



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
CURSO DE GRADUAÇÃO EM ENGENHARIA FLORESTAL

LETÍCIA DA SILVA CARNEIRO

USO DE GEOTECNOLOGIAS PARA MAPEAMENTO DA PEROBA-ROSA
(Aspidosperma polyneuron Müll. Arg)

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA
Orientador

SEROPÉDICA, RJ
Março – 2023



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
CURSO DE GRADUAÇÃO EM ENGENHARIA FLORESTAL

LETÍCIA DA SILVA CARNEIRO

USO DE GEOTECNOLOGIAS PARA MAPEAMENTO DA PEROBA-ROSA
(Aspidosperma polyneuron Müll. Arg)

Monografia apresentada ao Curso de Engenharia Florestal, como requisito parcial para a obtenção do Título de Engenheiro Florestal, Instituto de Florestas da Universidade Federal Rural do Rio de Janeiro.

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA
Orientador

SEROPÉDICA, RJ
Março – 2023

USO DE GEOTECNOLOGIAS PARA MAPEAMENTO DA PEROBA-ROSA
(Aspidosperma polyneuron Müll. Arg)

LETÍCIA DA SILVA CARNEIRO

APROVADA EM: 01/03/2023

BANCA EXAMINADORA:

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA – UFRRJ
Orientador

Prof. Dr. RICARDO VILAR NEVES – UFRRJ
Membro

Dr. BRUNO GEIKE DE ANDRADE - UFRRJ
Membro

DEDICATÓRIA

Dedico este trabalho as florestas, que são fonte de vida e de inspiração para a minha pesquisa. E, as tecnologias desenvolvidas para a gestão florestal cuja aplicação sustentável é fundamental para nosso futuro.

AGRADECIMENTOS

A conclusão desta jornada não teria sido possível sem o apoio e colaboração de muitas pessoas que me ajudaram a realizar meu sonho de ser Engenheira Florestal. Agradeço a todos que me ajudaram ao longo da minha vida acadêmica e pessoal, me proporcionando conselhos e oportunidades.

Gostaria de começar agradecendo a minha irmã por ser minha companheira constante, por seu amor e por ser minha maior motivação. Ela é minha melhor amiga e minha maior fonte de orgulho.

Aos meus pais, pela dedicação, incentivo e amor. Agradeço sua crença em meu potencial e por estar ao meu lado a cada passo dessa caminhada. Gostaria de agradecer especialmente ao meu pai por ser meu exemplo e mestre, desde a pessoa até o profissional, meu amigo e a conversa de café mais enriquecedora de todas. Também quero agradecer aos meus padrinhos pelo carinho e apoio ao longo da minha vida. Minha sincera gratidão a todos que ajudaram meus pais e a mim desde o início de nossas vidas até agora. Sem cada um de vocês, eu não teria chegado até aqui.

Gostaria de expressar minha gratidão ao grupo PET e à nossa orientadora, Profa. Dra. Vanessa Maria Basso, por compartilharem seu conhecimento, dedicação e pelo apoio durante a maior parte da minha graduação.

Meu orientador, obrigado pela atenção, paciência e sabedoria compartilhada durante todo o processo de escrita. Suas sugestões foram fundamentais para a conclusão deste trabalho. Também gostaria de agradecer a todos que tornaram possível a realização deste trabalho, desde o apoio no dia a dia na floresta até o processamento de dados, em especial ao Prof. Dr. Renato Cesar Gonçalves Robert, que tem uma vontade excepcional de proporcionar grandes experiências florestais aos alunos de Engenharia Florestal.

Agradeço a todas as mulheres que vieram antes de mim, que ocuparam nosso espaço e que tornaram minha caminhada menos difícil. Em especial, agradeço às minhas grandes companheiras de vida, Karolayne e Amanda, por todo o apoio emocional e incentivo durante toda a minha jornada. Agradeço às minhas grandes companheiras de curso, Esther e Bruna, que tornaram o ambiente acadêmico mais estimulante. E grata a minha grande amiga, Mayara, por todas nossas trocas ao longo da vida.

Agradeço a cada lugar que passei e as pessoas que conheci em cada um deles. Obrigado pelas experiências e todas as lições aprendidas. Obrigada a todos que foram minha casa e abrigo, em especial a Karolayne, Jonathan e Patrick, em diferentes momentos da graduação vocês foram a minha parceria e tornaram meus dias mais leves. Foi com vocês que encontrei forças em muitos momentos difíceis.

Gostaria de agradecer à fascinante Universidade Federal Rural do Rio de Janeiro por ter me proporcionado uma experiência única e enriquecedora. Aqui, pude desfrutar de um ambiente acadêmico diverso e desafiador, e tive acesso a uma série de recursos e oportunidades que me ajudaram a crescer como pessoa e profissional. Sou grata pela experiência de ser ruralina, aqui vivi experiências incríveis que guardarei para toda a vida.

Sou grata pela oportunidade de estudar e trabalhar com as maravilhas da natureza, incluindo as majestosas árvores. Agradeço à natureza por ter me presenteado com a beleza das florestas e me inspirado a dedicar minha vida à preservação e conservação desses ecossistemas. Reconheço que a minha formação como Engenheira Florestal não teria sido possível sem o entendimento da importância de preservar a natureza.

Por fim, não posso deixar de agradecer a Deus, por permitir eu estar aqui, com garra e coragem para enfrentar as demais etapas da vida.

RESUMO

A Peroba-Rosa (*Aspidosperma Polyneuron* Mull.Arg) é uma árvore de grande porte, cuja madeira apresenta alta qualidade e valor comercial. Considerada importante para a conservação da biodiversidade, localizar e caracterizar essa espécie no seu espaço é fundamental tanto para atividades econômicas, quanto conservacionistas. Uma forma inovadora de obter informações espaciais detalhadas sobre a ocorrência de espécies de árvores em grandes áreas consiste em integrar imagens de sensoriamento remoto com os métodos de aprendizado de máquina. Este trabalho teve como objetivo desenvolver um modelo de aprendizado profundo para identificar a espécie Peroba-Rosa em um fragmento florestal no Paraguai. O estudo integrou imagens de sensoriamento remoto com métodos de aprendizado de máquina fazendo uso do software ArcGIS Pro para obter informações espaciais detalhadas sobre a ocorrência e mapeamento dessa espécie. O uso de geotecnologias, de soluções de hardware, software e peopleware permitiu o desenvolvimento de um poderoso instrumento de tomada de decisão, que facilitou a coleta, armazenamento e análise eficiente de dados. O modelo de aprendizagem desenvolvido demonstrou uma aplicação técnica viável, porém apresentando resultados com precisão de 23%, e mostrou o potencial desta ferramenta e do uso do ArcGIS Pro para mapeamento da espécie de interesse. Pesquisas futuras podem melhorar a precisão do modelo por meio de mais testes e treinamentos.

Palavras-chave: Geoprocessamento; Aprendizado Profundo; ArcGIS Pro.

ABSTRACT

The Peroba-Rosa (*Aspidosperma Polyneuron* Mull. Arg) is a large tree, whose wood presents high quality and commercial value. Considered important for biodiversity conservation, locating and characterizing this species in its habitat is essential for both economic and conservation activities. An innovative way to obtain detailed spatial information on the occurrence of tree species in large areas is to integrate remote sensing images with machine learning methods. This study aimed to develop a deep learning model to identify the Peroba-Rosa species in a forest fragment in Paraguay. The study integrated remote sensing images with machine learning methods using ArcGIS Pro software to obtain detailed spatial information on the occurrence and mapping of this species. The use of geotechnologies, hardware, software, and peopleware solutions enabled the development of a powerful decision-making tool, which facilitated the efficient collection, storage, and analysis of data. The developed learning model demonstrated a feasible technical application, but showed results with an accuracy of only 23%, indicating the potential of this tool and the use of ArcGIS Pro for mapping the species of interest. Future research can improve the accuracy of the model through further testing and training.

Keywords: Geoprocessing; Deep Learning; ArcGIS Pro

SUMÁRIO

1. INTRODUÇÃO	11
2. REVISÃO DE LITERATURA	2
2.1. Caracterização da <i>Aspidosperma polyneuron</i> Müll. Arg	2
2.2. Geotecnologias	3
2.2.1. Sensoriamento Remoto	3
2.2.2. Geoprocessamento e os Sistemas de Informação Geográfica	4
2.3. Veículo Aéreo Não Tripulado	4
2.4. Deep Learning e Redes Neurais	4
3. MATERIAL E MÉTODOS	6
3.1. Caracterização da Área de Estudo	6
3.2. Base de Dados: Inventário Florestal	6
3.3. Coleta das Amostras	9
3.4. ArcGIS Pro	11
3.5. Desenvolvimento do Modelo	11
3.6. Verificação do Modelo	13
4. RESULTADOS	13
4.1. Exportação dos Dados de Treinamento	13
4.2. Treinamento do Modelo	14
4.3. Detecção de Objetos usando Deep Learning	15
4.4. Verificação da Acurácia da Detecção de Objetos usando Deep Learning	16
5. DISCUSSÃO	17
6. CONCLUSÃO	18
7. REFERÊNCIAS BIBLIOGRÁFICAS	19
ANEXO	24

LISTA DE TABELAS

Tabela 1: Descrição dos dados obtidos no Inventário Florestal.	8
--	---

LISTA DE FIGURAS

Figura 1: Exemplar de <i>Aspidosperma polyneuron</i> Müll. Arg (Hernandarias, Paraguai).	2
Figura 2: Campos e Subcampos da Inteligência Artificial.	5
Figura 3: a) Mapa de Localização b) Zoom Mapa de Localização da Área de Estudo.	7
Figura 4: Mapa da Área de Estudo com subdivisão das Unidades de Pesquisa.	8
Figura 5: Mapa da Distribuição das Perobas-Rosa em cada Unidade de Pesquisa.	9
Figura 6: Destaque da UP 1 e UP 2.	10
Figura 7: Destaque da UP 3, UP 4 e UP5.	10
Figura 8: Passo a passo para desenvolvimento de um modelo em <i>Deep Learning</i> no software ArcGIS Pro.	11
Figura 9: Ortomosaico da Área de Estudo.	12
Figura 10: Arquivos de saída após aplicação da ferramenta <i>Export Training Data For Deep Learning</i>	14
Figura 11: Resultado do arquivo “ <i>stats</i> ” após aplicação da ferramenta <i>Export Training Data For Deep Learning</i>	14
Figura 12: Arquivos de saída após aplicação da ferramenta <i>Train Deep Learning Model</i>	15
Figura 13: Resultado da Detecção de Peroba-Rosa.....	16
Figura 14: Aproximação do Resultado da Detecção de Peroba-Rosa.....	17
Figura 15: Resultado da Verificação de Acurácia do Modelo.....	18

1. INTRODUÇÃO

A Peroba-Rosa (*Aspidosperma polyneuron* Mull. Arg) é uma árvore de grande porte e de madeira de alta qualidade, que é muito valorizada no mercado, utilizada em construção, mobiliário e objetos de decoração (HATSCHBACHE ZILLER, 1995). Devido ao seu alto valor comercial, as intensas extrações dessa espécie ocasionaram sua inclusão na lista de conservação ex situ e in situ na categoria de ameaçada de extinção, tanto no Brasil quanto na Venezuela (CARVALHO, 2004), devido a isso, a utilização da Peroba-Rosa no Brasil é limitada. Atualmente, toda a madeira de Peroba-Rosa utilizada no Brasil é importada do Paraguai, onde ainda é abundante, mas pouco utilizada (CARVALHO, 2004).

Além do seu valor comercial, também é considerada uma espécie importante para a conservação da biodiversidade, pois abriga uma grande variedade de espécies de animais e plantas em seu habitat natural. Independente do uso, é importante preservar, proteger e possuir cada vez mais informações sobre o comportamento dessa espécie para garantir seus benefícios a longo prazo.

Localizar e caracterizar espécies no espaço é fundamental para várias atividades, por exemplo, a conservação da natureza no contexto da mudança global e do declínio da biodiversidade só pode ser implementada e supervisionada com sucesso com representações espaciais precisas do estado, estrutura e funcionamento dos ecossistemas e sua flora (NAGENDRA et al., 2013, PETTORELLI et al., 2017, TURNER et al., 2003). A silvicultura requer informações regulares e extensas sobre os povoamentos florestais, incluindo sua estrutura, volume de madeira, composição de espécies e danos florestais (FASSNACHT et al., 2016, MCROBERTS e TOMPO, 2007, WHITE et al., 2016). Em relação a todas essas tarefas e requisitos, o sensoriamento remoto se estabelece continuamente como uma tecnologia chave (KATTENBORN et al., 2021).

Normalmente, as informações sobre as espécies presentes na floresta são obtidas por meio de inventários de campo que incluem, por exemplo, a contagem de indivíduos arbóreos (ROCHA, 2004). Essa atividade gera altos custos, muitos esforços envolvidos, tempo de serviço e equipe de campo, e algumas vezes resultam em uma baixa cobertura de amostragem e frequência. A informação obtida no inventário é essencial para o conhecimento e futuro manejo sustentável desta floresta, fornece informações valiosas sobre seus recursos florestais e auxilia a identificar áreas destinadas para conservação, manejo e desenvolvimento. Por isso, sempre houve interesse no desenvolvimento de novas técnicas para estimar parâmetros florestais de forma mais prática e econômica (SANTOS et al., 2017).

Uma forma inovadora de obter informações espaciais detalhadas sobre a ocorrência de espécies de árvores em grandes áreas é integrando imagens de sensoriamento remoto com os métodos de aprendizado de máquina (FERREIRA, 2021). As geotecnologias são um conjunto de tecnologias para coleta, processamento, análise e disponibilização de informações com referência geográfica. São compostas por soluções de *hardware*, *software* e *peopleware* que juntas constituem-se em poderosos instrumentos como suporte à tomada de decisão (ROSA, 2013). O uso de geotecnologias pode ser útil no mapeamento da Peroba-Rosa, uma vez que permite coletar, armazenar e analisar grandes quantidades de dados geográficos e espaciais de maneira eficiente.

Nesse sentido, os Veículos Aéreos Não Tripulados (VANTs) são de extrema relevância, tendo em vista sua disseminação e ampla utilização em pesquisas científicas e demais atividades comerciais em florestas. O processamento de imagens de alta resolução possibilita identificar espécies de árvores, pois permite que os indivíduos sejam identificados em nível de copa das árvores individualmente (FERREIRA, 2021).

Para isso, as redes neurais convolucionais (CNNs), que são um tipo de método de Deep Learning, foram aclamadas como uma abordagem promissora para identificar espécies

de árvores em imagens de sensoriamento remoto, especialmente em dados de alta resolução (KATTENBORN et al., 2021). As CNNs são projetadas para extrair automaticamente padrões espaciais (por exemplo, formas, bordas, textura) de imagens usando um conjunto de operações de convolução e agrupamento (ZHANG et al., 2016), aprendendo assim características específicas do objeto.

No caso das espécies arbóreas, tais características estão relacionadas principalmente à estrutura da copa: disposição de folhas e galhos na copa ou padrões de coloração causados por eventos fenológicos (FERREIRA, 2021). O delineamento individual da copa da árvore é uma tarefa desafiadora, particularmente em florestas tropicais em que as copas das árvores geralmente se sobrepõem e têm tamanhos e formas altamente variáveis (TOCHON et al., 2015; WAGNER et al., 2018; BRAGA et al., 2020).

O objetivo geral deste trabalho é desenvolver um modelo de aprendizagem de Deep Learning voltado à identificação de árvores de Peroba-Rosa situadas em um fragmento florestal localizado no Paraguai.

2. REVISÃO DE LITERATURA

2.1. Caracterização da *Aspidosperma polyneuron* Müll. Arg

Pertencente à família das Apocynaceae, a Peroba-rosa (*Aspidosperma polyneuron* Mull.Arg) é uma espécie perenifólia, com alturas médias de 15 a 25 m, DAP de 50 a 100 cm, podendo atingir 50 m de altura e 390 cm de DAP, em casos excepcionais (EMBRAPA, 2004). Um exemplar da espécie é apresentado na Figura 1.



Figura 1: Exemplar de *Aspidosperma polyneuron* Müll. Arg (Hernandarias, Paraguai). Fonte: Rogério Santos, 2021.

Ela apresenta um tronco cilíndrico, reto ou levemente tortuoso, com fuste retilíneo, que pode medir de 12 a 20 m e em casos raros, 30 m; A sua ramificação é cimosa, ocorre só na parte superior do tronco, com a sua trifurcação, formando uma copa alta corimbiforme (EMBRAPA, 2004).

A Peroba-rosa possui uma casca grossa, podendo ter uma espessura de até 50 mm, com a parte externa com a coloração variando de cinzenta a castanho-grisácea, áspera e

fissurada longitudinalmente. A sua casca interna tem uma coloração rósea muito intensa e a sua parte interna, onde encontra-se o câmbio, é amarelada (EMBRAPA, 2004).

Possui folhas simples, alternadas, de formas variáveis, oblongas a obovada-elípticas, em alguns casos lustrosas na face superior, com o ápice arredondado e margem inteira. A sua folha pode atingir até 8 cm de comprimento e 3 cm de largura (EMBRAPA, 2004).

Suas flores são tubulares branco-amareladas a creme, numerosas, pequenas, curtas paniculadas terminais de 1 a 4 cm de comprimento. Os seus frutos possuem folículo deiscente, elipsoide, séssil, comumente achatado, semilenhoso, com dimensões de 2,5 a 6 cm de comprimento por 1 a 2 cm de largura, crista mais ou menos proeminente, coloração pardo-escura e com 2 a 5 sementes por fruto, com a sua frutificação ocorrendo a cada 2 a 4 anos (EMBRAPA, 2004).

A Peroba-rosa corre desde o nordeste da Argentina, norte da Colômbia, norte e leste do Paraguai, noroeste do Peru, norte da Venezuela e no Brasil (MARTINEZ-CROVETTO, 1963. LOPEZ ET ALL., 1987. FINOL URDANETA & MELCHIOR, 1970. APUD EMBRAPA, 2004).

A espécie é secundária tardia ou clímax tolerante à sombra, possuindo uma regeneração sob o dossel, ao qual tem ocorrência em todos os extratos florestais, elas se desenvolvem em grupamentos denominados “perobais” (FACCHINI, 1970. APUD EMBRAPA, 2004).

Outra característica silvicultural importante a ser destacada sobre essa espécie é o seu hábito de crescimento característico que facilita a identificação em imagem. Seu crescimento em altura dá-se sempre através de três brotos, sendo que dois são suprimidos e apenas um deles prevalece; este emite também três brotos, e até nas plantas adultas os galhos terminam em três pequenos ramos (EMBRAPA, 2004).

Figura 1: Exemplar de *Aspidosperma polyneuron* Müll. Arg (Hernand

2.2. Geotecnologias

As geotecnologias referentes ao Sensoriamento Remoto e aos Sistemas de Informações Geográficas (SIG) estão cada vez mais interligadas. Suas aplicações nos diferentes campos do conhecimento têm aumentado (FLORENZANO, 2005).

Segundo Rosa e Roberto (2013), geotecnologias são um conjunto de tecnologias para coleta, processamento, análise e disponibilização de informações com referência geográfica. . Dentre as geotecnologias podemos destacar: a cartografia digital, o sensoriamento remoto, o sistema de posicionamento global, o sistema de informação geográfica.

No geral, o uso de geotecnologias nos ajuda a entender e gerenciar melhor a Terra e seus recursos, além de proteger o meio ambiente. Em específico, as geotecnologias podem ser uma ferramenta valiosa para ajudar a identificar e classificar espécies de plantas com precisão, o que é importante para uma ampla gama de aplicações, incluindo conservação da biodiversidade, gerenciamento de recursos e pesquisa ecológica.

2.2.1. Sensoriamento Remoto

O sensoriamento remoto pode ser definido, de uma maneira ampla, como sendo a forma de obter informações de um objeto ou alvo, sem que haja contato físico com o mesmo (ROSA, 2013). Esta tecnologia revolucionou a forma como estudamos e monitoramos a Terra.

A informação obtida é apresentada em forma de imagem, e a compreensão das imagens obtidas por sensoriamento remoto inclui o entendimento de que objetos na superfície

da Terra, como vegetação, água e solo, refletem, absorvem e transmitem determinados comprimentos de onda da radiação eletromagnética em proporções que variam de acordo com suas características biofísicas e/ou propriedades químicas. Portanto, a interpretação das imagens é baseada em elementos básicos, extraindo informações de objetos, regiões ou fenômenos, considerando cor/tom, textura, tamanho, forma, sombreamento, altura padrão e posição (CALDAS, 2006).

Um dos principais benefícios do sensoriamento remoto para o estudo da floresta é permitir que cientistas colem uma grande quantidade de dados de forma rápida e eficiente. Os métodos tradicionais de coleta de dados sobre florestas, como a realização de inventários florestais, podem ser demorados e trabalhosos. Por outro lado, o sensoriamento remoto permite cobrir vastas áreas de terra em um período de tempo relativamente curto, fornecendo uma imagem mais abrangente e precisa do estado de uma determinada floresta.

2.2.2. Geoprocessamento e os Sistemas de Informação Geográfica

Segundo o Instituto Nacional de Pesquisas Espaciais (INPE), o geoprocessamento é um conjunto de estudos e técnicas destinados a coletar, tratar e processar dados de referência espaciais. Essas atividades são realizadas por sistemas específicos comumente chamados de sistemas de informação geográfica (SIG).

Os SIG permitem realizar análises complexas, ao integrar dados de diversas fontes e ao criar bancos de dados georreferenciados. Tornam ainda possível automatizar a produção de documentos cartográficos (CÂMARA et al., 2003). O software GIS inclui uma variedade de ferramentas e funções que podem ser usadas para analisar e manipular dados, incluindo ferramentas para criar mapas, analisar padrões espaciais e modelar processos geográficos.

O geoprocessamento é usado em vários campos, incluindo ciência ambiental, planejamento urbano, gerenciamento de recursos naturais e transporte. É uma ferramenta importante para entender e gerenciar a Terra e seus recursos de forma rápida e precisa, sempre facilitando os processos de tomadas de decisões com base em dados geográficos.

2.3. Veículo Aéreo Não Tripulado

O VANT (Veículo Aéreo Não Tripulado) é um exemplo de ferramenta tecnológica que possui ampla aplicação no setor florestal (PONTES e FREITAS, 2015), que apresenta possibilidade de aplicação na identificação individual de espécies de árvores (FERREIRA, 2020). Como ferramenta estratégica na gestão de áreas florestais, os VANTs podem auxiliar na localização de árvores derrubadas, no planejamento de corte e otimização do processo de extração da madeira (LUNDQVIST, 2014).

O monitoramento de sobrevivência realizado pelo VANT permite a realização do censo, que consegue processar toda a área de plantio com menor tempo, podendo propiciar maior exatidão nos levantamentos (GALIZIA et al., 2016). Uma das principais vantagens do uso de VANT para identificação florestal é a capacidade de cobrir grandes áreas de forma rápida e fácil. Os métodos tradicionais de levantamento florestal, inventário, geralmente envolvem o envio de equipes de pesquisadores in loco para coletar dados, o que pode ser demorado e trabalhoso. Com um VANT, é possível cobrir vastas extensões de floresta em uma fração do tempo, permitindo que os pesquisadores colem mais dados em menos tempo.

As imagens aéreas captadas pelo VANT, têm o potencial de discriminar espécies que compõem o dossel em ambientes tropicais (Peck et al., 2012; Otero et al., 2018). Essas imagens são normalmente adquiridas com apenas três canais (RGB), fornecendo assim informações espectrais limitadas. No entanto, eles geralmente apresentam resoluções hiperespectrais (tamanho do pixel de <10 cm), o que permite uma visualização clara e extração

de características estruturais (forma, tamanho e textura) de objetos no solo (FERREIRA, 2020).

Quando a informação espectral é pouco disponível, como é o caso das imagens RGB, a quantificação da textura pode melhorar a precisão da classificação de espécies arbóreas (FERREIRA et al., 2019). O que ocorre no caso da Peroba-Rosa, pois suas copas individuais têm características morfológicas distintas, que podem produzir padrões de textura peculiares que facilitam o seu reconhecimento no aprendizado profundo.

No geral, o uso de VANTs para identificação florestal oferece inúmeros benefícios, incluindo a capacidade de cobrir grandes áreas rapidamente, acessar áreas de difícil acesso, monitorar as árvores individualmente e reduzir o impacto ambiental dos esforços de pesquisa.

2.4. *Deep Learning* e Redes Neurais

O aprendizado profundo é um subcampo do aprendizado de máquina (Figura 2) inspirado na estrutura e função do cérebro, especificamente nas redes neurais que compõem o cérebro. Envolve o uso de algoritmos chamados de redes neurais, que são compostas por camadas de “neurônios” interconectados que processam e transmitem informações (ESRI, 2021).

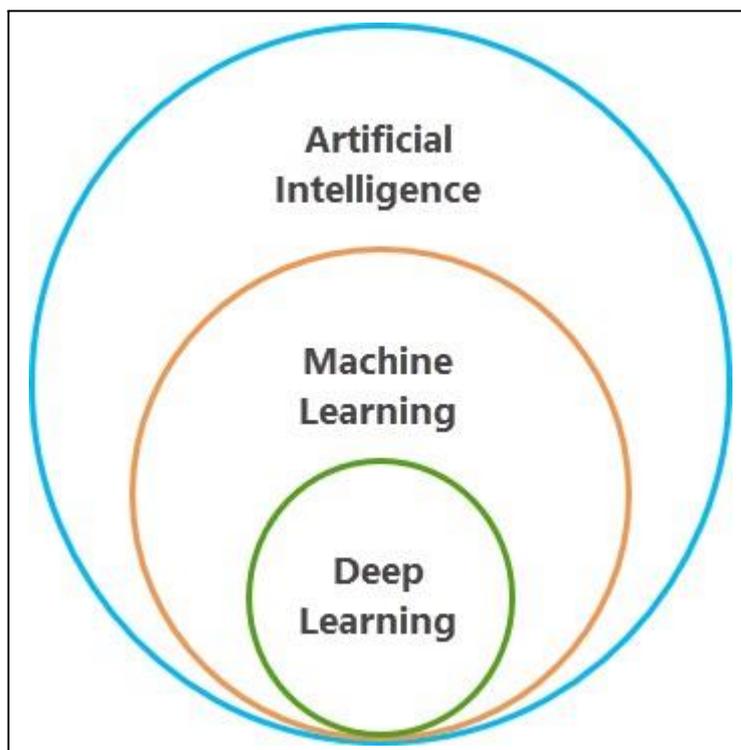


Figura 2: Campos e Subcampos da Inteligência Artificial. Fonte: Esri, 2023.

O Deep Learning baseia-se em Rede Neurais Profundas (*Deep Neural Networks*), as quais conseguem trabalhar com centenas de camadas hierárquicas, possibilitando análises mais complexas com múltiplos níveis de abstração (MATLAB, 2017). Nessas redes neurais profundas, cada camada treina um conjunto de características que são geradas a partir das camadas antecessoras. E quanto mais características são processadas, mais os nós conseguem reconhecer características ainda mais complexas (JUNIOR, 2022). Todo esse conjunto de camadas e nós que são interligados e processados em uma rede neural profunda é conhecido como hierarquia de características. Essa hierarquia de características, de complexidade e

abstrações incrementais, que permite redes de Deep Learning sejam capazes de processar conjuntos de dados de alta dimensão com bilhões de parâmetros (PATHMIND, 2019).

As redes neurais são treinadas para executar uma tarefa específica ao receber grandes quantidades de dados e usar esses dados para ajustar a intensidade das conexões entre os neurônios, em um processo conhecido como "treinamento". Entretanto, apesar dessas redes serem capazes de identificar estruturas em dados não-estruturados e não-categorizados, como fotos, mídia crua, texto, vídeo e gravações de áudios (PATHMIND, 2019), estudos indicam que para obtermos um bom treinamento nessas redes, precisa-se de aproximadamente 1000 imagens para cada classe a ser classificada (WARDEN, 2017). Porém, usando redes neurais convolucionais, conseguimos obter bons resultados utilizando poucos dados para treinamento (SHU, 2019). Depois de treinada, uma rede neural pode fazer previsões ou realizar ações com base em novos dados de entrada.

As Redes Neurais Convolucionais (CNN - *Convolutional Neural Networks*) são redes neurais utilizadas para classificação de imagens e detecção de objetos. Essa rede neural artificial recebe uma imagem e subsequentemente processa a mesma em camadas internas, nas quais consegue-se identificar e diferenciar objetos dentro da imagem (BORGES, 2021).

As CNNs são capazes de extrair características precisas das imagens de maneira automática. Em uma camada convolucional, cada neurônio artificial é organizado espacialmente, onde cada entrada está sempre sujeita a uma operação de convolução, onde uma operação matemática de matrizes é aplicada. Essas operações de convolução podem ser entendidas como filtros no sinal de entrada, e com isso, ao invés das CNNs utilizarem filtros prontos, utilizam filtros que foram personalizados durante o processo de treinamento (BAULÉ et al., 2020).

O aprendizado profundo tem sido usado para obter desempenho de ponta em uma ampla gama de tarefas, incluindo a identificação de árvores.

3. MATERIAL E MÉTODOS

3.1. Caracterização da Área de Estudo

O lugar de estudo encontra-se no distrito de Hernandarias - Paraguai (Figura 3), pertencente à empresa J&M ISMAR S.A. A instituição possui uma área nativa, situada em uma de suas fazendas, Aserradero San Miguel Arcángel, localizada às margens da Supercarretera Itaipu KM 23, Yvaga Rape, 25°16'44.7" Sul 54°45'26.0" Oeste.

A propriedade possui 1.000 ha, dos quais, aproximadamente 320 ha deles é floresta nativa, com uma topografia suave ondulada, predominando na região Latossolos (LÓPEZ et al., 1998 apud MORENO, 2019), cuja vegetação predominante na região é a Floresta Atlântica do Alto Paraná (ÁVILA-TORRES et al., 2021).

O clima da região é classificado segundo Köppen-Geiger como Cfa, ou seja, clima subtropical, com verão quente. As temperaturas são superiores a 22°C no verão e com mais de 30 mm de chuva no mês mais seco; a temperatura anual média de 23°C, precipitação anual média de 1.990 mm e altitude de 253 m (DIRECCIÓN GENERAL DE ESTADÍSTICA ENCUESTAS Y CÉNSOS, 2022).

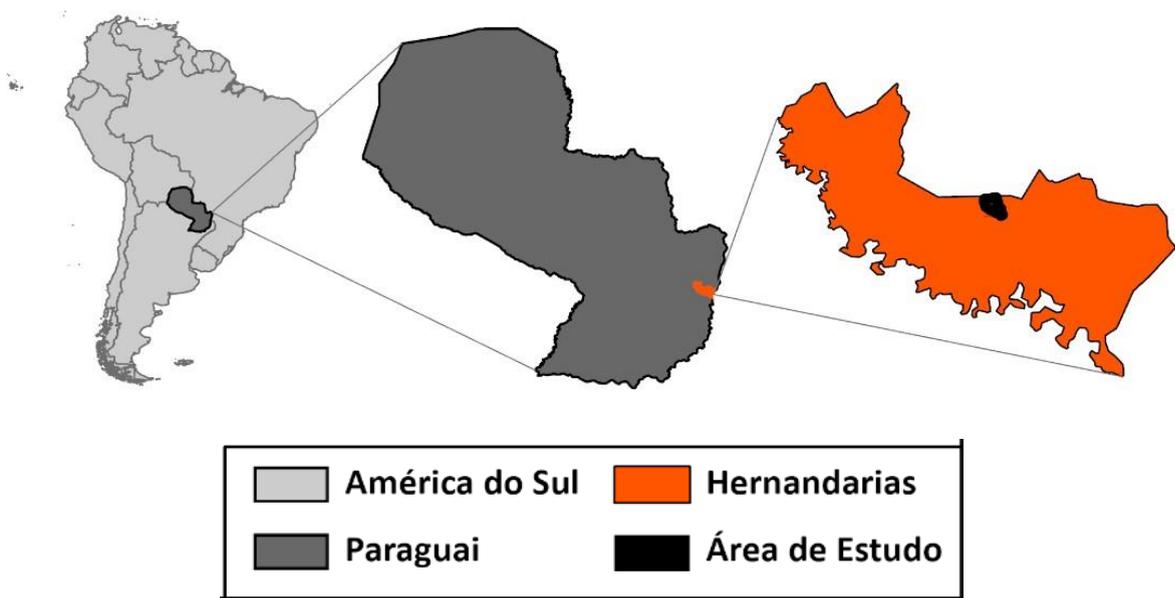
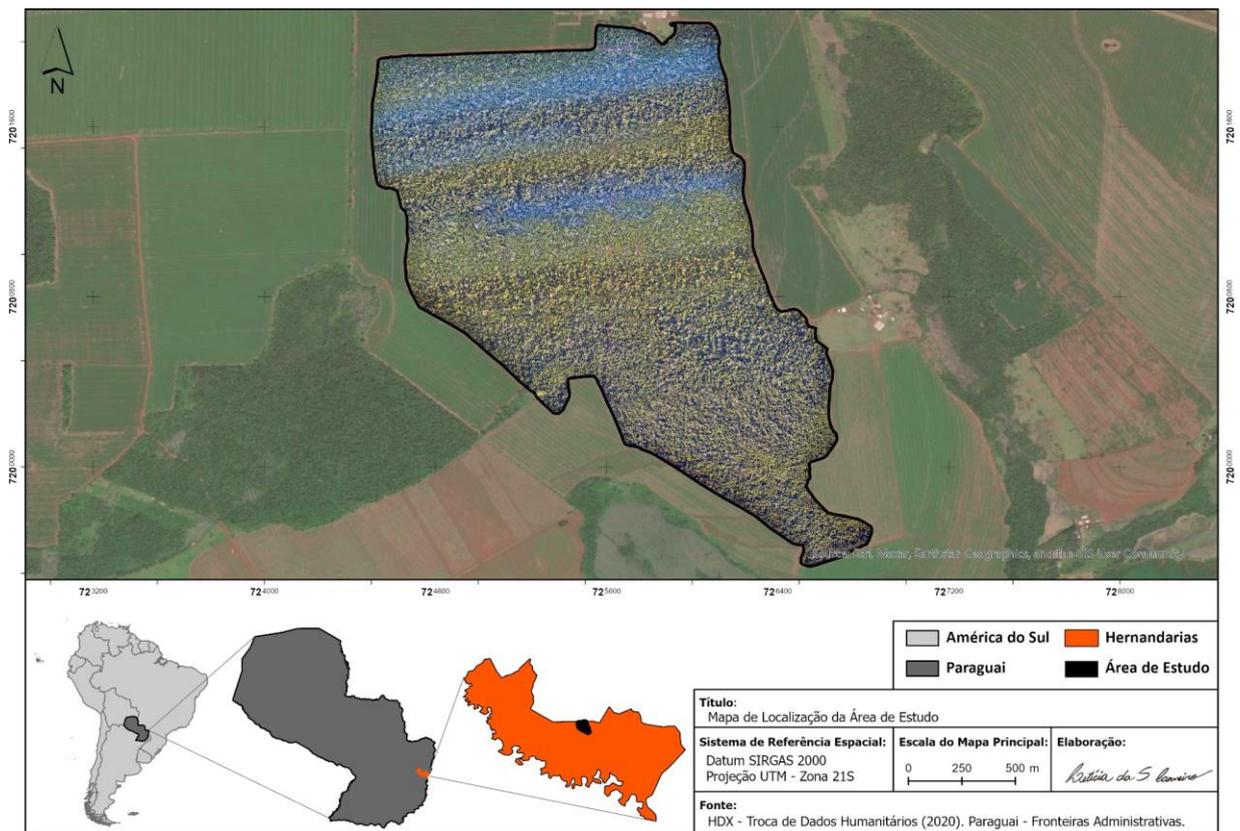


Figura 3: a) Mapa de Localização b) Zoom Mapa de Localização da Área de Estudo. Fonte: Autor.

3.2. Base de Dados: Inventário Florestal

Foi realizado um inventário florestal na área de estudo por uma equipe composta por 23 participantes. Dentre esses, 16 eram estudantes de engenharia florestal da UFRRJ e da Universidade Federal do Paraná (UFPR), 1 era engenheira florestal formada pela UFPR e a equipe foi orientada pelo Prof. Dr. Renato Cesar Gonçalves Robert, também da UFPR. Além disso, todo o caminhamento na área foi orientado por 5 mateiros de origem local, indígenas que possuíam o conhecimento empírico, experiência e vivência de demais trabalhos realizados na floresta nativa local.

O inventário foi realizado entre junho e setembro de 2021, totalizando 3 meses de atividade. Inicialmente, a área foi dividida em 5 unidades de pesquisa (UP), que são as unidades de trabalho do inventário (Figura 4).

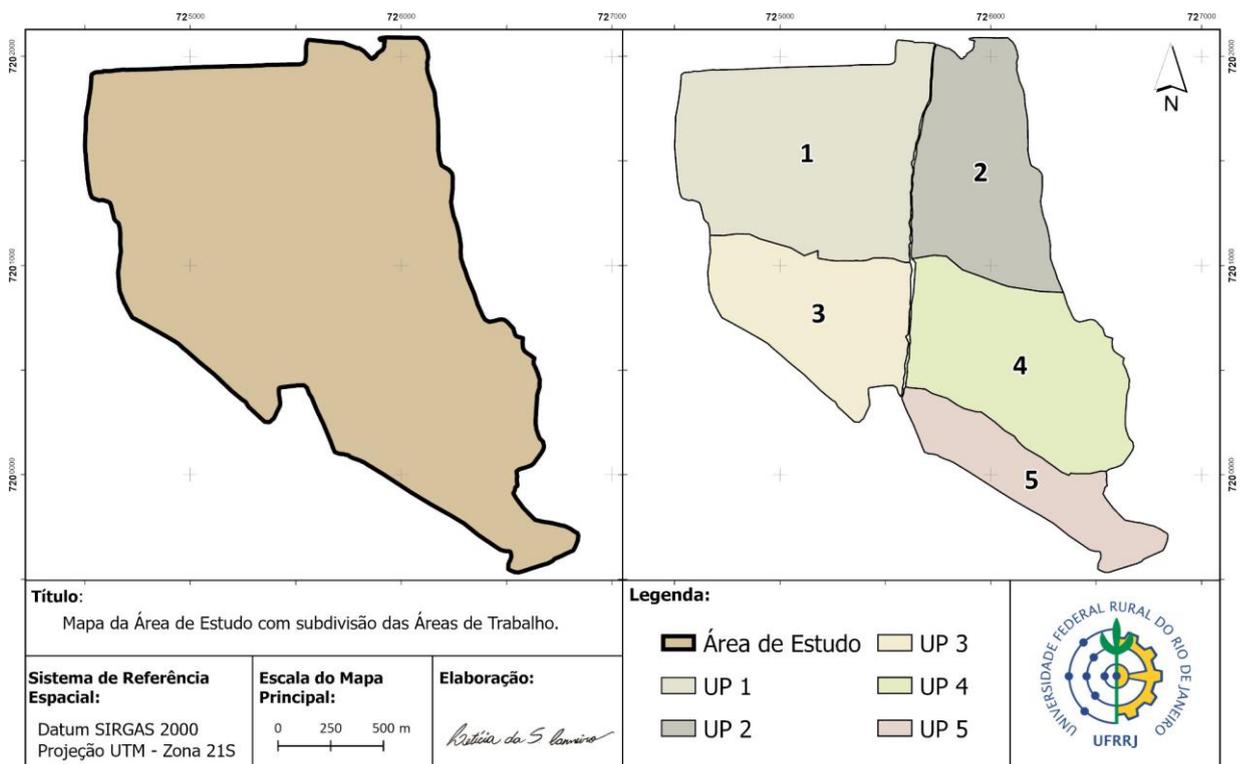


Figura 4: Mapa da Área de Estudo com subdivisão das Unidades de Pesquisa. Fonte: Autor.

As unidades possuem tamanhos distintos (Tabela 1), pois sua delimitação foi feita de acordo com estradas já presentes na área de estudo. O censo foi realizado em todos os indivíduos com o DAP > 30 cm, porém para este trabalho serão destacadas as informações referentes a Peroba-Rosa.

Tabela 1. Descrição dos dados obtidos no Inventário Florestal.

UP	Área (ha)	Quantidade Árvores Nativas	Quantidade de Peroba-Rosa
1	98	23287	696
2	60	15402	318
3	54	13420	156
4	72	18610	145
5	34	9401	0

Os indivíduos de Peroba-Rosa identificados no inventário florestal estão evidenciados na Figura 5.

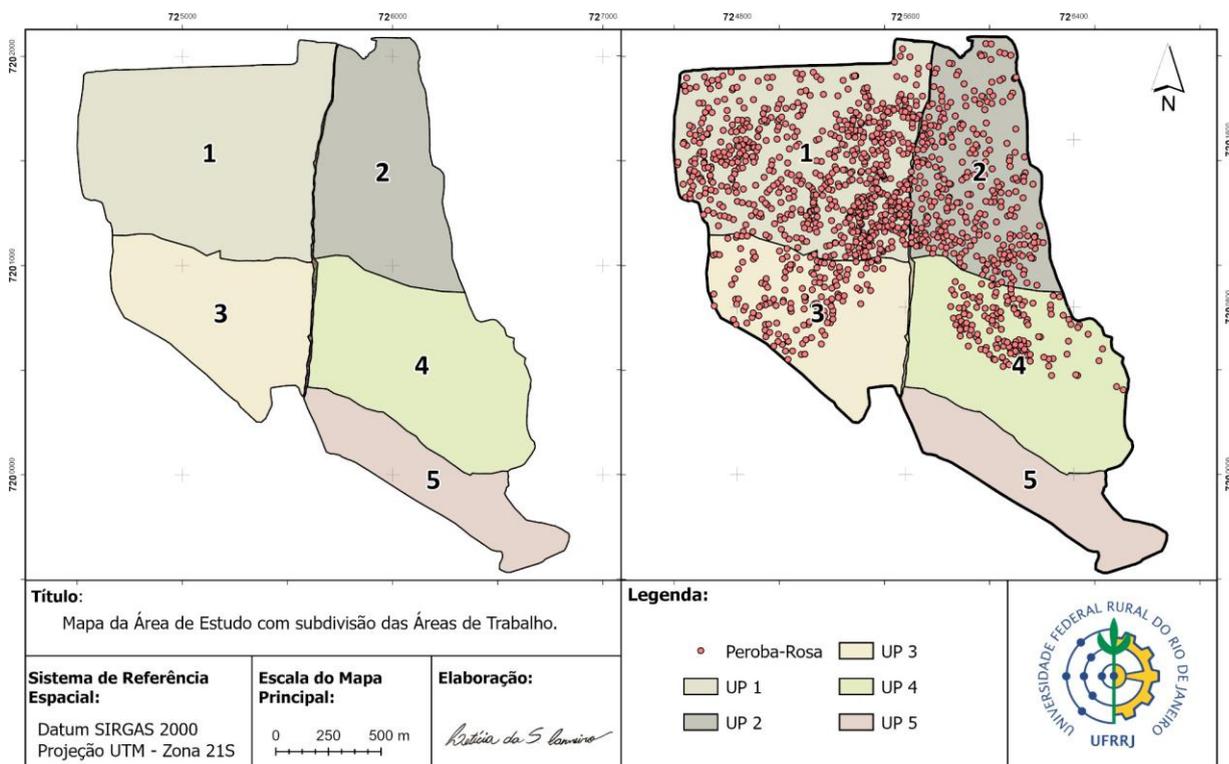


Figura 5: Mapa da Distribuição das Perobas-Rosa em cada Unidade de Pesquisa. Fonte: Autor.

Para realização inventário, elaborou-se uma planilha com as seguintes informações: Código da placa; Código do GPS; Circunferência na altura do peito; Espécie; Altura comercial (Hc); Altura total (Ht); Direção de queda (DQ); Qualidade do fuste; Observação. Na coleta destas informações utilizou as seguintes ferramentas: GPS; Avenza (aplicativo de celular); fita métrica; placas de identificação; e, bússola. Todos os dados do foram processados no QGIS, Excel e Power BI.

Este inventário florestal foi utilizado como fonte de dados para comparações de resultados, estudos e inovação no campo da engenharia florestal.

3.3. Coleta das Amostras

A base de dados usada para a coleta de amostras foi o ortomosaico da floresta (Figura 9), que como descrito na Figura 5 foi dividido em 5 áreas de pesquisa. Dessas 5 áreas, 2 delas tiveram o seu processamento de imagens comprometido devido a diferença de dias de voo. Essas duas áreas, UP 1 e UP 2, apresentam faixas de cores diferentes, como pode ser visualizado na Figura 6. Por possuir qualidade de imagem inferior às demais, as informações referentes a UP 1 e UP 2 não foram consideradas para construção do modelo.

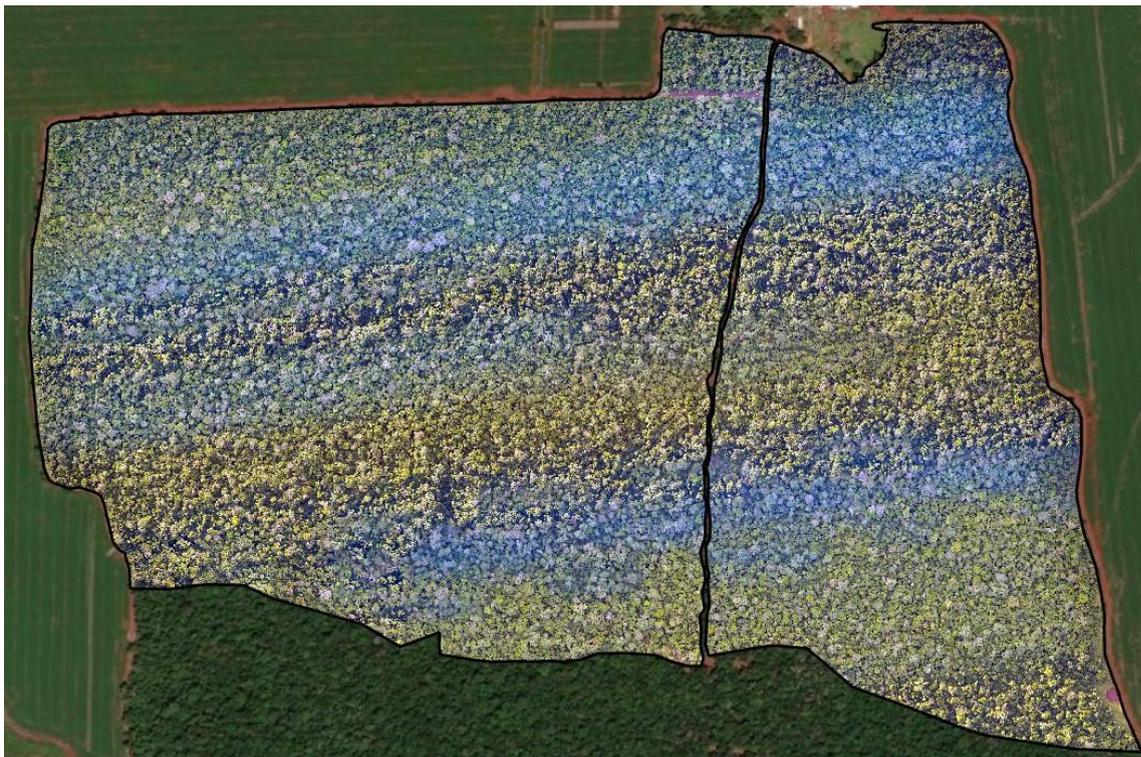


Figura 6: Destaque da UP 1 e UP 2. Fonte: Autor.

As imagens das demais áreas de pesquisa (UP 3, UP 4 e UP 5) estão em condição ideal para a coleta de amostras, como pode ser visualizado na Figura 7.



Figura 7: Destaque da UP 3, UP 4 e UP5. Fonte: Autor.

No entanto, no inventário florestal realizado na área de estudo não foi identificada a presença de indivíduos da Peroba-Rosa na UP 5, por isso não foram coletadas amostras nesta região. Portanto, as informações utilizadas para a coleta de amostras de Peroba-Rosa foram retiradas da UP 3 e UP 4.

. A amostra representa a base de dados que foi usada para ensinar a máquina a tomar decisões e realizar tarefas. Foi utilizada a metodologia da validação cruzada, que consiste em dividir o conjunto de dados de treinamento em subconjuntos, que no caso deste estudo são as Unidades de Pesquisa, e treinar o modelo com uma parte dos dados e testá-lo com a outra parte. Isso permite avaliar a capacidade do modelo de generalizar para novos dados.

O modelo foi treinado com o conjunto de dados da UP3 e UP4 que possuem um total de 302 indivíduos de Peroba-Rosa. Dessas foram selecionados 100 indivíduos como amostra para treinamento do modelo. Logo, aproximadamente, 33% das amostras foram usadas como conjunto de treinamento e 67% foi destinado para a validação do modelo.

3.4. ArcGIS Pro

Todas as etapas do presente trabalho foram obtidas através do uso do *software* ArcGIS Pro. O ArcGIS Pro fornece uma coleção de ferramentas eficientes para gerenciar e analisar grandes coleções de imagens, como as obtidas por VANTs (ESRI, 2023). Dentro do software foi utilizada a extensão ArcGIS *Image Analyst* que forneceu ferramentas de geoprocessamento para analisar os dados das imagens.

Os recursos do Image Analyst são agrupados em categorias (conjuntos de ferramentas) de funcionalidades relacionadas. O conjunto de ferramentas utilizadas foi o chamado Deep Learning. Este consistiu na execução de um modelo de aprendizado profundo treinado em um raster de entrada e uma classe de recurso (de Peroba nesse caso) opcional para produzir uma classe de recurso na qual cada objeto de entrada tem uma classe atribuída de categoria (ESRI, 2023).

3.5. Desenvolvimento do Modelo

Para desenvolvimento do modelo são adotadas técnicas de Deep Learning para automatizar a identificação das árvores de Peroba-Rosa. O modelo desenvolvido é executado no software ArcGIS Pro e segue a metodologia descrita na Figura 8.



Figura 8: Passo a passo para desenvolvimento de um modelo em Deep Learning no software ArcGIS Pro. Fonte: Esri (2021).

Para desenvolver uma ferramenta de identificação de árvores em *Python*, foi utilizado o *framework* de aprendizado de máquina em *Deep Learning* disponível na biblioteca da Esri (ESRI, 2023) e algumas técnicas de pré-processamento de dados.

O primeiro passo foi a coleta de imagens de VANT das árvores localizadas na área de estudo especificada. O voo de VANT foi realizado ao longo de 5 dias de voo, em cada etapa as imagens foram analisadas para certificar a boa qualidade e para garantir visibilidade satisfatória das árvores. O VANT utilizado foi o Phantom 4, as fotos foram processadas utilizando o software Agisoft Metashape e a resolução obtida no ortomosaico (Figura 9) foi de 5 cm/pixel.

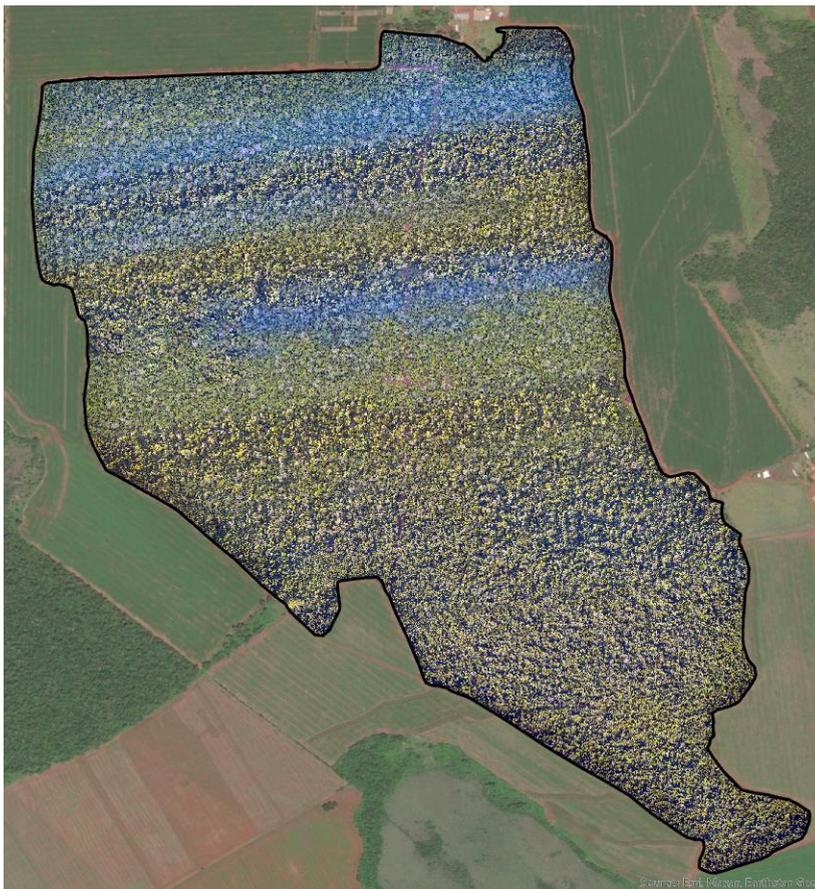


Figura 9: Ortomosaico da Área de Estudo. Fonte: Autor.

A seguir foram utilizadas técnicas de processamento de imagem para equalizar a qualidade das imagens a fim de extrair características das árvores. No ArcGIS Pro, a ferramenta "*Stretch Type*" foi usada para ajustar a faixa de tonalidade ideal da imagem raster. O tipo de ajuste escolhido foi o "*Percent Clip*", que é usado para definir os limites da faixa tonal de uma imagem com base em uma porcentagem dos valores extremos de pixel (ESRI, 2021). Por exemplo, se definir a porcentagem de recorte como 1%, os valores de pixel de 1% mais baixo e mais alto serão descartados e a faixa tonal será ajustada para que o 1% mais baixo e o 1% mais alto dos valores de pixel sejam os novos valores mínimo e máximo. Isso é útil para remover valores "*outliers*" de uma imagem e melhorar a exibição de detalhes em áreas de interesse, que no caso deste estudo são as árvores de Peroba-Rosa.

Depois de pré-processar a imagem, foram usadas técnicas de aprendizado profundo para extrair características das imagens de maneira automática. Para isso, foi utilizada as redes

neurais convolucionais que é muito eficaz para processar imagens e é usada para extrair características precisas das árvores.

Para iniciar a criação do modelo foi criado um conjunto de treinamento a partir dos dados obtidos do inventário florestal, com a localização dos indivíduos do inventário, com destaque para a Peroba-Rosa. Esse treinamento foi baseado em uma amostragem aleatória, dividida em duas classes, Peroba-Rosa e Vegetação Nativa (colocar imagem da amostra de treinamento), esse conjunto de treinamento especificou as características da espécie de interesse. A exportação dos dados para treinamento foi feito usando a ferramenta de geoprocessamento do ArcGIS Pro chamada “*Export Training Data For Deep Learning*”.

O modelo escolhido foi o RCNN mask, que foi treinado utilizando a ferramenta de geoprocessamento do ArcGIS Pro “*Train Deep Learning Model*”. Nessa fase, os dados de treinamento são inseridos no modelo, que irá aprender a identificar as árvores com base nas características fornecidas.

O modelo criado foi testado em uma das áreas de produção que compõem o ortomosaico original . Nesta fase foi usada a ferramenta de geoprocessamento do ArcGIS Pro “*Detect Objects Using Deep Learning*”. O local de teste (UP 4) é composto de dados que o modelo ainda não viu, essa etapa permite a avaliação da precisão do modelo na identificação das árvores.

Durante o processo o modelo pode ser ajustado, se necessário, com base nos resultados dos testes. Neste caso, podem ser adicionados mais dados de treinamento, os parâmetros do algoritmo podem ser ajustados ou ainda pode ser feita a escolha de um algoritmo diferente. Neste estudo foi utilizado somente um tipo de algoritmo de classificação.

3.6. Verificação do Modelo

Para verificação do modelo foi usada a ferramenta “*Compute Accuracy for Object Detection*” do software ArcGIS Pro.

A ferramenta calculou a precisão do modelo de deep learning comparando os objetos por ele detectados com os dados de referência obtidos no inventário florestal. A precisão do modelo foi avaliada usando as seguintes métricas de precisão (ESRI, 2023):

- Precisão: A proporção do número de verdadeiros positivos para o número total de previsões;
- Recall: A proporção do número de verdadeiros positivos para o número total de previsões positivas;
- Pontuação F1: A média ponderada da precisão é novamente tomada. Os valores variam de 0 a 1 em que 1 significa maior precisão;
- AP: A métrica de Precisão Média (AP), que é a precisão média em todos os valores de chamada entre 0 e 1 em um determinado valor de Interseção sobre União (IoU);
- Verdadeiro Positivos: O número de verdadeiros positivos gerados pelo modelo;
- Falso Positivos: O número de falsos positivos gerados pelo modelo;
- Falso Negativos: O número de falsos negativos gerados pelo modelo.

4. RESULTADOS

A execução completa de todas as etapas descritas durou um total de 48 horas, 21 minutos e 4 segundos.

4.1. Exportação dos Dados de Treinamento

Nessa primeira etapa do processamento tivemos como resultado os chips de imagem contendo a amostra de classe da imagem de origem, as Perobas. Os dados de amostra de treinamento de classificação foram usados como uma camada de base de construção, para gerar os produtos esperados. Os dados vetoriais da amostra de treinamento foram convertidos em conjuntos de dados de treinamento de aprendizado profundo usando uma parte da imagem da área de estudo, a UP 3 e UP 4.

O resultado dessa etapa foi uma pasta de chips de imagem (Figura 10). É importante esclarecer que os chips de imagem são pequenos pedaços ou fragmentos de uma imagem que são gerados automaticamente a partir de uma imagem de alta resolução.

Nome	Data de modificação	Tipo	Tamanho
images	12/02/2023 17:57	Pasta de arquivos	
labels	12/02/2023 17:56	Pasta de arquivos	
esri_accumulated_stats.json	12/11/2022 10:46	Arquivo JSON	4 KB
esri_model_definition.emd	12/11/2022 10:46	Arquivo EMD	4 KB
map	12/11/2022 10:46	Documento de Texto	51 KB
stats	12/11/2022 10:46	Documento de Texto	1 KB

Figura 10: Arquivos de saída após aplicação da ferramenta *Export Training Data For Deep Learning*. Fonte: Autor.

Na amostra de treinamento previamente preparada foi definido o campo da classe de Peroba-Rosa como “10”. Foram coletadas 100 amostras dessa classe e quando processadas na ferramenta *Export Training Data For Deep Learning*, alguns parâmetros foram adicionados para produzir o resultado de interesse.

A imagem de fonte de entrada foram as unidades que continham as amostras de treinamento. Após adicionar as imagens da UP 3 e UP4, foi escolhida uma nova pasta de saída dos arquivos denominada “Treino”. Foi definida a classe de interesse para análise e a partir desse ponto demais parâmetros foram selecionados.

Alguns parâmetros foram modificados, como o *Rotation Angle*, este é o ângulo de rotação que será usado para gerar chips de imagem adicionais. Foi definido que um chip de imagem será gerado com um ângulo de rotação de 30°. As mesmas amostras de treinamento foram capturadas em vários ângulos em vários chips de imagem para aumento de dados, esse fator permitiu que o número de amostras fosse extrapolado de 100 para 1162 (Figura 11).

```
images = 956 *4*256*256
Class feature statistics:
features = 1162
features per image = [min = 1, mean = 1,22, max = 4]
classes = 1
cls name          cls value  images  features  min size  mean size  max size
10                10        956    1162     0,00     31,59     165,14
```

Figura 11: Resultado do arquivo “stats” após aplicação da ferramenta *Export Training Data For Deep Learning*. Fonte: Autor.

Apesar de ser uma quantidade expressiva de dados, o ideal é que tivéssemos 10 vezes mais amostras para treinamento satisfatório do modelo. A quantidade de amostra foi limitada pelos fatores especificados no tópico 3.3 Coleta de Amostras do presente trabalho.

4.2. Treinamento do Modelo

A ferramenta usada nessa etapa foi a Train Deep Learning Model, esta treinou o modelo de aprendizado profundo usando as estruturas de saída da etapa anterior, que incluíam as imagens e as pastas de rótulos geradas a partir da ferramenta Export Training Data For Deep Learning, esses foram os dados de entrada. Assim como na etapa anterior, foi criada uma nova pasta denominada “Modelo” para a saída dos resultados (Figura 12).

Nome	Data de modificação	Tipo	Tamanho
ModelCharacteristics	12/02/2023 19:46	Pasta de arquivos	
model_metrics	22/01/2023 17:34	Chrome HTML Document	1.796 KB
modelo teste.dlpc	22/01/2023 17:34	Arquivo DLPK	162.568 KB
modelo teste.emd	22/01/2023 17:33	Arquivo EMD	4 KB
modelo teste.pth	22/01/2023 17:32	Arquivo PTH	172.045 KB

Figura 12: Arquivos de saída após aplicação da ferramenta *Train Deep Learning Model*. Fonte: Autor.

O principal parâmetro modificado nesta etapa foi o “*Max Epochs*”, esse termo se refere a uma iteração completa do treinamento de um modelo em todos os dados de treinamento. Em outras palavras, uma época é a quantidade de vezes que o modelo é treinado com o conjunto de dados completo. Com esse parâmetro definimos o número máximo de épocas para as quais o modelo será treinado. Uma época máxima de um significa que o conjunto de dados será transmitido para frente e para trás através da rede neural uma vez. Segundo Esri (2023), o valor padrão é 20, porém devido às limitações da máquina foi adotado o valor de 10, este foi o máximo de interações que o computador foi capaz de executar.

Como resultado desta etapa temos os “*Model Metrics*”, que são uma medida de precisão e desempenho do modelo, o treinamento do apresentou precisão de 66% (Anexo 1), essas métricas ajudaram a avaliar o quão bem o modelo previu ou classificou os dados.

4.3. Detecção de Objetos usando Deep Learning

Esta ferramenta executa o modelo de aprendizado profundo treinado em uma imagem de entrada (UP 4) para produzir uma classe de recursos contendo os objetos que encontram

Perobas, veja na Figura 13.

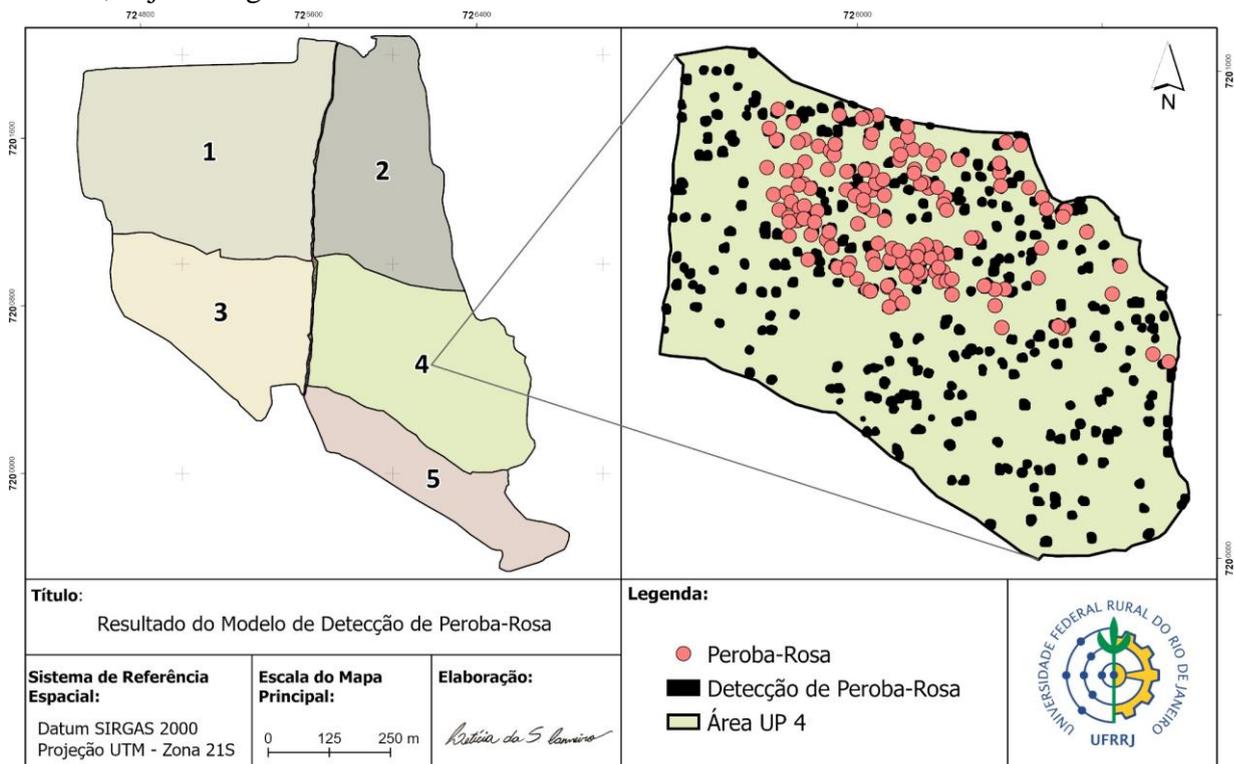


Figura 13: Resultado da Detecção de Peroba-Rosa. Fonte: Autor.

O modelo desenvolvido identificou 470 indivíduos de Peroba-Rosa na UP 4. Dos resultados gerados temos 103 indivíduos que se enquadram como verdadeiros positivos, de fato são as Perobas, 336 são falsos positivos, são outras espécies presentes na área que foram confundidas como Perobas pelo modelo e 31 são falsos negativos, que foram as Perobas que o modelo não conseguiu identificar. Sendo que no inventário usado como fonte de dados foram identificados 145 indivíduos de Peroba-Rosa na UP 4.

O modelo desenvolvido teve uma precisão de 23%, porém mesmo que a precisão do modelo tenha sido baixa, ele foi capaz de identificar os indivíduos de Peroba-Rosa que foram amostrados no Inventário Florestal (Figura 14). O modelo foi capaz de identificar 103 das 145 Perobas presentes na UP 4, ao considerar isso temos 71% de acurácia do usuário (esse termo também poderia ser explicado na revisão).

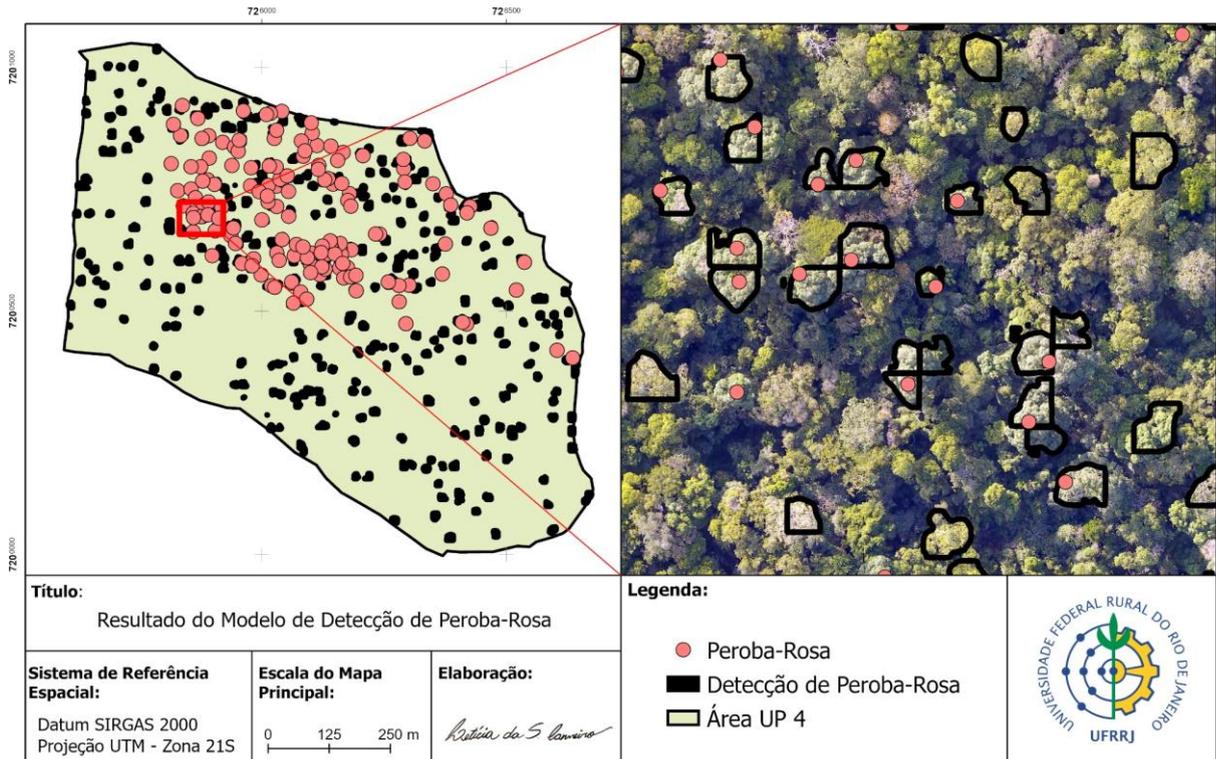


Figura 14: Aproximação do Resultado da Detecção de Peroba-Rosa. Fonte: Autor.

O desenvolvimento do modelo teve duas principais limitações, a primeira foi a baixa quantidade de amostras, o que diminuiu a capacidade de treinamento e a outra foi a falta de um computador de alta performance, visto que o uso do ArcGIS Pro e da biblioteca de Deep Learning exige uma máquina de grande capacidade de processamento.

4.4. Verificação da Acurácia da Detecção de Objetos usando Deep Learning

A precisão do modelo foi estimada ao avaliar a capacidade de identificação de árvores de Peroba-rosa em imagens do conjunto de teste. Para isso, foi usada a ferramenta Detectar Objetos. Por meio dessa análise foi verificada a precisão de 0,23, recall de 0,79, F1 de 0,36 e AP de 0,27. Além disso, os valores de Verdadeiros Positivos que foram de 103, Falsos Positivos que foram 336 e Falsos Negativos que foram de 31 (Figura 15).

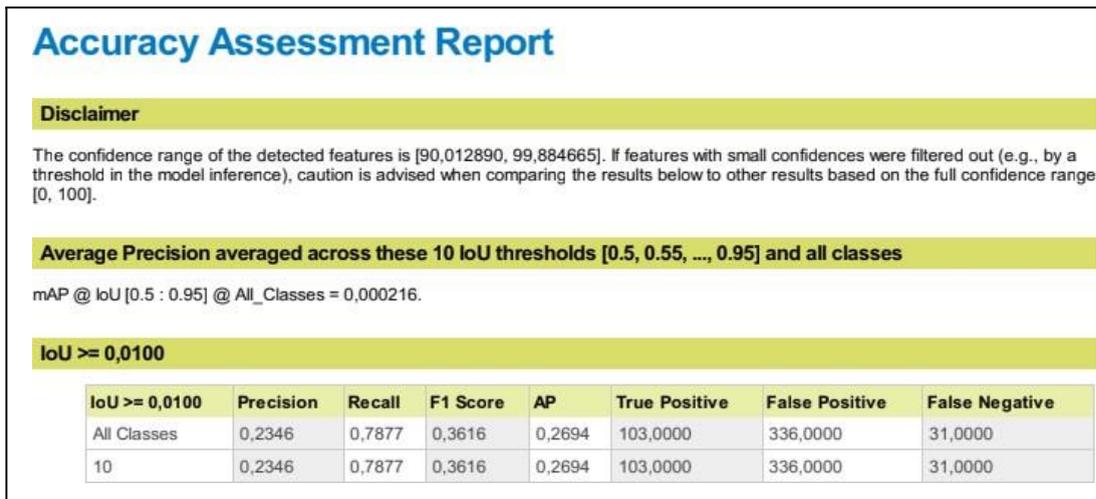


Figura 15: Resultado da Verificação de Acurácia do Modelo. Fonte: Autor.

5. DISCUSSÃO

Os resultados mostram que usar as ferramentas de geoprocessamento relacionadas ao Deep Learning dentro do ArcGIS Pro pode gerar a identificação e localização das árvores de Peroba-Rosa, vale evidenciar que existem várias oportunidades para melhorar o modelo e os resultados.

Elencar as oportunidades que foram mencionadas acima.

Elencar os fatores que podem ter contribuído para a baixa precisão do modelo.

As decisões sobre o tipo de modelo e modelo de backbone a usar foram influenciadas pelo computador disponível e pela precisão dos modelos testados, outros tipos de modelos e o uso de parâmetros mais avançados podem resultar em maior precisão na detecção de árvores de Peroba-Rosa. Portanto, o uso de recursos de hardware de alta performance deve ser considerado. Além disso, outras configurações e combinações de modelos devem ser usadas no contexto de outros estudos experimentais (HENNIG, 2021).

Trabalhos anteriores demonstraram o potencial do uso de métodos de aprendizagem profunda para identificar espécies, como é o caso do estudo de detecção de árvores individuais e classificação de espécies de palmeiras amazônicas usando imagens UAV e aprendizado profundo (FERREIRA et al., 2020) e do mapeamento preciso de castanheiras (*Bertholletia excelsa*) em florestas amazônicas usando imagens de satélite WorldView-3 e redes neurais convolucionais (FERREIRA et al. 2021). Além desses estudos, temos pesquisas que mostram o potencial do uso das redes neurais para conhecimento da vegetação, como vemos na Revisão sobre Redes Neurais Convolucionais (CNN) em sensoriamento remoto de vegetação (KATTENBORN, et al., 2021).

Além disso, temos trabalhos que fazem uso e auxiliam a popularizar as aplicações do ArcGIS PRO, como é o caso do estudo realizado Universidade da Flórida (*University of Florida*) onde é elucidado como realizar a classificação em Deep Learning de imagens de drone de alta resolução usando o software ArcGIS PRO (ABD-ELRAHMAN, 2021). E, também, o estudo realizado na Universidade de Viena (*Vienna University*) que usa as mesmas etapas de processamento para identificação de Prados de pomar, refere-se à combinação de árvores frutíferas extensivamente manejadas em combinação com campos e pastagens (HENNIG, 2021).

No presente trabalho foi desenvolvido um novo método baseado em redes neurais para mapear e identificar a Peroba-Rosa usando imagens RGB obtidas por meio de voo de VANT.

Segundo pesquisas realizadas durante a elaboração do presente trabalho, este é o primeiro estudo que demonstra o potencial do Deep Learning para identificação da Peroba-Rosa. De toda forma, o sucesso do estudo foi possível devido a copa característica da espécie de estudo, que permite à espécie se destacar dentre as demais presentes na floresta. Nossos resultados mostram que a Peroba pode ser mapeada em nível de copa, porém é necessário maior treinamento para obtenção de maior taxa de precisão do modelo.

6. CONCLUSÃO

O modelo investigado não foi capaz de identificar a copa de Peroba-Rosa satisfatoriamente, embora a metodologia em si tenha potencial para aprimoramentos em pesquisas futuras.

Com base nos resultados encontrados podemos concluir que:

- É viável desenvolver um modelo de identificação em Deep Learning para a Peroba-Rosa;
- O ArcGIS Pro é um software promissor para trabalhar com Deep Learning;
- Quando atingir melhor performance essa metodologia tem potencial de gerar ganho de gestão para atividades florestais.

Além disso, dados de treinamento de outras áreas podem ser integrados para fornecer um modelo melhorado e mais geral para identificação da espécie. O modelo adequadamente treinado poderia então ser usado com sucesso em outras regiões e, assim, contribuir para o manejo sustentável desta espécie.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABD-ELRAHMAN, A., BRITT, K., LIU, T. **Deep Learning Classification of High-Resolution Drone Images Using the ArcGIS Pro Software**. FOR374/FR444, 10/2021. EDIS, v. 2021, n. 5, 2021. Acesso em: 14/02/2023.

Avaliação de Detecção. **COCO Common Objects in Context**. Disponível em: <https://cocodataset.org/#detection-eval>. Acesso em: 04/02/2023.

ÁVILA-TORRES, I. et al. **Análisis Crítico de la Biogeografía del Paraguay**. Disponível em: http://scielo.iics.una.py/scielo.php?script=sci_arttext&pid=S2222-145X2018000100042. Acesso em: 08/01/2023.

BAULÉ, D. d. S.; GRESSE VON WANGENHEIM, C.; VONWANGENHEIM, A.; HAUCK, J. C. R. **Recent Progress in Automated Code Generation from GUI Images using Machine Learning Techniques**. Journal of Universal Computer Science, 26(9), 2020.

BORGES, C. D. B. **Aprendizado de atravessabilidade em imagens aéreas usando redes totalmente convolucionais**. 2021. 84f. Dissertação (Mestrado em Engenharia Elétrica e Computação) – Programa de Pós-Graduação em Engenharia Elétrica e de Computação - Campus de Sobral, Universidade Federal do Ceará, Sobral, 2021.

BRAGA, J. R. G., PERIPATO, V., DALAGNOL, R., FERREIRA, M. P., TARALBAKA, Y., ARAGÃO, O. C., CAMPOS VELHO, L. E. F., SHIGUEMORI, E. H., WAGNER, F. H. **Tree crown delineation algorithm based on a convolutional neural network**. Remote Sensing, v. 12, n. 8, p. 1288, 2020.

CÂMARA, G. e DAVIS, C. Introdução. In: CÂMARA, G.; DAVIS, C. e MONTEIRO, A. M. V. (Ed.). **Introdução à Ciência da Geoinformação**. São José dos Campos: INPE, 2003. p. 1-5.

CÉNSOS, Dirección General de Estadística Encuestas y (org.). **Atlas Censal del Paraguay**. Disponível em: <https://docplayer.es/7355132-Atlas-censal-del-paraguay.html>. Acesso em: 08/01/2023.

DB-CITY. **Hernandarias**. Disponível em: <https://pt.db-city.com/Paraguai--Alto-Paran%C3%A1--Hernandarias>. Acesso em: 08/01/2023.
EMBRAPA (ed.). **Peroba-Rosa: Aspidosperma polyneuron**. Curitiba: Embrapa, 2004. 12 p. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/287286/peroba-rosa-aspidosperma-polyneuron>. Acesso em: 08/01/2023.

ESRI. **ArcGIS Pro**. Disponível em: <https://www.esri.com/pt-br/arcgis/products/arcgis-pro/overview#liSwitcher>. Acesso em: 12/02/2023.

ESRI. **Deep learning in ArcGIS Pro**. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/deep-learning-in-arcgis-pro.htm>. Acesso em: 29/01/2023.

ESRI. **Export Training Data For Deep Learning**. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/export-training-data-for-deep-learning.htm>. Acesso em: 12/02/2023.

ESRI. **How Compute Accuracy For Object Detection works**. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/how-compute-accuracy-for-object-detection-works.htm>. Acesso em: 01/02/2023.

ESRI. **Introduction to deep learning**. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/what-is-deep-learning-.htm>. Acesso em: 29/01/2023.

ESRI. **Train Deep Learning Model**. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/train-deep-learning-model.htm>. Acesso em: 12/02/2023.

FASSNACHT, F. E., LATIFI, H., STENRECZAK, K. MODZELEWSKA, A., LEFSKY, M., WASER, L. T., STRAUB, C., GHOSH, A. **Review of studies on tree species classification from remotely sensed data**. Remote Sensing of Environment, v. 186, p. 64-87, 2016.

Disponível em:

https://www.sciencedirect.com/science/article/pii/S0034425716303169?casa_token=N6BycPbHCLoAAAAA:7HaCnUF94QEJjj7AVJ0CfSrxoj8Xcmx8pTOKgo3ADKGtn09sJoVxCyIpGA0AkQAdjLyO820Eg. Acesso: 04/02/2023.

FERREIRA, M. P., DE ALMEIDA, D. R. A., DE ALMEIDA PAPA, D., MINERVINO, J. B. S., VERAS, H. F. P., FORMIGHIERI, A., SANTOS, C. A. N., FERREIRA, M. A. D., FIGUEIREDO, E. O., FERREIRA, E. J. L.. **Individual tree detection and species classification of Amazonian palms using UAV images and deep learning**. Forest Ecology and Management, 475, 118397, 2020. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S037811272031166X>. Acesso em: 08/01/2023.

FERREIRA, M. P., LOTTE R. G., D'ELIA F. V., STAMATOPOULOS C., KIM D., RIBEIRO M. B. N., BENJAMIN A. R.. **Accurate mapping of Brazil nut trees (*Bertholletia excelsa*) in Amazonian forests using WorldView-3 satellite images and convolutional neural networks**. Ecological Informatics, v. 63, p. 101302, 2021. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S1574954121000935>. Acesso em: 08/01/2023.

FERREIRA, M.P., WAGNER, F.H., ARAGÃO, L.E., SHIMABUKURO, Y.E., DE SOUZA FILHO, C.R. **Tree species classification in tropical forests using visible to shortwave infrared worldview-3 images and texture analysis**. ISPRSJ. Photogram Remote Sens. 149, 119–131, 2019.

FLORENZANO, T. G. **Geotecnologias na geografia aplicada: difusão e acesso**. Revista do Departamento de Geografia, v. 17, p. 24-29, 2005. Acesso em: 08/01/2023

GALIZIA, L. F. C.; RAMIRO, G. A.; ROSA, C. J. C. **Qualidade das atividades silviculturais e silvicultura de precisão**. Série Técnica IPEF, Piracicaba, v.24, n.45, 2016.

HATSCHBACH, G. G.; ZILLER, S. R. **Lista vermelha de plantas ameaçadas de extinção no Estado do Paraná**. 1995. Disponível em: <<https://www.scielo.br/j/rarv/a/Vp89QgfTMzRQhJ3JY6TQDsj/?lang=pt&format=pdf>>. Acesso em: 04/02/2023.

HDX - Troca de Dados Humanitários, 2020. **Paraguai - Fronteiras Administrativas Subnacionais**. Disponível em: <<https://data.humdata.org/dataset/cod-ab-pry>>. Acesso em: 29/01/2023.

HENNIG, S. **Orchard meadow trees: tree detection using deep learning in ArcGIS pro**. GI_Forum 2021, v. 9, p. 82-93, 2021. Acesso em: 14/02/2023.
INPE. Bernardo F. T. Rudorff. Brasil (Org.). **Produtos de Sensoriamento Remoto**. Disponível em: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em: 08/01/2023.

JUNIOR, P., 2022. **Desenvolvimento de um modelo de avaliação de aprendizagem de machine learning no ensino médio voltado a detecção de objetos**. Disponível em: <https://repositorio.ufsc.br/handle/123456789/232989>. Acesso em: 08/01/2023.

KATTENBORN, T., LEITLOFF, J., SCHIEFER, F., HINZ, S., 2021. **Review on convolutional neural networks (cnn) in vegetation remote sensing**. ISPRS J. Photogramm. Remote Sens. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271620303488?via%3Dihub>. Acesso em: 04/02/2023.

LUNDQVIST, R. **Vants encontram madeira derrubada pelo vento**. Just Forest, Suécia, n. 01, p. 18-19, 2014.

MATLAB, I. **Introducing Deep Learning with MATLAB**. The MathWorks Inc. New York, USA, 2017.

MCROBERTS, R. E., TOMPPO, E. O. **Remote sensing support for national forest inventories**. Remote sensing of environment, v. 110, n. 4, p. 412-419, 2007. Disponível em: https://www.sciencedirect.com/science/article/pii/S0034425707001721?casa_token=Kw_HiDoQZzgAAAAA:F2EmYfv6UWbHahcBKg_jN4a07-PPL-g0_18kBRS5f5297yeLKBqgJWDmYfi-Kk-8K7pFpZMILA. Acesso em: 04/02/2023.

MORENO, G. A. P. **Efecto de Diferentes Dosis de Material Calcáreo Sobre el pH Y Acidez Intercambiable en Suelos Acidos de Textura Arcillosa y Arenosa en los Distritos de Hernandarias y Nueva Italia**. 2019. 71 f. Tese (Doutorado) - Curso de Geologia, Departamento de Geología, Universidad Nacional de Asunción, San Lorenzo, 2019. Disponível em: <https://www.geologiadelparaguay.com.py/Tesis-Ariel-Peralta.pdf>. Acesso em: 08/01/2023.

NAGENDRA, H., LUCAS, R., HONRADO, J. P., JONGMAN, R. H., TARANTINO, C., ADAMOS, M., & MAIROTA, P. et al. **Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats**. Ecological Indicators, v. 33, p. 45-59, 2013. Disponível em: https://www.sciencedirect.com/science/article/pii/S1470160X12003317?casa_token=EwKU-v

I9w0YAAAAA:caosEmgSb9KKCJpCR6oWpaDCtjn1Nu5FD3DWIDTv3cpWGacOgj6XYzbZAPzngjdpZpunAiItBQ. Acesso em: 04/02/2023.

OTERO, V., VAN DE KERCHOVE, R., SATYANARAYANA, B., MARTÍNEZ-ESPINOSA, C., FISOL, M. A. B., IBRAHIM, M.R.B., SULONG, I., MOHD-LOCKMAN, H., LUCAS, R., DAHDUH-GUEBAS, F., 2018. **Managing mangrove forests from the sky: Forest inventory using field data and unmanned aerial vehicle (uav) imagery in the matang mangrove forest, peninsular Malaysia.** *Forest Ecol. Manage.* 411, 35–45.

PATHMIND, A. **Beginner's Guide to Convolutional Neural Networks (CNNs).** Disponível em: <<https://wiki.pathmind.com/convolutional-network>>. Acesso em: 08/01/2023.

PECK, M., MARISCAL, A., PADBURY, M., CANE, T., KNIVETON, D., CHINCHERO, M.A., 2012. **Identifying tropical Ecuadorian Andean trees from inter-crown pixel distributions in hyperspatial aerial imagery.** *Appl. Veg. Sci.* 15, 548–559.

PETTORELLI, N., Schulte to Bühne H, Tulloch A, Dubois G, Macinnis-Ng C, Queirós AM, Keith DA, Wegmann M, Schrodt F, Stellmes M, Sonnenschein R (2017). **Satellite remote sensing of ecosystem functions: opportunities, challenges and way forward.** *Remote Sens Ecol Conserv*, v. 4, p. 71-93. Disponível em: <<https://zslpublications.onlinelibrary.wiley.com/doi/10.1002/rse2.59>>. Acesso em: 04/02/2023.

PONTES, G. R.; FREITAS, T. U. **Monitoramento de plantios de eucalipto utilizando técnicas de sensoriamento remoto aplicadas em imagens obtidas por VANT.** In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. São José dos Campos: INPE, 2015. p. 4057-4064.

ROSA, R.. **Introdução ao geoprocessamento.** UFU: Apostila, cap. 5. Uberlândia, 2013.
SANTOS, M. M. et al. **Estimativa de parâmetros florestais em área de cerrado a partir de imagens do sensor Landsat 8.** *Floresta*, v. 47, p. 75-83, 2017.

SHU, M. **Deep learning for image classification on very small datasets using transfer learning,** 2019. Disponível em: <<https://lib.dr.iastate.edu/creativecomponents/345>>. Acesso em: 08/01/2023.

TOCHON, G., FÉRET, J. B., VALERO, S., MARTIN, R. E., KNAPP, D. E., SALEMBIER, P., CHANUSSOT, J., ASNER, J. P. **On the use of binary partition trees for the tree crown segmentation of tropical rainforest hyperspectral images.** *Remote sensing of environment*, v. 159, p. 318-331, 2015. Disponível em: https://www.sciencedirect.com/science/article/pii/S0034425714005124?casa_token=73bOlpdonBwAAAAA:C1eBXtvQWaqAk--qzVT1wph_T3CR5VI2NMZd3zKLETFFV7v8TdTZmM0Yfoey07k4200KY4qkVQ. Acesso em: 04/02/2023.

TURNER, W., SPECTOR, S., GARDINER, N., FLADELAND, M., STERLING, E., Steininger, M.. **Remote sensing for biodiversity science and conservation.** *Trends in ecology & evolution*, v. 18, n. 6, p. 306-314, 2003. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169534703000703?casa_token=HzuXewG0J9cAAAAA:b1LwkhFWOguVsSOA6wHnE8RusSdcqPco7S8b02A53f55FJIU86ba5CD_ChVdB7yfwmn5fdK2jw>. Acesso em: 04/02/2023.

WAGNER, F. H., FERREIRA, M. P., SANCHEZ, A., HIRYE, M. C., ZORTEA, M., GLOOR,... & Aragão, L. E. **Individual tree crown delineation in a highly diverse tropical forest using very high resolution satellite images**. ISPRS journal of photogrammetry and remote sensing, v. 145, p. 362-377, 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271618302582>. Acesso em: 04/02/2023.

WARDEN, P. **How many images do you need to train a neural network?** 2017. Disponível em: <https://petewarden.com/2017/12/14/how-many-images-do-you-need-to-train-a-neural-network/>. Acesso em: 08/01/2023.

WHITE, J. C., COOPS, NC, WULDER, MA, VASTARANA, M., HILKER, T., TOMPALSKI, P.,. **Remote sensing technologies for enhancing forest inventories: A review**. *Canadian Journal of Remote Sensing*, v. 42, n. 5, p. 619-641, 2016. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/07038992.2016.1207484>. Acesso em: 04/02/2023.

ZHANG, Liangpei; ZHANG, Lefei; DU, B. **Deep learning for remote sensing data: A technical tutorial on the state of the art**. *IEEE Geoscience and remote sensing magazine*, v. 4, n. 2, p. 22-40, 2016. Disponível em: https://ieeexplore.ieee.org/abstract/document/7486259?casa_token=4tFzkwhD54gAAAAA:HsUK5BLSb3EBrfAxS1TezYOYoxSZZV0yq2dLMg8pSBumluGCNGJvaojRJ1nzg8TZcr45HJwFrg. Acesso em: 04/02/2023

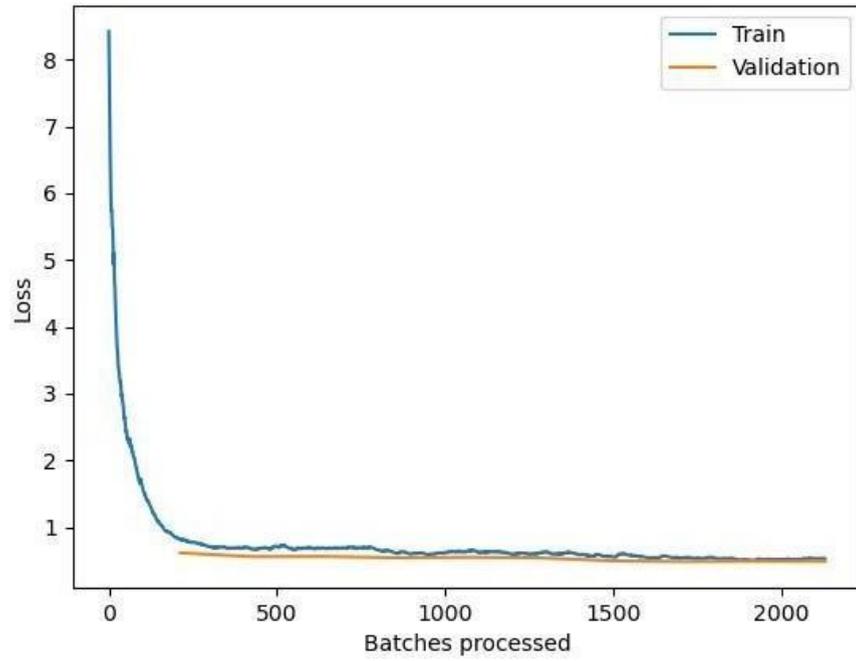
ANEXO

MaskRCNN

Backbone: resnet50

Learning Rate: slice('2.7542e-05', '2.7542e-04', None)

Training and Validation loss



Analysis of the model

Average Precision Score: {'10': 0.6648936171269586}

Ground Truth / Predictions

