

UNIVERSIDADE FEDERAL DE SÃO CARLOS - UFSCar  
CENTRO DE CIÊNCIAS DA NATUREZA - CCN  
ENGENHARIA AMBIENTAL

José Matheus Segre Moneva Viveiros

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO AUTOMÁTICA  
DE MUDAS DE RESTAURAÇÃO FLORESTAL EM IMAGENS RGB E  
MULTIESPECTRAIS PROVENIENTES DE AERONAVES REMOTAMENTE  
PILOTADAS

BURI - SP  
2023

José Matheus Segre Moneva Viveiros

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO AUTOMÁTICA  
DE MUDAS DE RESTAURAÇÃO FLORESTAL EM IMAGENS RGB E  
MULTIESPECTRAIS PROVENIENTES DE AERONAVES REMOTAMENTE  
PILOTADAS

Trabalho de conclusão de curso  
apresentado ao Centro de Ciências da  
Natureza da Universidade Federal de São  
Carlos, para obtenção do título de  
Bacharel em Engenharia Ambiental.

Orientador: Paulo Guilherme Molin  
Coorientadora: Melodie Kern Sarubu  
Dorth Sinegalia

Buri - SP  
2023

Segre Moneva Viveiros, José Matheus

Aplicação de inteligência artificial na identificação de mudas de restauração florestal em imagens RGB e multiespectrais provenientes de aeronaves remotamente pilotadas / José Matheus Segre Moneva Viveiros -- 2023. 36f.

TCC (Graduação) - Universidade Federal de São Carlos, campus Lagoa do Sino, Buri

Orientador (a): Paulo Guilherme Molin

Banca Examinadora: Paulo Guilherme Molin, André

Marcondes Andrade Toledo, Adriana Cavalieri Sais

Bibliografia

1. Sensoriamento remoto com drone. 2. Restauração florestal. 3. Inteligência artificial. I. Segre Moneva Viveiros, José Matheus. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)


DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Lissandra Pinhatelli de Britto - CRB/8 7539

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS DA NATUREZA  
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL


**Folha de Aprovação**

Assinatura dos membros da comissão examinadora que avaliou e aprovou a Defesa de Trabalho de Conclusão de Curso do(a) candidato(a) José Matheus Segre Moneva Viveiros, realizada em 06/03/2023:

Documento assinado digitalmente  
 PAULO GUILHERME MOLIN  
Data: 01/04/2023 22:55:45-0300  
Verifique em <https://validar.iti.gov.br>


---

Prof. Dr. **Paulo Guilherme Molin** – Orientador(a)  
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente  
 ANDRÉ MARCONDES ANDRADE TOLEDO  
Data: 06/04/2023 12:30:06-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. **André Marcondes Andrade Toledo**  
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente  
 ADRIANA CAVALIERI SAIS  
Data: 31/03/2023 19:49:11-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof.<sup>a</sup> Dr.<sup>a</sup> **Adriana Cavalieri Sais**  
Centro de Ciências Agrárias – UFSCar – Campus Araras

## AGRADECIMENTO

Inicialmente, gostaria de dedicar os agradecimentos deste trabalho aos meus familiares, em especial aos meus pais, Andréa Segre Moneva Viveiros e José Carlos Viveiros, e minha irmã Cecília Segre Moneva Viveiros, pois sempre estiveram ao meu lado incentivando, ajudando perante as dificuldades e me aconselhando nas tomadas de decisões. Dedico também aos meus amigos e colegas de graduação, estes foram muito importantes para que eu conseguisse alcançar meus objetivos.

Agradeço ao Centro de Pesquisa e Extensão em Geotecnologias (CePE-Geo), e seus coordenadores André Marcondes Andrade Toledo e Paulo Guilherme Molin (orientador deste trabalho), do qual participo desde meu segundo ano de graduação e tive o privilégio de aprender e me aprofundar na ciência e pesquisa, sobretudo, pois me deu a oportunidade de encontrar minha vocação e meu lugar no mundo profissional, o qual hoje vejo com muito entusiasmo e admiração. Aproveito para agradecer a todos os membros do CePE-Geo, em especial a minha coorientadora Melodie Kern Sarubu Dorth Sinegalia.

Sou grato também ao Laboratório de Silvicultura e Pesquisas Florestais (LASPEF) que, em parceria com o CePE-Geo, possibilitou a realização do presente trabalho cedendo uma área de restauração florestal que representou minha área de estudo.

Não posso deixar de estender meus reconhecimentos à instituição de ensino UFSCar Lagoa do Sino, seu corpo docente e equipe administrativa que sempre estiveram presentes e solícitos a sanar quaisquer empecilhos que eventualmente apareceram pela minha caminhada. Serei sempre grato e orgulhoso de ser filho de uma casa tão acolhedora e especial.

Todos que mencionei neste agradecimento são apenas algumas das muitas pessoas que me ajudaram ao longo desta jornada, sou muito grato a todos que passaram pela minha história e me transformaram de alguma forma, reconheço a importância de todos e tenho a ciência de que ninguém vence sozinho, muito obrigado!

*“Working hard to get my fill”*

Journey.

## RESUMO

A restauração florestal corresponde a uma série de técnicas e ações que objetivam o reparo e a manutenção de ecossistemas florestais. No Brasil, a restauração florestal desempenha um papel fundamental na restituição do bioma de Mata Atlântica e ganha força no século XXI com o surgimento de instrumentos legais que passam a exigir a compensação e o reparo de danos ambientais. Neste contexto, a restauração florestal não deve ser aplicada visando apenas as técnicas que melhor atendem a área de estudo, mas também é importante considerar o seu monitoramento a longo prazo, com o objetivo de averiguar o sucesso e a progressão do processo de restauração. Atualmente, o monitoramento da restauração utiliza equipamentos como Sistemas de Aeronaves Remotamente Pilotadas (do inglês, RPAS) para, através de atividades *in loco* e processamento de imagens em laboratório, facilitar a fiscalização periódica da área restaurada, gerando informações como o número de indivíduos plantados, classificação em espécies, estimativa de altura, entre outros. Tais práticas de monitoramento exigem um grande gasto de tempo e recursos humanos que, se otimizados, podem contribuir para o maior custo-benefício do processo de restauração. Diante da dificuldade atual em otimizar o monitoramento da restauração florestal, o presente trabalho teve por objetivo aplicar o algoritmo de inteligência artificial Mask R-CNN para automatizar a contagem e delineamento de mudas de restauração em imagens provenientes de RPAS, comparando o desempenho deste algoritmo em imagens RGB e multiespectrais (MSP). Os resultados obtidos pelo estudo mostraram que o algoritmo foi mais eficiente quando aplicado em imagens RGB, identificando 717 mudas de um total de 1069, já nas imagens MSP o algoritmo obteve um desempenho inferior, identificando 61 mudas de um total de 1011. Um outro resultado do trabalho foi o índice de Jaccard, que infere a porcentagem de acerto no delineamento (análise de sobreposição/interseção) dos objetos identificados (mudas), neste caso, tanto para as imagens RGB quanto para as MSP, o algoritmo apresentou um índice de interseção com variação de 50 a 95%. A contribuição deste estudo para as futuras pesquisas em monitoramento e mapeamento da vegetação, demonstra que é possível automatizar a contagem e delineamento de mudas em imagens derivadas de RPAS, poupando recursos e tempo, confirmando que o uso de algoritmos de inteligência artificial representa um método muito promissor para realização desta tarefa. Conclui-se também que a maior eficiência do algoritmo nas imagens RGB descarta a necessidade de utilizar um sensor multiespectral para esta finalidade, barateando o custo dos equipamentos e trazendo alternativas para o monitoramento da restauração florestal.

**Palavras-chave:** monitoramento da restauração. sensoriamento remoto. drone. Mask R-CNN.

### **ABSTRACT**

*Forest restoration corresponds to several actions and techniques aimed at repairing and maintaining forest ecosystems. In Brazil, forest restoration plays an important role in the restitution of the Atlantic Forest biome and only gained ground in the 21st century with the introduction of laws that demand compensation and repair of environmental damage. In this sense, forest restoration can not be applied aiming only at the techniques that best serve the study area, but also it is essential to consider its long-term monitoring to verify the progression of the restoration process. Nowadays, restoration monitoring uses equipment such as the Remotely Piloted Aircraft System (RPAS) that through loco activities and image processing in the laboratory aids the periodic inspection of the restored area. It enables information such as the number of resilient individuals, species classification, and vegetation height of the given area. Such monitoring practices require a large investment of time and human resources. Those practices may contribute to greater cost-effectiveness of the restoration process if they are optimized. In front of the current impediments in optimizing forest restoration monitoring, this project aims to apply the artificial intelligent algorithm Mask R-CNN to automate the counting and delineation of restoration seedlings in images from RPAS, comparing the performance of this algorithm in RGB and multispectral (MSP) images. The results obtained by the study showed that the algorithm was more efficient when applied to RGB images, identifying 717 seedlings out of a total of 1069. On the other side, the MSP images obtained a lower performance, identifying 61 seedlings out of a total of 1011. Another outcome of the study was the Jaccard index, which refers to the percentage of hits in the delineation (overlap/intersection analysis) of identified objects (seedlings), in this case, such as to the images RGB as to the MSP, the algorithm presented an index of intersection ranging from 50 to 95%. The contribution of this study to future academic research in monitoring and mapping the vegetation shows that it is possible to automate the counting of seedlings delineation in RPAS derived from images. Moreover, it saves resources and time, acknowledging that the use of artificial intelligence algorithms represents a promising method for accomplishing this function. It is also concluded that the greater efficiency of the algorithm in RGB images rules out the need to use a multispectral sensor for this purpose, lowering the cost of equipment and bringing alternatives to make monitoring forest restoration more viable.*

*Keyword: restoration monitoring. remote sensing. drone. Mask R-CNN.*

## LISTA DE ILUSTRAÇÕES

Figura 1 - Área de restauração florestal da UFSCar de Araras (região central da fotografia).	18
Figura 2 - Mapa de localização da área de restauração florestal da UFSCar de Araras.	19
Figura 3 - DJI Mavic 2 Pro adaptado com sensor MSP <i>Parrot</i> Sequoia+.	20
Figura 4 - Coleta dos GCPs com o receptor Spectra Precision SP60.	21
Figura 5 - Coleta do ponto base com o receptor Spectra Precision SP60.	21
Figura 6 - Mosaico RGB da área de estudo.	23
Figura 7 - Mosaico MSP falsa cor da área de estudo.	23
Figura 8 - Mapa da verdade de campo no mosaico RGB.	25
Figura 9 - Mapa da verdade de campo no mosaico MSP.	26
Figura 11 – Gráfico da qualidade do treinamento com 400 amostras no mosaico RGB.	30
Figura 12 – Mapa das mudas segmentadas pelo modelo Mask R-CNN treinado com 400	31
Figura 13 – Gráfico da qualidade do treinamento com 500 amostras no mosaico MSP.	32
Figura 14 – Mapa das mudas segmentadas pelo modelo Mask R-CNN treinado com 500 amostras no mosaico MSP.	32

## LISTA DE TABELAS

Tabela 1 - Relação teórica - área de inferência dos resultados.	19
Tabela 2 - Relação de mudas da área de inferência dos resultados no mosaico RGB.	24
Tabela 3 - Relação de mudas da área de inferência dos resultados no mosaico MSP.	25
Tabela 4 - Informações de treinamento dos modelos Mask R-CNN no mosaico RGB.	27
Tabela 5 - Informações de treinamento dos modelos Mask R-CNN no mosaico MSP.	27
Tabela 6 – Matriz de confusão dos modelos Mask R-CNN no mosaico RGB.	29
Tabela 7 – Índice IoU dos modelos Mask R-CNN no mosaico RGB.	29
Tabela 8 – Matriz de confusão dos modelos Mask R-CNN no mosaico MSP.	29
Tabela 9 – Índice IoU dos modelos Mask R-CNN no mosaico MSP.	30

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>12</b>
<b>2</b>	<b>OBJETIVOS</b> .....	<b>15</b>
2.1	OBJETIVO GERAL .....	15
2.2	OBJETIVOS ESPECÍFICOS .....	15
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>15</b>
3.1	RESTAURAÇÃO FLORESTAL .....	15
3.2	SEGMENTAÇÃO DE IMAGENS NO SENSORIAMENTO REMOTO DA VEGETAÇÃO .....	16
<b>4</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>18</b>
4.1	ÁREA DE ESTUDO .....	18
4.3	PÓS-PROCESSAMENTO DOS DADOS GNSS E PROCESSAMENTO DAS IMAGENS AÉREAS .....	22
4.4	ELABORAÇÃO DAS VERDADE DE CAMPO, TREINAMENTO DO ALGORITMO, INFERÊNCIA DOS RESULTADOS E VERIFICAÇÃO DA ACURÁCIA DOS MODELOS .....	24
<b>5</b>	<b>RESULTADOS</b> .....	<b>29</b>
<b>6</b>	<b>DISCUSSÃO DOS RESULTADOS</b> .....	<b>33</b>
<b>7</b>	<b>CONCLUSÕES</b> .....	<b>34</b>
	<b>REFERÊNCIAS</b> .....	<b>35</b>

## 1 INTRODUÇÃO

Atualmente existem diversos ecossistemas com diferentes níveis de degradação, desde alterações parciais até grandes interferências antrópicas, ações que contribuem progressivamente para a degradação da biosfera. Apesar de muitos ecossistemas não apresentarem condições naturais de regeneração e recuperação a curto prazo, a interferência humana pode atuar de maneira benéfica, ajudando estas áreas a possuírem condições semelhantes às iniciais, através de um processo conhecido como restauração ecológica (BRANCALION et al., 2015).

A restauração ecológica deve ser entendida como uma ampla ciência onde os ecossistemas restaurados podem variar de recifes de corais até florestas tropicais, obrigando a distinção em seus estudos. Deste modo, chamamos de restauração florestal todo e qualquer processo de restauração ecológica atrelado aos ecossistemas florestais. No Brasil esta restauração teve início no século XIX ganhando força apenas no século XXI, com a criação de instrumentos legais que objetivam a reparação de danos ambientais, sendo que estes instrumentos impulsionam as atividades da restauração florestal aumentando os estudos e a demanda de projetos, consolidando a crescente formação de profissionais e de pesquisas nos últimos anos (BRANCALION et al., 2015).

Um método de restauração florestal, em áreas que impossibilitam o uso do potencial de regeneração natural, é o plantio de sementes e mudas que proporcionam condições favoráveis para o desenvolvimento do meio ambiente, técnica utilizada com frequência no Brasil para reparação da Mata Atlântica (RODRIGUES, et al. 2009). Como boa parte das áreas degradadas no país apresentam baixa resiliência local e de paisagem, com poucos fragmentos remanescentes, o plantio de mudas acaba sendo o principal método utilizado para atender as demandas legais (BRANCALION et al., 2015).

Considerando a necessidade em obter informações da dinâmica florestal, o sensoriamento remoto vem demonstrando um grande potencial em gerar produtos para estudos de vegetação e inventário florestal, imagens aéreas com resoluções espaciais cada vez melhores estão entre as grandes vantagens de sua aplicação. Esta vantagem é assegurada graças à utilização de RPAS (sigla em inglês para sistema de aeronaves pilotadas remotamente), tecnologia popularmente conhecida como drone e que oferece um monitoramento próximo ao nível do solo, criando uma boa integração com o estudo da vegetação (ARAUJO et al., 2020).

O sensoriamento remoto com RPAS é difundido no monitoramento em microescala, onde o projeto se aplica em uma pequena área quando comparada com cenas de plataformas orbitais. A aplicação de RPAS passa a ser apropriada em estudos florestais, onde os principais objetivos são, por exemplo, determinar as linhas de plantio, identificar possíveis pragas e contabilizar indivíduos. Entre os benefícios assegurados pelo monitoramento com RPAS temos o baixo custo operacional, a flexibilidade da resolução temporal (podendo obter informações diárias e em qualquer horário), além da versatilidade em sobrevoar uma mesma região utilizando diferentes sensores passivos ou ativos (NETO et al., 2019).

Os sensores passivos captam a energia eletromagnética refletida pelos objetos enquanto os sensores ativos são capazes de emitir e captar a onda que será refletida pelos alvos, tendo como exemplo de sensor ativo o LIDAR (do inglês *Light Detection and Ranging* que significa Detecção de Luz e Alcance) que varre uma superfície enviando pulsos de laser, apesar de sua grande eficiência em sensoriamento remoto da vegetação, sua utilização demanda um grande custo financeiro e conhecimento operacional. Entre os sensores passivos mais utilizados temos o RGB que opera na faixa do espectro visível (400 a 700 nm) e o multiespectral (MSP) que registra imagens em múltiplas bandas (*Blue, Green, Red, Near-infrared, Red edge*, entre outros), sendo que nos estudos florestais o uso de RGB é atrelado a fotointerpretação enquanto o MSP permite uma melhor caracterização espectral da vegetação (NETO et al., 2019).

Um dos principais objetivos do monitoramento da restauração é verificar se o projeto de restauração está se desenvolvendo de maneira correta. Informações como a altura de indivíduos vegetais, densidade de regenerantes e mortalidade dos indivíduos são alguns dos indicadores quantitativos, parâmetros que possibilitam avaliar a qualidade da restauração (BRANCALION et al., 2015). Quando falamos em pagamento por projetos de restauração florestal, o contratante tem interesse em saber se os parâmetros estão sendo verificados, informações que quantificam a qualidade do projeto indicam se o que foi pago está sendo devidamente cumprido, neste aspecto, o contratado deve realizar um monitoramento adequado da área do projeto, visando obter os parâmetros desejados.

Nos atuais estudos de dinâmica e manejo florestal, a interpretação, o delineamento e a contagem automática de indivíduos e espécies vegetais em imagens, configuram as maiores problemáticas encontradas. As alternativas mais promissoras para resolução destes problemas estão nos algoritmos de inteligência artificial aplicados no processamento de imagens de alta resolução espacial, tornando evidente o grande potencial em estudos que relacionam trabalhos de campo com RPAS e processamento digital de imagens utilizando

técnicas de aprendizagem profunda (*deep learning*) e visão computacional (ONISHI, et al. 2021).

Diante do contexto abordado, este trabalho compreende um estudo da aplicação do algoritmo Mask R-CNN (inteligência artificial) para verificar a resposta obtida na identificação de mudas de restauração florestal em imagens RGB e MSP, provenientes de RPAS. Pretende-se, deste modo, verificar o resultado obtido pelo uso de inteligência artificial nas atividades de monitoramento da restauração, além disso, comparar os produtos gerados utilizando imagens RGB e MSP.

Contudo, há uma dificuldade prática de se monitorar os estágios iniciais de projetos de restauração. Esse monitoramento, com foco em controle de qualidade, tem seu início na localização e contagem de indivíduos plantados, que uma vez mapeados, podem gerar outros produtos de monitoramento (mortalidade, análise de espaçamento, estimativa de altura, classificação em espécies, etc). Entende-se, deste modo, que este trabalho pode auxiliar nos futuros estudos do monitoramento da restauração florestal em sua fase inicial, utilizando método de *deep learning* e segmentação de imagens para viabilizar a identificação automática de mudas em produtos derivados do sensoriamento remoto.

A realização deste trabalho tem como justificativa a necessidade de estudar, no contexto do monitoramento da restauração, ferramentas que automatizam a segmentação de objetos em imagens derivadas de RPAS, visando acompanhar o processo de restauração florestal em sua fase inicial para poupar tempo, mão de obra e verba, garantindo o sucesso da restauração florestal.

O presente estudo também se insere em um projeto temático FAPESP que busca compreender e estudar a dinâmica da paisagem restaurada – Projeto temático FAPESP nº 2018/18416-2 intitulado “Compreendendo florestas restauradas para o benefício das pessoas e da natureza - NewFor”.

## **2 OBJETIVOS**

### **2.1 OBJETIVO GERAL**

O presente trabalho tem por objetivo aplicar o algoritmo de inteligência artificial Mask R-CNN dentro do software ArcGIS Pro, utilizando diferentes rotinas de treinamento, para identificar mudas de restauração florestal em mosaicos de imagens RGB e multiespectrais provenientes de RPAS.

### **2.2 OBJETIVOS ESPECÍFICOS**

Como objetivos específicos do estudo, tem-se:

- A criação de poligonais que representam as mudas de restauração florestal nos mosaicos RGB e MSP, através do processo de segmentação do algoritmo Mask R-CNN;
- A criação de um mapa de localização das mudas; e
- A criação de uma matriz de confusão comparando a qualidade dos resultados obtidos para cada rotina de treinamento.

## **3 FUNDAMENTAÇÃO TEÓRICA**

### **3.1 RESTAURAÇÃO FLORESTAL**

Por uma perspectiva histórica podemos dizer que a exigência em recuperar a vegetação nativa no Brasil evoluiu de acordo com o tempo, o primeiro Código Florestal instituído em 1934 estabelecia em seu art. 23 que “Nenhum proprietário de terras cobertas de mattas poderá abater mais de tres quartas partes da vegetação existente”, esta vigência formulou o que conhecemos hoje por reserva legal (RL). Outra exigência estabelecida neste código foi o art. 76 que sinalizava: “A importancia paga com a indemnização do damno causado a qualquer floresta, será applicado no replantio, ou restauração, da mesma floresta, ou, não sendo possivel, de outra próxima” (COSTA, 2016).

Em 1965 a Lei nº 4.771 determinava no seu art. 44 que todo imóvel rural com área sem a exigência de RL deveria compensar este espaço assistindo a regeneração natural ou conduzindo o plantio de mudas em uma área equivalente, dentro da mesma microbacia do imóvel. Na atualidade o novo código florestal (Lei nº 12.651/2012), sancionada em 2012, também chamado de Lei de Proteção à Vegetação Nativa (LPVN), amplia e reconhece de forma clara a necessidade de restituir Áreas de Preservação Permanentes (APPs) e RL, resultando nas crescentes atividades de restauração ecológica (COSTA, 2016).

Analisando as leis que já foram criadas no Brasil com o objetivo de preservar a vegetação nativa, é notório o foco que estes instrumentos legais possuem em exigir a reparação e restauração dos ecossistemas e da biodiversidade, práticas que são necessárias para garantir o bom funcionamento ecológico do meio físico, entretanto, surge a discussão sobre os recursos tecnológicos, humanos e econômicos para o funcionamento dos projetos de restauração (COSTA, 2016).

Do ponto de vista econômico a LPVN representa um grande incentivo no país, uma de suas características foi o fortalecimento do Pagamento por Serviços Ambientais (PSA) para os proprietários de terras que dispõem de áreas com preservação e recuperação ecológica (BRANCALION *et al.*, 2016). O PSA pode ser entendido como a remuneração atribuída a preservação da biodiversidade, preservação hidrológica e sequestro de carbono, onde os beneficiários que proporcionam estes serviços ambientais recebem um pagamento governamental com um valor reajustado anualmente (PERES, 2019).

Dentro do PSA existem diversas modalidades que inserem o beneficiário nos mercados econômicos internacionais, o principal deles é o crédito de carbono, atribuído pelo sequestro ou diminuição do fluxo de carbono (CARNEIRO *et al.*, 2020). Portanto, as vantagens associadas à restauração florestal não refletem apenas na contribuição em reparar o meio ambiente, também estão cada vez mais vinculadas à questão econômica global, configurando uma tendência o pagamento por serviços ambientais e a retribuição pelo aumento do estoque de carbono.

### 3.2 SEGMENTAÇÃO DE IMAGENS NO SENSORIAMENTO REMOTO DA VEGETAÇÃO

O aumento na capacidade computacional das atuais tecnologias possibilitou a *deep learning* se desenvolver e abrir novos caminhos para o tratamento dos dados de sensoriamento remoto, o surgimento de redes com um maior número de camadas de processamento transformou as convencionais redes de informações em cadeias profundas de aprendizagem, capazes de relacionar quantidades superiores de dados (KATTENBORN *et al.*, 2021).

As redes neurais convolucionais conhecidas por sua sigla em inglês CNN (*Convolutional Neural Network*) caracterizam um método de *deep learning* criado originalmente para reconhecer objetos em imagens, sem a preocupação de informar características de dimensões espaciais. Com sua vasta aplicação, principalmente em

sensoriamento remoto, este método começou a ser difundido em trabalhos que buscavam estabelecer análises espaciais de objetos, possibilitando o aperfeiçoamento destes algoritmos (FERREIRA *et al.*, 2020).

No sensoriamento remoto da vegetação, a CNN vem demonstrando resultados promissores quando comparada com as demais arquiteturas de aprendizagem profunda, tendo como grande característica a capacidade de identificar com eficiência os traços contextuais dos *pixels* vizinhos, sinalizando uma vantagem em mapear padrões encontrados em estudos de vegetação (KATTENBORN *et al.*, 2019). Considerando tal aspecto, uma de suas grandes finalidades está na detecção e segmentação de copas e indivíduos florestais, técnicas que consistem em localizar e delinear um objeto atribuindo uma classe a ele (KATTENBORN *et al.*, 2021).

Entre as CNN utilizadas em sensoriamento remoto a arquitetura baseada em máscara de região (Mask R-CNN) é a mais difundida na segmentação de instâncias (KATTENBORN *et al.*, 2021). Como apresentado no trabalho de Machefer *et al.* (2020), a Mask R-CNN foi utilizada no processo de segmentação e detecção de plantas em imagens de RPAS, os resultados obtidos demonstraram a eficiência desta arquitetura em imagens de alta resolução espacial, implicando em uma boa contagem e localização de indivíduos quando comparado com os métodos tradicionais de visão computacional.

Em Braga *et al.* (2019) o delineamento e a localização de copas de árvores em imagens de RPAS foram executados utilizando a mesma arquitetura e o produto gerado demonstrou uma alta taxa de acerto e, apesar do bom resultado do trabalho, foi apontado uma perda na qualidade da identificação de indivíduos pequenos e com pouca cobertura de *pixels*, todavia, o trabalho sugere a correção desta falha com o acréscimo de mais dados de copas de árvores pequenas no conjunto de arquivos de treinamento da rede.

A Mask R-CNN também foi utilizada por Chadwick *et al.* (2020) para delinear copas individuais de coníferas através de imagens RGB de alta resolução espacial obtidas por RPAS. Seus resultados comprovaram a capacidade desta rede neural em delinear automaticamente as copas de coníferas em vastas condições de regeneração, apontando como maior desvantagem, apenas a obrigatoriedade em vetorizar manualmente um conjunto de dados de treinamento.

## 4 MATERIAIS E MÉTODOS

### 4.1 ÁREA DE ESTUDO

A área de restauração florestal utilizada no trabalho está localizada no *campus* de Araras da Universidade Federal de São Carlos e corresponde a uma área experimental do Laboratório de Silvicultura e Pesquisas Florestais (LASPEF). O projeto de restauração foi realizado em março de 2021 e conta com uma área de aproximadamente 4,6 ha, possuindo 5.184 mudas plantadas em um espaçamento de 2 x 3 metros (2 m entre as mudas e 3 m entre as linhas).

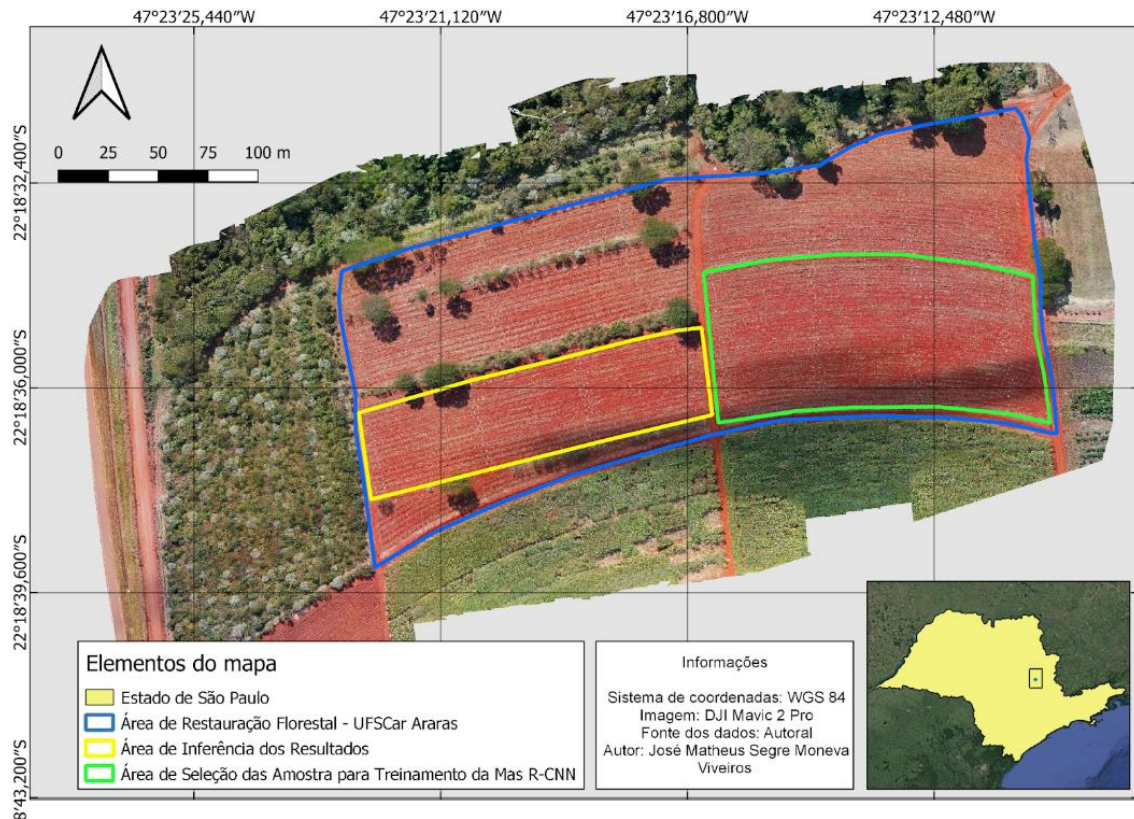
Figura 1 - Área de restauração florestal da UFSCar de Araras (região central da fotografia).



Fonte: Molin, 2021.

Apesar da área de restauração equivaler a 4,6 ha, o presente estudo não utilizou toda essa extensão, optando por delimitar duas grandes parcelas (Figura 2). A primeira representa a região onde foram vetorizadas as mudas para criação dos bancos de dados de treinamento (*datasets*), e a segunda onde foram aplicados os modelos de Mask R-CNN já treinados, para inferência dos resultados.

Figura 2 - Mapa de localização da área de restauração florestal da UFSCar de Araras.



Fonte: Compilado do autor.

A área de inferência dos resultados contava com 16 linhas de plantio e foi delimitada considerando uma parcela florestal com um inventário de campo pré-estabelecido, este inventário possibilitou a criação de uma relação teórica (Tabela 1) onde se quantificou o número de mudas plantadas dentro da área de inferência dos resultados. Posteriormente, esta relação teórica foi utilizada para validar a fotointerpretação e vetorização manual das mudas presentes na área, dando origem a bancos de dados vetoriais denominados verdade de campo.

Tabela 1 - Relação teórica - área de inferência dos resultados.

Relação Teórica - Área de Inferência dos Resultados	
	Número de Mudas Plantadas
Mudas por Linha	85
Total	1360

Fonte: Compilado do autor.

Em relação à área de seleção das amostras para treinamento da Mask R-CNN, foi escolhida uma região da área de restauração florestal onde se verificou uma maior diversidade

nas espécies de mudas plantadas. Esta diversidade é fundamental para criação dos *datasets* de treinamento pois, considerando a variação na geometria dos objetos (mudas), o processo de treinamento do algoritmo necessita de amostras com diferentes características, possibilitando a generalização das feições dos objetos no processo de inferência dos resultados.

#### 4.2 TRABALHO DE CAMPO

A etapa de campo foi realizada em maio de 2021 e contou com duas atividades, os voos com RPAS e as coletas dos pontos de controle em solo (do inglês, GCPs). Para realização dos voos foi utilizado a RPAS DJI Mavic 2 Pro adaptado com o sensor MSP *Parrot Sequoia+* (Figura 3), onde se obteve imagens RGB e MSP da área de estudo.

Figura 3 - DJI Mavic 2 Pro adaptado com sensor MSP *Parrot Sequoia+*.



Fonte: Molin, 2021.

As imagens RGB foram obtidas com o próprio sensor de fábrica (Hasselblad) embarcado na aeronave, garantindo produtos com resolução espacial de 1,4 cm/*pix* derivados de um voo com altura de 60 metros e sobreposição frontal e lateral de 85% das imagens (parâmetros de voo). Já as imagens MSP, foram geradas com o sensor *Parrot Sequoia+* utilizando os mesmos parâmetros de voo, resultando em imagens nas bandas ( *green, red, red edge* e *near infrared*) com resolução espacial de 6,5 cm/*pix*.

Ainda na etapa de campo foram distribuídos, antes da realização dos voos, quatro GCPs (Figura 4) nos limites da área de estudo, onde foram coletadas suas coordenadas com o

receptor GNSS geodésico Spectra Precision SP60. Simultaneamente à coleta dos GCPs, um outro receptor do mesmo modelo foi alocado em um ponto fixo durante cinco horas, para servir como ponto base (Figura 5) para o pós-processamento relativo dos demais GCPs. Toda a atividade com os receptores GNSS foi necessária para garantir a posterior correção espacial das imagens na etapa de criação dos mosaicos das imagens, garantindo uma qualidade na georreferenciamento dos objetos (mudas) que serão identificados pelo algoritmo Mask R-CNN.

Figura 4 - Coleta dos GCPs com o receptor Spectra Precision SP60.



Fonte: Molin, 2021.

Figura 5 - Coleta do ponto base com o receptor Spectra Precision SP60.



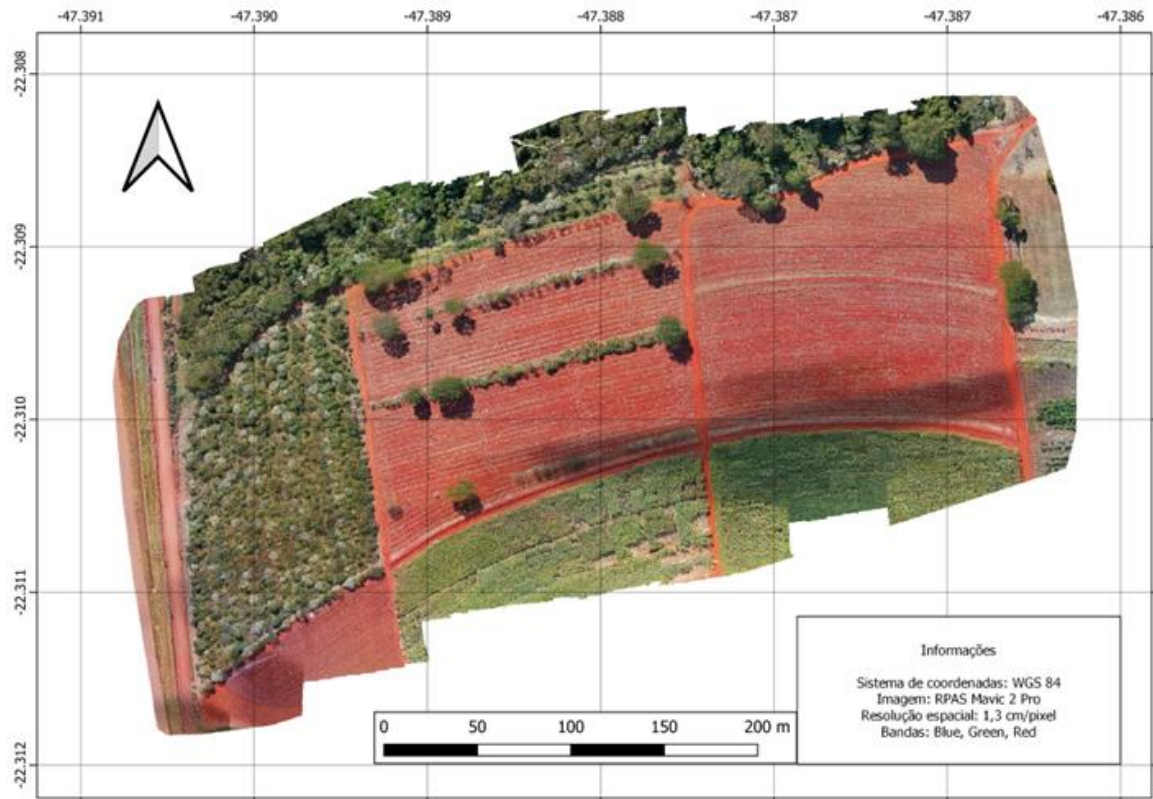
Fonte: Molin, 2021.

### 4.3 PÓS-PROCESSAMENTO DOS DADOS GNSS E PROCESSAMENTO DAS IMAGENS AÉREAS

Após a coleta dos dados em campo foram realizados processamentos em laboratório, onde se extraiu e pós-processou os dados GNSS dos receptores Spectra SP60, através do *software* Survey Office utilizando o método PPK (*Post Processing Kinematic*). Nesta etapa, o arquivo do receptor base foi corrigido através do processo de triangulação utilizando como referência três estações de monitoramento da Rede Brasileira de Monitoramento Contínua (RBMC), do IBGE. Com o arquivo do receptor base pós-processado e ajustado, aplicou-se uma correção diferencial nos arquivos do receptor *rover* (GCPs) em relação ao arquivo base.

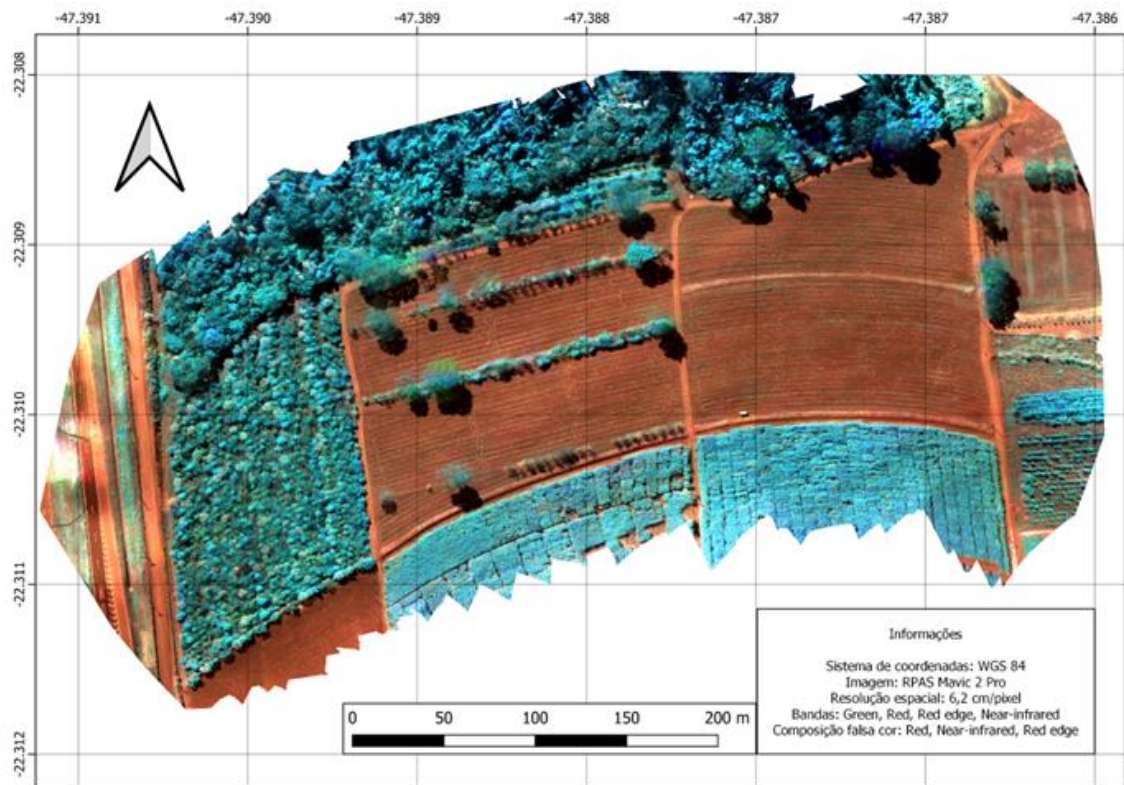
As imagens do RPAS também foram processadas nesta etapa do trabalho utilizando o *software* Pix4DMapper, gerando os mosaicos RGB e multiespectrais (Figuras 6 e 7, respectivamente) com as devidas correções geoespaciais, através das coordenadas pós-processadas dos GCPs. Importante salientar que o projeto criado no *software* Pix4DMapper utilizou um *template* personalizado, onde foram configuradas opções que melhor atendiam a demanda do estudo, visando mapeamento de vegetação e resultados que diminuíssem a quantidade de sombras presentes nos mosaicos finais, para melhor desempenho no posterior treinamento do algoritmo de inteligência artificial.

Figura 6 - Mosaico RGB da área de estudo.



Fonte: Compilado do autor.

Figura 7 - Mosaico MSP falsa cor da área de estudo.



Fonte: Compilado do autor.

#### 4.4 ELABORAÇÃO DAS VERDADES DE CAMPO, TREINAMENTO DO ALGORITMO, INFERÊNCIA DOS RESULTADOS E VERIFICAÇÃO DA ACURÁCIA DOS MODELOS

Através dos mosaicos RGB e MSP gerados pelo Pix4DMapper, foram criados dois modelos atribuídos como verdades de campo, um para cada mosaico (Figuras 8 e 9, respectivamente). Estes modelos foram concebidos através da fotointerpretação das mudas presentes na área de inferência dos resultados, correspondendo a polígonos gerados manualmente, cuja finalidade é servir como uma representação correta da geometria e localização das mudas plantadas.

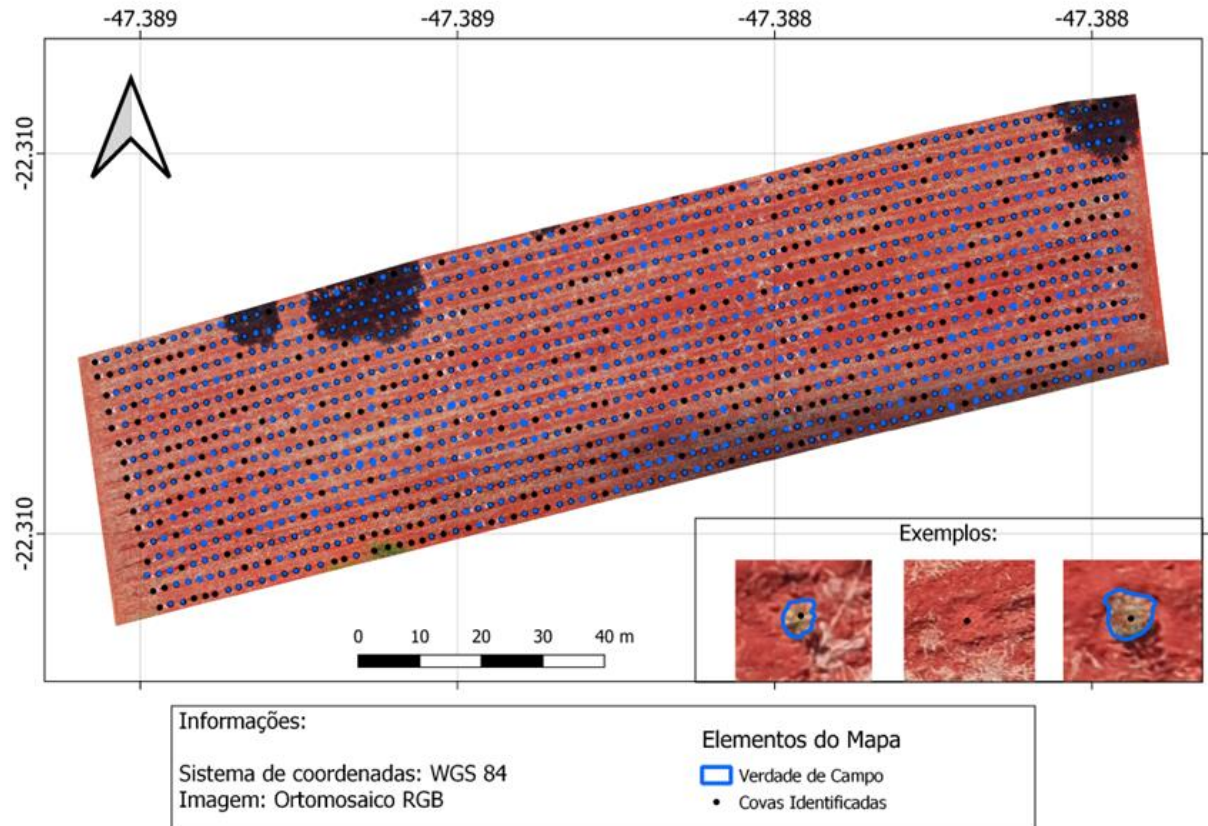
Apenas para o mosaico RGB, foi realizada uma contagem do número de covas, além da vetorização das mudas, onde foram gerados manualmente pontos correspondentes ao centroide de cada cova. Para fins de comparação com a relação teórica mostrada anteriormente, esta contagem teve por objetivo verificar o possível número de indivíduos (mudas) mortos no processo de restauração, confrontando a quantidade de covas identificadas com a quantidade de mudas vetorizadas. A partir deste processo de confronto, foi possível identificar 1.390 covas e 1.069 mudas, indicando uma diferença de 321 plantas que não vingaram, como mostra a Tabela 2.

Tabela 2 - Relação de mudas da área de inferência dos resultados no mosaico RGB.

Relação Fotointerpretação RGB - Área de Inferência dos Resultados																
Linha (ID)	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Num. Covas	86	86	85	90	86	85	86	87	87	86	87	89	87	87	89	87
Total Covas	1390															
Mudas Vetorizadas	61	60	61	71	66	66	65	65	73	59	68	70	70	73	73	68
Total Mudas Vetorizadas	1069															

Fonte: Compilado do autor.

Figura 8 - Mapa da verdade de campo no mosaico RGB.



Fonte: Compilado do autor.

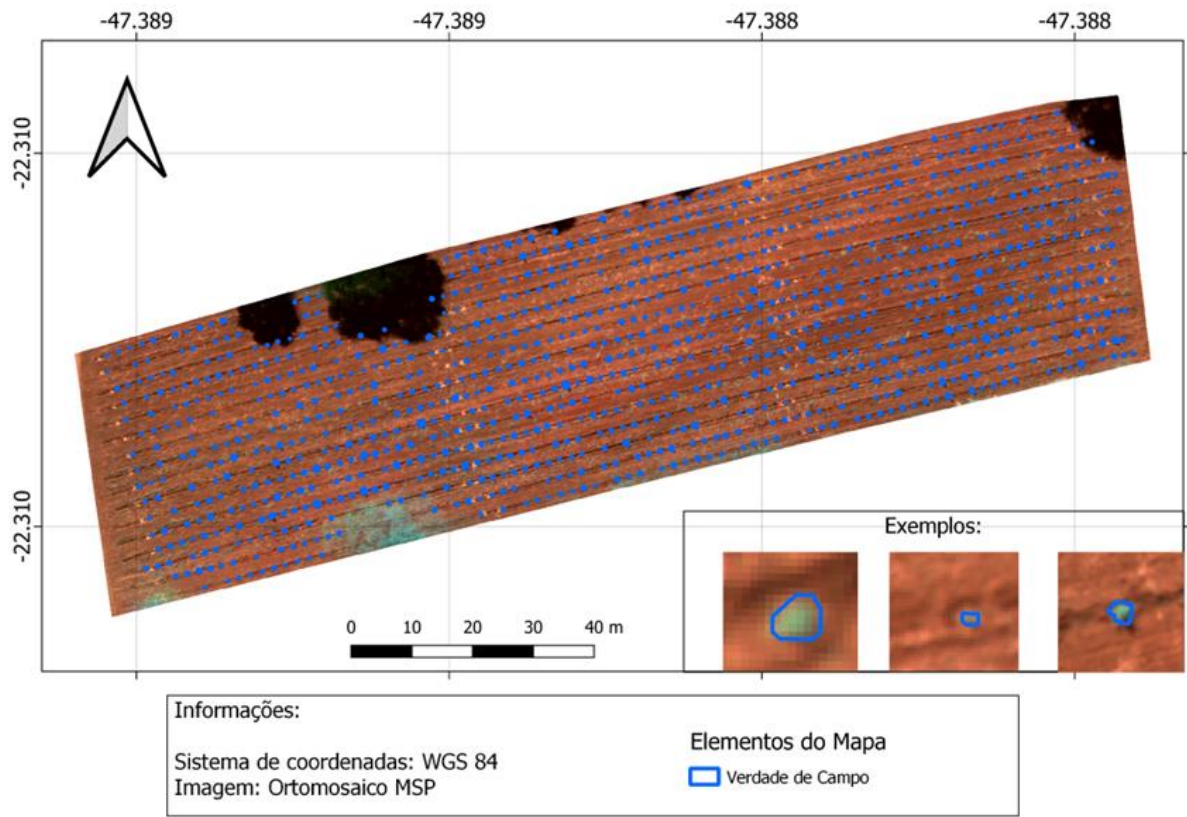
Em relação ao mosaico MSP, a mesma vetorização teve que ser realizada pois a resolução espacial deste mosaico difere do anterior e, portanto, o tamanho e geometria das mudas também. A Tabela 3 mostra a relação de mudas identificadas na área de inferência dos resultados do mosaico MSP e a Figura 9 ilustra um mapa com os polígonos das mudas (verdade de campo MSP) desta área.

Tabela 3 - Relação de mudas da área de inferência dos resultados no mosaico MSP.

Relação Fotointerpretação MSP - Área de Inferência dos Resultados																
Linha de Plantio	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Mudas Vetorizadas	57	58	59	73	65	66	63	63	73	60	68	70	64	66	55	51
Total Mudas Vetorizadas	1011															

Fonte: Compilado do autor.

Figura 9 - Mapa da verdade de campo no mosaico MSP.



Fonte: Compilado do autor.

As verdades de campo foram importantes para posterior comparação com os resultados obtidos pela Mask R-CNN e apuração da qualidade de seus resultados. Para aplicar o algoritmo de inteligência artificial Mask R-CNN na segmentação das mudas nos mosaicos RGB e MSP, foi necessário treinar este algoritmo com amostras contidas em *chips* de imagens denominadas *datasets*. O presente estudo optou por criar quatro diferentes *datasets* para cada mosaico, o primeiro com 200 amostras, o segundo com 300 amostras, o terceiro com 400 e o último com 500 amostras, totalizando 8 *datasets*. Toda a criação dos *datasets*, bem como o treinamento do algoritmo, inferência dos resultados e verificação da acurácia dos modelos foram realizados através da biblioteca de *Deep Learning* encontrada na caixa de ferramentas *Image Analyst Tools* do *software* ArcGIS Pro versão 2.9.3.

A criação dos *datasets* de treinamento partiu da vetorização manual de 200 amostras de mudas no mosaico RGB e, com a ferramenta *Export Training Data for Deep Learning*, estas amostras foram convertidas em um *dataset* com extensão de arquivos compatível ao algoritmo que se pretendia treinar, por fim, este processo foi repetido para a criação dos demais *datasets* de amostras. Importante salientar que, conforme o número de

amostras dos *datasets* aumentavam, eram preservadas as amostras dos *datasets* anteriores, possibilitando uma progressão na representatividade do banco de dados.

Após a criação dos oito *datasets* de treinamento (quatro com amostras RGB e quatro com amostras MSP), os modelos de Mask R-CNN foram treinados com a ferramenta *Training Deep Learning Model* resultando em oito modelos distintos. Nesta etapa, foi importante definir algumas configurações de processamento, sendo estas: o lote (número de amostras processadas de uma única vez dentro da época), a época (número de vezes que o algoritmo interpreta as amostras no processo de aprendizagem), a validação (porcentagem de amostras utilizadas para validar o modelo), o *backbone* (estrutura do algoritmo com o número de neurônios) e o processamento (unidade computacional onde o código fonte é processado).

Tabela 4 - Informações de treinamento dos modelos Mask R-CNN no mosaico RGB.

Informações do Treinamento da Mask R-CNN com amostras RGB				
Amostras	200	300	400	500
Lote	4	4	4	4
Época	39	42	52	39
Validação	20%	20%	20%	20%
Backbone	ResNet-50	ResNet-50	ResNet-50	ResNet-50
Processamento	GTX 1050	GTX 1050	GTX 1050	GTX 1050
Tempo (horas)	04:30	05:00	06:00	13:00

Fonte: Compilado do autor.

Tabela 5 - Informações de treinamento dos modelos Mask R-CNN no mosaico MSP.

Informações do Treinamento da Mask R-CNN com amostras MSP				
Amostras	200	300	400	500
Lote	4	4	4	4
Época	43	52	61	70
Validação	20%	20%	20%	20%
Backbone	ResNet-50	ResNet-50	ResNet-50	ResNet-50
Processamento	GTX 1050	GTX 1050	GTX 1050	GTX 1050
Tempo (horas)	00:58	01:00	01:03	01:05

Fonte: Compilado do autor.

Para cada treinamento foi gerado um arquivo na extensão *dlpk* (*deep learning package*), que representa o modelo de *deep learning* treinado, estes arquivos foram utilizados para segmentar as mudas na área de inferência dos resultados nos mosaicos RGB e MSP. Interessante perceber que o modelo só pode ser aplicado em um mosaico com a mesma resolução espectral das imagens utilizadas no *dataset* do seu treinamento, ou seja, um modelo

dlpk só funciona em um mosaico RGB se o mesmo foi treinado com amostras em imagens RGB, valendo-se da mesma lógica para o mosaico MSP.

A aplicação dos modelos na tarefa de segmentação foi possível através da ferramenta *Detect Objects Using Deep Learning*, e os resultados obtidos para cada modelo foram polígonos que, em teoria, correspondem às mudas presentes na área de inferência dos resultados. Para verificar a acurácia de cada resultado e, portanto, de cada modelo, foram utilizadas as verdades de campo. Nesta etapa final do trabalho, a acurácia foi calculada pela métrica de análise conhecida como índice de Jaccard (coeficiente de correlação) ou IoU (*Intersection over Union*), onde os polígonos dos objetos detectados pelos modelos são sobrepostos aos polígonos da verdade de campo, gerando uma matriz de confusão e uma porcentagem de sobreposição entre os dois conjuntos de dados. O cálculo da porcentagem de sobreposição dos polígonos (Figura 10) é obtido pela divisão dos valores de intersecção dos objetos (1) com os valores de suas respectivas uniões (2).

Figura 10 – Cálculo da sobreposição dos objetos pelo índice IoU.



Fonte: ESRI, 2021.

## 5 RESULTADOS

Os resultados alcançados pelo algoritmo Mask R-CNN foram separados em duas categorias distintas, os resultados obtidos no mosaico RGB e os resultados obtidos no mosaico MSP. Em cada categoria os resultados de seus modelos foram comparados através de uma matriz de confusão (Tabelas 6 e 8) e uma planilha com o índice IoU (Tabelas 7 e 9), posteriormente, foram discutidos a qualidade dos resultados no mosaico RGB e no MSP.

Importante salientar que a matriz de confusão corresponde a uma relação dos registros obtidos pelos modelos, sendo classificados como: verdadeiros positivos o número de objetos identificados corretamente, falsos positivos o número de objetos identificados erroneamente e falsos negativos o número de objetos que deveriam ser identificados.

Tabela 6 – Matriz de confusão dos modelos Mask R-CNN no mosaico RGB.

<b>Matriz de Confusão</b>			
Modelos	Verd. positivo	Falso positivo	Falso negativo
200 Amostras	659	1	410
300 Amostras	569	0	500
400 Amostras	717	1	352
500 Amostras	584	3	485

Fonte: Compilado do autor.

Tabela 7 – Índice IoU dos modelos Mask R-CNN no mosaico RGB.

<b>Intersection over Union (IoU)</b>					
Modelos	0,1 >IoU> 0,3	0,3 >IoU> 0,5	0,5 >IoU> 0,75	0,75 >IoU> 0,95	0,95 >IoU> 1
200 Amostras	1	11	235	412	0
300 Amostras	0	8	261	300	0
400 Amostras	3	12	308	394	0
500 Amostras	0	12	236	336	0

Fonte: Compilado do autor.

Tabela 8 – Matriz de confusão dos modelos Mask R-CNN no mosaico MSP.

<b>Matriz de Confusão</b>			
Modelos	Verd. positivo	Falso positivo	Falso negativo
200 Amostras	0	0	1011
300 Amostras	0	0	1011
400 Amostras	0	0	1011
500 Amostras	61	0	950

Fonte: Compilado do autor.


Tabela 9 – Índice IoU dos modelos Mask R-CNN no mosaico MSP.

<i>Intersection over Union (IoU)</i>					
Modelos	0,1 >IoU> 0,3	0,3 >IoU> 0,5	0,5 >IoU> 0,75	0,75 >IoU> 0,95	0,95 >IoU> 1
200 Amostras	0	0	0	0	0
300 Amostras	0	0	0	0	0
400 Amostras	0	0	0	0	0
500 Amostras	0	0	31	30	0

Fonte: Compilado do autor.

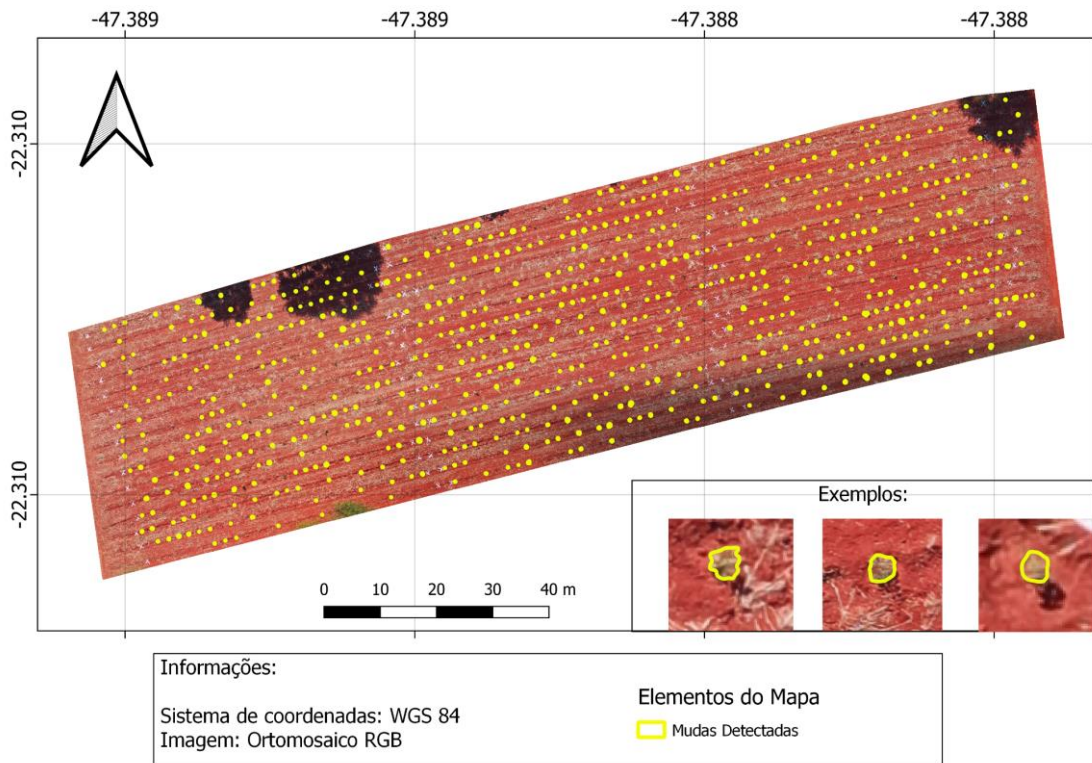
Considerando os modelos de Mask R-CNN aplicados no mosaico RGB, seus resultados apresentaram uma variação de 569 a 717 mudas segmentadas de um total de 1069, sendo o modelo treinado com 400 amostras o de maior destaque, demonstrando uma acurácia de 67%. As Figuras 11 e 12 ilustram, respectivamente, o gráfico da qualidade do treinamento e o mapa das mudas segmentadas por este modelo.

Figura 11 – Gráfico da qualidade do treinamento com 400 amostras no mosaico RGB.



Fonte: Compilado do autor.


Figura 12 – Mapa das mudas segmentadas pelo modelo Mask R-CNN treinado com 400 amostras no mosaico RGB.



Fonte: Compilado do autor.

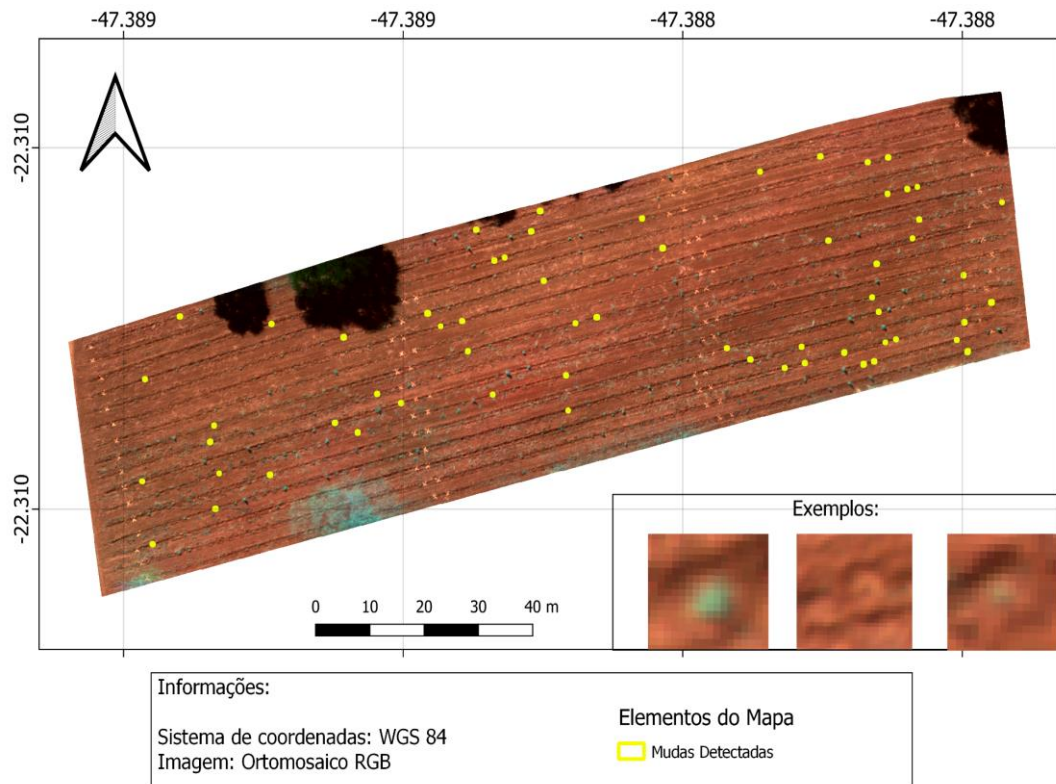
Em relação aos modelos aplicados no mosaico MSP, o único que conseguiu segmentar as mudas foi o modelo treinado com 500 amostras, demonstrando uma acurácia de 3% em seus resultados, segmentando apenas 61 mudas de um total de 1011. As figuras 13 e 14 ilustram, respectivamente, o gráfico da qualidade do treinamento e o mapa das mudas segmentadas por este modelo.

Figura 13 – Gráfico da qualidade do treinamento com 500 amostras no mosaico MSP.



Fonte: Compilado do autor.

Figura 14 – Mapa das mudas segmentadas pelo modelo Mask R-CNN treinado com 500 amostras no mosaico MSP.



Fonte: Compilado do autor.

## 6 DISCUSSÃO DOS RESULTADOS

Analisando os resultados do trabalho e considerando todo o aporte teórico necessário para sua realização, é notório que os produtos gerados contribuíram com informações relevantes. Primeiramente, a aplicação de inteligência artificial para segmentação de imagens no contexto do mapeamento da vegetação demonstrou bons resultados (KATTENBORN *et al.* 2019, MACHEFER *et al.* 2020, BRAGA *et al.* 2019), contudo, a segmentação de pequenos objetos sempre foi uma dificuldade recorrente nas pesquisas realizadas (BRAGA *et al.* 2019).

Neste aspecto, os resultados obtidos no mosaico RGB mostraram que, apesar dos objetos segmentados serem muito pequenos, é possível segmentar as mudas utilizando o algoritmo Mask R-CNN em imagens derivadas de RPAS, com resolução espacial próxima de 1,4 cm/pixel. Em relação a quantidade de mudas identificadas, o aumento no número de amostras de treinamento não garantiu um aumento na qualidade e quantidade de objetos detectados, mostrando que existe uma oscilação quando se trabalha com modelos de Mask R-CNN treinados com até 500 amostras.

Em relação aos resultados obtidos no mosaico MSP, o único modelo que conseguiu detectar as mudas foi o modelo treinado com 500 amostras, identificando um número de mudas muito abaixo do esperado. Investigando o gráfico da qualidade do treinamento deste modelo (Figura 13), fica evidente que a curva de treinamento termina abaixo da curva de validação, demonstrando que o número de amostras utilizadas para treinar o algoritmo foi muito baixo, um problema conhecido como *underfitting* (ZHANG *et al.* 2019). Como o mosaico MSP apresenta um maior número de bandas espectrais em seus metadados e, considerando que sua resolução espacial era inferior ao mosaico RGB, possivelmente o problema de *underfitting* foi ocasionado devido a maior complexidade da imagem, exigindo um maior banco de dados de treinamento quando se trabalha com mosaico MSP.

Em relação ao índice IoU extraído dos resultados, para todos os casos foi verificado um coeficiente de correlação satisfatório, tanto para o mosaico RGB quanto para o MSP, comprovando que a tarefa de segmentação realizada pelo algoritmo Mask R-CNN apresenta uma melhor performance quando comparada com a identificação dos objetos.

Sobre a aplicação dos métodos estudados no que tange o monitoramento da restauração florestal, os resultados do trabalho se mostraram muito promissores. O número de mudas identificadas pelo algoritmo no mosaico RGB foi considerável, porém, para fins de monitoramento da restauração, seria necessário um modelo com maior acurácia. Deste modo,

uma alternativa sugerida por este trabalho seria implementar um modelo de Mask R-CNN treinado com um maior banco de dados.

Um outro ponto muito relevante para o monitoramento da restauração é o custo dos equipamentos e sensores utilizados, com os resultados obtidos foi possível verificar que para automatizar a segmentação de mudas através de algoritmos de inteligência artificial, a resolução espacial da imagem apresenta um maior peso quando comparado com a resolução espectral, tendo em vista a comparação entre os resultados apresentados pelos modelos aplicados nos mosaicos RGB e MSP. Portanto, o gasto adicional com sensores multiespectrais torna-se irrelevante quando a finalidade do monitoramento é segmentar as mudas plantadas na fase inicial da restauração florestal.

## 7 CONCLUSÕES

O monitoramento é parte fundamental do processo de restauração florestal, acompanhar a fase inicial do seu desenvolvimento garante o sucesso da área restaurada. Dados como mortalidade de indivíduo, cálculo de biomassa e estimativa da área de dossel são informações relevantes que podem ser adquiridas a partir da contagem das mudas plantadas.

O presente trabalho mostrou que a contagem de mudas de restauração florestal em imagens RGB derivadas de RPAS pode ser automatizada com rotinas de segmentação, através de algoritmos de *deep learning* como a Mask R-CNN. Contudo, o estudo também mostrou que para inferir o número de indivíduos mortos e resilientes, é necessário um algoritmo treinado com um banco de dados superior a 500 amostras e, dependendo da idade das mudas, imagens com resolução espacial mais refinada. Também foi possível verificar que os modelos Mask R-CNN conseguiram diferenciar com êxito as mudas de restauração florestal das brachiarias presentes na área de estudo, através da análise do número de “verdadeiros positivo” e “falsos positivo” gerados a partir da matriz de confusão.

## REFERÊNCIAS

- ARAÚJO, Raquel Fernandes et al. Integrating high resolution drone imagery and forest inventory to distinguish canopy and understory trees and quantify their contributions to forest structure and dynamics. **PLOS ONE**, v. 15, n. 12, dec. 2020, p. 1-16. Disponível em: <https://doi.org/10.1371/journal.pone.0243079>. Acesso em: 12 ago. 2022.
- BRAGA, J.R.G.; VELHO, H.F.C.; SHIGUEMORI, E.; WAGNER, F.H. et al. Algoritmo de Delineação de Copas baseado em Deep Learning. In: **ANAIS DO XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 2019, Santos. Anais eletrônicos. São José dos Campos: INPE, 2019. Disponível em: <https://proceedings.science/sbsr-2019/papers/algoritmo-de-delineacao-de-copas-baseado-em-deep-learning>.
- BRANCALION, Pedro HS et al. Análise crítica da Lei de Proteção da Vegetação Nativa (2012), que substituiu o antigo Código Florestal: atualizações e ações em curso. **Natureza & Conservação**, v. 14, p. e1-e16, 2016.
- BRANCALION, Pedro Henrique Santin; GANDOLFI, Sergius; RODRIGUES, Ricardo Ribeiro. **Restauração florestal**. Oficina de Textos, 2015.
- ESRI (Estados Unidos). **ArcGIS Pro**: compute accuracy for object detection (image analyst). Compute Accuracy For Object Detection (Image Analyst). Disponível em: <<https://pro.arcgis.com/en/pro-app/2.9/tool-reference/image-analyst/compute-accuracy-for-object-detection.htm>>. Acesso em: 25 ago. 2022.
- CHADWICK, Andrew J. et al. Automatic Delineation and Height Measurement of Regenerating Conifer Crowns under Leaf-Off Conditions Using UAV Imagery. **Remote Sensing**, v. 12, n. 24, p. 4104, 2020. Disponível em: <https://doi.org/10.3390/rs12244104>. Acessado em: 28 ago. 2022.
- CARNEIRO, Juliana Paula Sá; DE SOUSA, Joyce Silvestre. Pagamento de serviços ambientais: uma análise sobre sua implantação. **Revista Meio Ambiente e Sustentabilidade**, v. 9, n. 18, 2020.
- COSTA, Márcio Macedo. Financiamento para a restauração ecológica no Brasil. **MUDANÇAS NO CÓDIGO FLORESTAL BRASILEIRO**, c. 9, p. 235, 2016.
- FERREIRA, Matheus Pinheiro et al. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. **Forest Ecology and Management**, v. 475, p. 118397, 2020.
- KATTENBORN, Teja et al. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, p. 24 - 49, 2021. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.12.010>. Acesso em: 05 ago. 2022.
- MACHEFER, MéliSSande et al. Mask R-CNN Refitting Strategy for Plant Counting and Sizing in UAV Imagery. **Remote Sensing**, v. 12, n. 18, p. 3015, 2020. Disponível em: <https://doi.org/10.3390/rs12183015>. Acesso em: 05 ago. 2022.
- MASANORI, Onishi; TAKESHI, Ise. Explainable identification and mapping of trees using UAV RGB image and deep learning. **Scientific Reports (Nature Publisher Group)**, v. 11, n. 1. Disponível em: <https://doi.org/10.1038/s41598-020-79653-9>. Acesso em: 12 ago. 2022.

NETO, Rorai Pereira Martins; BREUNIG, Fábio Marcelo. DRONES NAS CIÊNCIAS FLORESTAIS. **DRONES E CIÊNCIA**, p. 68, 2019.

PERES, Geovana Echeverria. A Importância do Pagamento por Serviços Ambientais–PSA. 2019. Disponível em: <http://dspace.unipampa.edu.br:8080/jspui/handle/riu/4400>.

RODRIGUES, Ricardo R. et al. On the restoration of high diversity forests: 30 years of experience in the Brazilian Atlantic Forest. **Biological conservation**, v. 142, n. 6, p. 1242-1251, 2009.

ZHANG, Haotian; ZHANG, Lin; JIANG, Yuan. Overfitting and underfitting analysis for deep learning based end-to-end communication systems. In: **2019 11th international conference on wireless communications and signal processing (WCSP)**. IEEE, 2019. p. 1-6.