda assim, aqui foram encontrados produtos com ótimo desempenho, superando, em alguns casos, técnicas clássicas de classificação como o Random Forest. Ressalta-se também o ótimo desempenho aqui encontrado mesmo com a utilização de dados orbitais que não possuíam resolução espacial altíssima - o que foi mais frequentemente encontrado nos estudos analisados. Ainda assim, esta análise não desaponta na aferição de desempenho, apresentando performance igualmente elevada em análises comparativas. Espera-se que, nesse sentido, sejam ampliadas as análises dessa temática em mesoescala e utilizando dados de acesso gratuito e de alta cadência temporal.

Por fim, o levantamento bibliográfico, metodologia e os resultados aqui apresentados não apenas contribuem para o avanço do conhecimento sobre a arborização na RMRJ, mas também oferecem subsídios valiosos, tanto para aplicação de técnicas de deep learning atrelado ao sensoriamento remoto e análises espaciais, quanto para elaboração de políticas públicas voltadas à gestão e preservação ambiental da RM.

8. REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, M. A metrópole e a urbanização no Brasil. Rio de Janeiro: Editora UFRJ, 2018.

ALEISSAEE, A. A. et al. Transformers in Remote Sensing: A Survey. *Remote Sensing*, MDPI AG, 30 mar. 2023.

ALZUBAIDI, L. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, v. 8, n. 1, p. 1-74, 2021.

ALVALÁ, R. C. dos S. et al. Eventos extremos de precipitação no Brasil: características observadas e projeções futuras. *Revista Brasileira de Meteorologia*, v. 32, supl. 1, p. 153–161, 2017.

AWAD, M. M.; LAUTERI, M. Self-Organizing Deep Learning (SO-UNet)—A Novel Framework to Classify Urban and Peri-Urban Forests. *Sustainability*, Basel, v. 13, art. 5548, 2021. DOI: 10.3390/su13105548.

BARBOSA, X. C.; BEZERRA, R. F. Breve introdução à história da Inteligência Artificial. *Jamaxi*, v. 4, n. 1, 2020.

BARGOS, D. C. Mapeamento e análise das áreas verdes urbanas como indicador da qualidade ambiental urbana: estudo de caso de Paulínia-SP. 2010. Tese (Doutorado) – Universidade [nome da universidade], [cidade], 2010.

BARRETO, I. J. O surgimento de novas regiões metropolitanas no Brasil: uma discussão a respeito do caso de Sorocaba (SP). *Espaço e Economia: Revista Brasileira de Geografia Econômica*, n. 1, 2012.

BRAGA, R. Mudanças climáticas e planejamento urbano: uma análise do Estatuto da Cidade. In: *VI Encontro Nacional da ANPPAS*. Belém, p. 1-15, 2012.

BRAGA, J. R. G. et al. Algoritmo de delimitação de copas baseado em deep learning. In: *XIX Simpósio Brasileiro de Sensoriamento Remoto*, 2019.

BEERY, S. et al. The auto arborist dataset: A large-scale benchmark for multiview urban forest monitoring under domain shift. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022.

CAPORUSSO, D.; MATIAS, L. Áreas verdes urbanas: avaliação e proposta conceitual. In: *1º SIMPGEO*, Rio Claro, São Paulo, 2008.

CARVALHO, W. S.; FILHO, F. J. C. M.; SANTOS, T. L. Uso e cobertura do solo utilizando Google Earth Engine (GEE): estudo de caso em uma unidade de conservação. *Brazilian Journal of Development*, v. 7, n. 2, fev. 2021.

CAVALHEIRO, F.; DEL PICCHIA, P. C. D. Áreas verdes: conceitos, objetivos e diretrizes para o planejamento. In: *Anais do 1º Congresso Brasileiro sobre*

Arborização Urbana e 4º Encontro Nacional sobre Arborização Urbana. Vitória-ES, p. 29-38, 1992.

CHEN, S.; ZHANG, M.; LEI, F. Mapping Vegetation Types by Different Fully Convolutional Neural Network Structures with Inadequate Training Labels in Complex Landscape Urban Areas. *Forests*, v. 14, n. 1788, 2023. DOI: 10.3390/f14091788.

CIRESAN, D. C.; GAMBARDELLA, L. M.; GIUSTI, A.; SCHMIDHUBER, J. Deep neural networks segment neuronal membranes in electron microscopy images. In: *NIPS*, 2012. p. 2852–2860.

COELHO, H. Turing, 100 anos depois do seu nascimento já pode uma máquina pensar? *Boletim da Sociedade Portuguesa de Matemática*, 2012.

CONGALTON, R. G.; GREEN, K. *Assessing the Accuracy of Remotely Sensed Data*. 2009.

CUNHA, I. I. F. R. et al. A importância da álgebra e geometria analítica no funcionamento do GPS. *Anais da Mostra de Iniciação Científica do CESUCA*, v. 16, p. 304-305, 2022.

DHARSHINI, M. P. A.; VIJILA, S. A. Survey of machine learning and deep learning approaches on sales forecasting. In: *2021 4th International Conference on Computing and Communications Technologies (ICCCT)*. IEEE, 2021. p. 59-64.

DINIZ, C. G. et al. Três décadas de mudanças na planície costeira brasileira: o status dos manguezais, da aquicultura e salicultura a partir de séries temporais Landsat e técnicas de aprendizado de máquina. 2020.

FENG, Q.; LIU, J.; GONG, J. UAV remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sensing*, v. 7, n. 1, p. 1074-1094, 2015.

FERNÁNDEZ-CABALLERO, A. et al. *Una perspectiva de la inteligencia artificial en su 50 aniversario*. 2006.

FERREIRA, L. S. *Vegetação, temperatura de superfície e morfologia urbana: um retrato da Região Metropolitana de São Paulo*. 2019. Dissertação (Mestrado em Arquitetura e Urbanismo) – Universidade de São Paulo, São Paulo, 2019.

FITZ, P. R. Uso de geotecnologias para o planejamento espacial. *Geografia*, v. 33, n. 2, p. 307-318, 2008.

FONSECA, L. M. G. *Processamento digital de imagens*. Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105 p.

FOODY, G. M. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, v. 80, n. 1, p. 185–201, 2002.

FUNDAÇÃO SOS MATA ATLÂNTICA & INPE. *Atlas dos Remanescentes Florestais da Mata Atlântica – Período 2019-2020*. São Paulo: SOS Mata Atlântica, 2021.

GANATRA, N.; PATEL, A. A multiclass plant leaf disease detection using image processing and machine learning techniques. *International Journal on Emerging Technologies*, v. 11, n. 2, p. 1082-1086, 2020.

GILL, S. E.; HANDLEY, J. F.; ENNOS, A. R.; PAULEIT, S. Adapting cities for climate change: The role of the green infrastructure. *Built Environment*, v. 33, n. 1, p. 115–133, 2007.

GILLNER, S.; VOGT, J.; ROLOFF, A. Climatic response and impacts of tree species in urban environments: An overview of research at the Institute of Forest Botany, Dresden University of Technology (Germany). *Urban Forestry & Urban Greening*, v. 15, p. 63–68, 2016.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016.

GOMES, D. S. Inteligência artificial: conceitos e aplicações. *Revista Olhar Científico*, v. 1, n. 2, p. 234-246, 2010.

GOMES, M. A. S.; SOARES, B. R. Reflexões sobre qualidade ambiental urbana. *Estudos Geográficos: Revista Eletrônica de Geografia*, v. 2, n. 2, p. 21-30, 2004.

GÓMEZ, H. et al. Mapping urban green spaces at the metropolitan level using very high resolution satellite imagery and deep learning techniques for semantic segmentation. *Remote Sensing*, v. 13, n. 2031, 2021. DOI: 10.3390/rs13112031.

GUO, J. et al. 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*, v. 198, p. 1–15, 2023.

GREY, G. W.; DENEKE, F. J. *Urban Forestry*. New York: John Wiley & Sons, 1978.

HAMAGUTI, E. K.; BREVE, F. A. Introdução sobre machine learning e deep learning. 2022.

HARTLING, Sean et al. Urban tree species classification using a WorldView-2/3 and LiDAR data fusion approach and deep learning. *Sensors*, v. 19, n. 1284, p. 1-23, 2019. DOI: 10.3390/s19061284.

HASHIM, H.; LATIF, Z. A.; ADNAN, N. A. Urban vegetation classification with NDVI threshold value method with very high resolution (VHR) Pleiades imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 42, p. 237-240, 2019.

HIRYE, M. C. M. Estudos e técnicas de mapeamento de vegetação urbana. *CEP*, v. 12, p. 010.

HOSAKI, G. Y. G.; RIBEIRO, D. F. *Deep learning: ensinando a aprender*. 2021.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, v. 83, n. 1–2, p. 195-213, 2002.

HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. 2. ed. Melbourne: OTexts, 2018.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). *Regiões de Influências das Cidades 2018 - REGIC*. Rio de Janeiro: IBGE, 2020.

INSTITUTO DE PESQUISAS ECONÔMICAS APLICADAS (IPEA). *Atlas do desenvolvimento humano nas regiões metropolitanas brasileiras*.

JENSEN, J. R. *Introductory Digital Image Processing: A Remote Sensing Perspective*. 2016.

KAUFMAN, Y. J.; TANRÉ, D. Strategy for direct and indirect methods for correcting the aerosol effect on remote sensing: From AVHRR to EOS-MODIS. *Remote Sensing of Environment*, v. 55, n. 1, p. 65–79, 1996.

KIM, Hannah; JEONG, Young-Seob. Sentiment classification using convolutional neural networks. *Applied Sciences*, v. 9, n. 11, p. 2347, 2019.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436-444, 2015.

LEITE, M. E.; ROSA, R. Geografia e geotecnologias no estudo urbano. *Caminhos de Geografia*, v. 17, n. 17, p. 180-186, 2006.

LEPORACE, C. *Machine learning e a aprendizagem humana: uma análise a partir do enativismo*. 2023. Tese de Doutorado.

LI, J. et al. Deep learning in multimodal remote sensing data fusion: A comprehensive review. *International Journal of Applied Earth Observation and Geoinformation*, v. 105, p. 1–15, ago. 2022.

LIMA, A. M. L. P.; CAVALHEIRO, F.; NUCCI, J. C.; SOUSA, M. A. L. B.; FIALHO, N.; DEL PICCHIA, P. C. D. Problemas de utilização na conceituação de termos como espaços livres, áreas verdes e correlatos. In: *Anais do II Congresso de Arborização Urbana*. São Luis-MA, p. 539-553, 1994.

LIN, N. et al. Urban vegetation extraction from high-resolution remote sensing imagery on SD-UNet and vegetation spectral features. *Remote Sensing*, v. 15, n. 4488, 2023. DOI: 10.3390/rs15184488.

LOBODA, C. R.; DE ANGELIS, B. L. D. Áreas verdes públicas urbanas: conceitos, usos e funções. *Ambiência*, v. 1, n. 1, p. 125-139, jan./jun. 2005.

LOURENÇO, J. S. Q.; SILVA, R. G.; CRUZ, C. B. M. Dinâmicas urbanas e florestais das regiões metropolitanas de Rio de Janeiro e São Paulo: uma trajetória ao longo de 34 anos (1985 a 2018). In: MENEZES, P. M. L.; FERNANDES, M. C.; CRUZ, C. B. M. (org.). *Cartografias do Ontem, Hoje e Amanhã*. 1. ed. Curitiba: Appris, 2021. p. 537-552.

LUMNITZ, S. *Mapping urban trees with deep learning and street-level imagery*. 2019. Tese (Mestrado em Ciências) – The University of British Columbia, Vancouver, 2019.

MA, L. et al. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 152, p. 166–177, 2019.

MAHESH, B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*, v. 9, n. 1, p. 381-386, 2020.

MARTELLI, A. Arborização urbana versus qualidade de vida no ambiente construído. *Revista Faculdades do Saber*, v. 1, n. 02, p. 133-142, 2016.

META AI & WRI. *Global Canopy Height Map, 1m Resolution*. 2024.

MILANO, M. S. Arborização urbana. In: *Curso sobre arborização urbana. Resumos*. Curitiba: UNILIVRE/Prefeitura Municipal de Curitiba/Sociedade Brasileira de Arborização Urbana, p. 1-5, 1993.

MITCHELL, T. *Machine learning*. McGraw Hill, 1997.

NATARAJAN, B. K. *Machine learning: a theoretical approach*. Morgan Kaufmann, 1991.

MORATO, R. G.; KAWAKUBO, F. S.; LUCHARI, A. Geografia da desigualdade ambiental na Subprefeitura de Campo Limpo, Município de São Paulo. In: *Anais do XII Simpósio Brasileiro de Sensoriamento Remoto*, Goiânia, 2005.

MONTEIRO, A. M. V.; CÂMARA, G. *Geotecnologias e análise espacial em estudos urbanos e ambientais*. São Paulo: Oficina de Textos, 2021.

NEYNS, R.; CANTERS, F. Mapping of urban vegetation with high-resolution remote sensing: A review. *Remote Sensing*, v. 14, n. 1031, 2022. DOI: 10.3390/rs14041031.

NICOLAU, V. N. *Mapeamento de cobertura e uso de solo a partir de dados de sensoriamento remoto utilizando redes neurais*. 2020. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

NILSSON, N. *The quest for artificial intelligence: a history of ideas and achievements*. Cambridge: Cambridge University Press, 2009.

NOBRE, C. A. et al. Vulnerabilidade das megacidades brasileiras às mudanças climáticas: região metropolitana do Rio de Janeiro. *Parcerias Estratégicas*, v. 17, n. 34, p. 197–220, 2012.

NOWAK, D. J.; DWYER, J. F. Understanding the benefits and costs of urban forest ecosystems. In: KUSER, J. E. (ed.). *Urban and Community Forestry in the Northeast*. 2. ed. New York: Springer, 2007. p. 25–46.

NORTON, B. A. et al. Planning for cooler cities: A framework to prioritise green infrastructure to mitigate high temperatures in urban landscapes. *Landscape and Urban Planning*, v. 134, p. 127–138, 2015.

NUCCI, J. C. *Qualidade ambiental e adensamento urbano: um estudo de ecologia e planejamento da paisagem aplicado ao distrito de Santa Cecília (São Paulo)*. São Paulo: Humanitas/FAPESP, 2008.

OKE, T. R. The micrometeorology of the urban forest. *Philosophical Transactions of the Royal Society B: Biological Sciences*, v. 324, n. 1223, p. 335–349, 1989.

OLIVEIRA, F. S. *Mapeamento da vegetação urbana e distribuição espacial e temporal de ilhas de calor*. 2015. Tese de Doutorado. Universidade Federal do Espírito Santo, Jerônimo Monteiro.

OLOFSSON, P.; FOODY, G. M.; STEHMAN, S. V.; WOODCOCK, C. E. Making better use of accuracy data in land change studies: Estimating accuracy and area

and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, v. 129, p. 122–131, 2014.

OSCO, L. P. *Avanços em aprendizagem profunda aplicada ao sensoriamento remoto*. 2023.

PAIVA, H. N.; GONÇALVES, W. Florestas urbanas: planejamento para a qualidade de vida. Viçosa: Aprenda Fácil, 2002.

PANCHER, A. M. Os reflexos dos avanços das geotecnologias no estudo da evolução da ocupação urbana. *Revista Geonorte*, v. 3, n. 5, p. 1694–1706, 2012.

PAULA, I. F. M.; FERREIRA, C. C. M. Avaliação e mapeamento da cobertura vegetal da região central da cidade de Juiz de Fora–MG. *RAEGA-O Espaço Geográfico em Análise*, v. 39, p. 146-166, 2017.

PEREIRA, L. Uso de deep learning aplicado à classificação de tráfego em arquitetura SDN. 2022.

PETTORELLI, N. *The Normalized Difference Vegetation Index (NDVI)*. Oxford: Oxford University Press, 2013.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: *Third ERTS Symposium*, 1, 1973. p. 309–317.

PIPPI, L. G. A.; TRINDADE, L. C. O papel da vegetação arbórea e das florestas nas áreas urbanas. *Paisagem e Ambiente*, n. 31, p. 81-96, 2013.

PLANET. *Planet imagery product specifications*. p. 91, 2023.

RIBEIRO, J. B. et al. Detecção de linhas de plantio em plantações de cana-de-açúcar utilizando deep learning. 2023.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. [S.l.]: Springer, 2015.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. 1974.

RUSSEL, S. J.; NORVIG, P. *Artificial Intelligence: a modern approach*. 3. ed. New Jersey: Prentice Hall, 2009.

SACADURA, J. P. V. C. Segmentação de imagens multiespectrais de alta resolução utilizando o modelo U-Net para cartografia de uso do solo. 2021.

SALBITANO, F.; BORELLI, S.; CONIGLIARO, M.; CHEN, Y. *Guidelines on urban and peri-urban forestry*. FAO Forestry Paper. Roma: FAO, 2016.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 1959.

SARAIVA, Marciano et al. Automatic mapping of center pivot irrigation systems from satellite images using deep learning. *Remote Sensing*, v. 12, n. 3, p. 558, 2020.

SILVA, S. T.; MELLO, J. M.; ACERBI JUNIOR, F. W.; REIS, A. A.; RAIMUNDO, M. R.; SILVA, I. L. G.; SCOLFORO, J. R. S. Uso de imagens de sensoriamento remoto para estratificação do cerrado em inventários florestais. *Pesquisa Florestal Brasileira*, Colombo, v. 34, n. 80, p. 337-343, 2014.

SCCON. Nossa Abordagem. Disponível em: <https://www.scccon.com.br/empresa/nossa-abordagem/>. Acesso em: 09 set. 2023.

SIERRA, J.; SUÁREZ-COLLADO, Á. Understanding economic, social, and environmental sustainability challenges in the Global South. *Sustainability*, v. 13, n. 13, art. 7201, 2021.

SHAHTAHMASSEBI, A. R. et al. Remote sensing of urban green spaces: A review. *Urban Forestry & Urban Greening*, v. 57, p. 126946, 2021. DOI: 10.1016/j.ufug.2020.126946.

SHELHAMER, E.; LONG, J.; DARRELL, T. Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014.

SHINDE, P. P.; SHAH, S. A review of machine learning and deep learning applications. In: *2018 Fourth international conference on computing communication control and automation (ICCUBEA)*. IEEE, 2018. p. 1-6.

SILVA, R. G.; LOURENÇO, J. S. Q.; CRUZ, C. B. M. Uma análise comparativa das dinâmicas sócio-espaciais das regiões metropolitanas de Rio de Janeiro e São Paulo nos últimos 34 anos com suporte do geoprocessamento. In: *JGEOTEC*, 5., 9 a 12 nov. 2020, Rio de Janeiro. *Anais [...]*. Geopartners, Niterói, 2020.

SILVA, R. G. et al. Análise comparativa de mapeamentos do uso e cobertura a partir de imagens Landsat-8 e Sentinel-2 através do algoritmo Random Forest na plataforma Google Earth Engine. *Revista Tamoios*, v. 19, n. 2, p. 61-79, 2023.

SOUZA, C. E.; OLIVEIRA, M. I.; JÚNIOR, M. E. Uso de geotecnologias para mapeamento e análise de áreas verdes urbanas no município de Campos dos Goytacazes, RJ, Brasil. *Revista Vértices*, v. 22, n. 3, p. 590-609, 2020.

SPOLTI, A. C. Classificação de vias através de imagens aéreas usando Deep Learning. 2018.

STUBBINGS, P. et al. A hierarchical urban forest index using street-level imagery and deep learning. *Remote Sensing*, v. 11, n. 12, p. 1395, 2019. DOI: 10.3390/rs11121395.

TAOUARY, E. C. Deep learning para identificação precisa de desmatamentos através do uso de imagens satelitárias de alta resolução. 2019. Tese de Doutorado. Universidade Federal de Goiás, Goiás.

TEIXEIRA, A. F. et al. Aplicação de engenharia simultânea de sistemas ao monitoramento de fronteiras terrestres brasileiras utilizando uma missão de constelação de satélites. *Simpósio de Aplicações Operacionais em Áreas de Defesa–SIGE*, 2020.

TIMILSINA, S.; SHARMA, S. K.; ARYAL, J. Mapping urban trees within cadastral parcels using an object-based convolutional neural network. In: *Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Göttingen,

Germany: Copernicus Publications, v. IV-5/W2, p. 111–117, 2019. DOI: 10.5194/isprs-annals-IV-5-W2-111-2019.

TOMLINSON, R. *Thinking About GIS: Geographic Information System Planning for Managers*. 5. ed. Redlands: Esri Press, 2019.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127–150, 1979.

TURING, A. M. Computing machinery and intelligence. *Mind*, v. 49, p. 433-460, 1950. Disponível em: <http://cogprints.org/499/1/turing.html>. Acesso em: 14 dez. 2020.

ULRICH, R. S. View through a window may influence recovery from surgery. *Science*, v. 224, n. 4647, p. 420–421, 1984.

UTSCH, K. G. Uso de redes neurais convolucionais para classificação de imagens digitais de lesões de pele. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica)-Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, Espírito Santo, 2018.

VENTURA, Jonathan et al. Individual tree detection in large-scale urban environments using high-resolution multispectral imagery. 2022.

WANG, Wei et al. Urban forest identification from high-resolution images using deep-learning method. In: *IEEE International Geoscience and Remote Sensing Symposium*, 2021, [S.I.]. *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium*. [S.I.]: IEEE, 2021. p. 5283-5286.

WEINSTEIN, B. G. et al. Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. *Remote Sensing*, v. 11, n. 11, p. 1309, 2019. DOI: 10.3390/rs11111309.

WULDER, M. A. et al. Land cover 2.0. *International Journal of Remote Sensing*, v. 40, n. 9, p. 3336–3365, 2019.

XU, J. et al. A method for urban forest tree height extraction based on smartphones using deep learning. *Remote Sensing*, v. 15, n. 97, 2023. DOI: 10.3390/rs15010097.

XUAN, J. et al. Intelligent estimating the tree height in urban forests based on deep learning combined with a smartphone and a comparison with UAV-LiDAR. *Remote Sensing*, v. 15, art. 97, 2022. DOI: 10.3390/rs15010097.

YANG, Y. et al. Delineating urban functional zones using U-Net deep learning: Case study of Kuancheng District, Changchun, China. *Land*, v. 10, n. 11, p. 1266, 2021.

YUAN, F.; SAWAYA, K. E.; LOEFFELHOLZ, B. C.; BAUER, M. E. Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing. *Remote Sensing of Environment*, v. 98, n. 2, p. 317–328, 2017.

ZHANG, A. et al. *Dive into deep learning*. Cambridge University Press, 2023.

ZHANG, C.; ZHU, X. A review of deep learning methods for remote sensing data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 13, p. 4525–4543, 2020.

ZHOU, Z.; RAHMAN SIDDIQUEE, M. M.; TAJBAKHSN, N.; LIANG, J. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation. *IEEE Transactions on Medical Imaging*, v. 39, n. 6, p. 1856–1867, 2019.

ZHU, X. X. et al. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, v. 5, n. 4, p. 8–36, 2017.